

UNIVERSIDAD DE DEUSTO

ALGORITMOS PARA EL SEGUIMIENTO Y ADECUACIÓN DE LA CALIDAD DE LA COLONOSCOPIA EN EL CRIBADO DE CÁNCER COLORRECTAL

Tesis doctoral presentada por Alain Sánchez González
dentro del Programa de Doctorado en Ingeniería Informática y Telecomunicación
Dirigida por Dra. Begoña García-Zapirain Soto



UNIVERSIDAD DE DEUSTO

ALGORITMOS PARA EL SEGUIMIENTO Y ADECUACIÓN DE LA CALIDAD DE LA COLONOSCOPIA EN EL CRIBADO DE CÁNCER COLORRECTAL

Tesis doctoral presentada por Alain Sánchez González

dentro del Programa de Doctorado en Ingeniería Informática y Telecomunicación

Dirigida por Dra. Begoña García-Zapirain Soto

El doctorando La directora

Bilbao, febrero de 2017

Algoritmos para el seguimiento y adecuación de la calidad de la colonoscopia en el cribado de cáncer colorrectal.

Doctorando: Alain Sánchez González
Directora: Begoña García-Zapirain Soto

Texto impreso en Bilbao
Primera edición, febrero 2017

Resumen

El cáncer colorrectal (CCR) es el tumor maligno de mayor incidencia en España si se tiene en cuenta a hombres y mujeres. Según la Asociación Española Contra el Cáncer (AECC) cada año son diagnosticados entre 28.500 y 33.800 nuevos casos, detectándose alrededor de 20.000 de ellos en hombres y 14.000 en mujeres. Además, se estima que afectará a 1 de cada 20 hombres y a 1 de cada 30 mujeres antes de cumplir los 74 años, lo que supone una gran incidencia para la población. En cuanto a su mortalidad, es la segunda causa principal de fallecimientos asociados con el cáncer en España cuando se considera a ambos sexos juntos y por separado, estimándose alrededor de 15.000 muertes en el año 2015.

La investigación que se propone trata de aportar una ayuda al diagnóstico médico en dos de los aspectos más importantes de la colonoscopia, la evaluación de la calidad de preparación del colon y la detección de pólipos. Para ello se ha propuesto la siguiente hipótesis de trabajo: "Es posible diseñar algoritmos de procesado digital de imagen (PDI) que ayuden a la detección y segmentación automática de pólipos en imágenes colonoscópicas tras la verificación y evaluación de la calidad de preparación del colon del paciente". Para poder verificar la hipótesis se ha definido el objetivo principal del trabajo, quedando éste definido de la siguiente forma: "Diseñar y validar algoritmos de PDI para la verificación y evaluación de la calidad de preparación del colon basada en parámetros objetivos y detección automática de pólipos en imágenes colonoscópicas".

En cuanto a las aportaciones realizadas por la presente tesis doctoral, éstas se centran en dos aspectos. Por un lado, se ha diseñado un sistema de evaluación de la calidad de preparación del colon basado en

la escala de limpieza del colon de Boston (ELCB), haciendo uso de parámetros objetivos. Con ello se pone fin a una de las limitaciones de las escalas de evaluación, la subjetividad del evaluador. Por otro lado, se ha diseñado un sistema de detección automática de pólipos que servirá de apoyo al especialista, tratando de reducir al mínimo las lesiones perdidas.

Los resultados obtenidos tanto para la evaluación de la calidad de preparación del colon mediante la ELCB, como para la detección automática de pólipos han sido satisfactorios. La valoración de la ELCB proporcionada por el método diseñado ha conseguido una significancia estadística mediante el test de la suma de rangos por parejas de Wilcoxon con respecto a la realidad de $p = 0.086$, no observándose diferencias significativas. En cuanto al análisis de la correlación respecto a los valores reales, se ha conseguido una valoración del coeficiente de correlación intraclase (CCI) de 0.921, siendo una correlación de grado muy alto. Continuando con la detección automática de pólipos, se ha conseguido una tasa de detección con una precisión de un 96.05 % haciendo uso de la base de datos *CVC Colon Database*.

A la vista de los resultados obtenidos se puede afirmar que la hipótesis de partida ha quedado validada. Asimismo, se ha cumplido con el objetivo principal definido para la presente investigación. De esta manera se espera dotar a los especialistas de herramientas de ayuda al diagnóstico que repercutan de forma positiva en la salud de los pacientes.

Agradecimientos

Todo trabajo de investigación requiere la participación de numerosas personas e instituciones. Es gracias a su esfuerzo y dedicación por lo que se hace posible su consecución. Esta tesis doctoral no es una excepción, por lo que quiero expresar mi más sincero agradecimiento a quienes, de forma directa o indirecta, han contribuido durante todo este tiempo.

En primer lugar, agradezco a mi directora de tesis, la Dra. María Begoña García-Zapirain Soto, por permitirme realizar esta tesis doctoral bajo su dirección y que con su ayuda he podido culminar con éxito.

En segundo lugar, es preciso agradecer el apoyo mostrado hacia mi persona por Deiker, ya que confiaron tanto en mí como en la presente investigación, otorgándome una de las becas de formación de personal investigador, gracias a la cual he podido finalizar esta tesis doctoral.

En tercer lugar, quisiera agradecer al Departamento de Salud del Gobierno Vasco por confiar en el proyecto "Solución tecnológica para el seguimiento y adecuación de la calidad de la colonoscopia en el cribado de cáncer colorrectal", que ha sido financiado mediante la convocatoria de "Ayudas a Proyectos de Investigación en Salud", a partir del cual se ha desarrollado la presente tesis doctoral. Sin su ayuda no hubiese sido posible la realización de esta investigación.

En cuarto lugar, agradezco el tiempo y esfuerzo dedicado por los especialistas integrantes del grupo de investigación creado alrededor de esta tesis. Gracias a su asesoramiento y soporte se han podido cumplir los objetivos fijados. Por estos motivos, quisiera agradecer de forma especial a: Luis Bujanda, Inés Gil y Julyssa Cobián del Hospital Donostia, Fidencio Bao e Iñigo García del Hospital de San Eloy, Ángel

José Calderón y Ana Belén Díaz del Hospital de Basurto, Maite Escalante y Aitor Orive del Hospital Universitario Araba, Manuel Zaballa e Ignacio Morentín del Hospital Universitario Cruces, Alain Huerta del Hospital de Galdakao y por último a Isabel Idígoras e Isabel Portillo de Osakidetza Central.

En quinto lugar, agradezco el tiempo y esfuerzo dedicado por mis compañeros de departamento Jose Antonio Urigüen, Fernando Jorge, Gonzalo Eguíluz, Jose Maeso, Zelai Sáenz de Urturi y Álvaro Muro, ya que sus aportaciones, revisiones y experiencia han servido para mejorar de forma significativa el trabajo que se presenta. Además de esto, siempre he contado con su apoyo moral en los momentos más comprometidos, lo cual siempre es importante.

En sexto lugar, quisiera agradecer a mi compañera Yolanda García su esfuerzo, conocimiento experto en el campo de la estadística y dedicación desinteresada, que he aplicado en el capítulo de resultados, sin la cual no hubiera sido posible su conclusión.

En séptimo lugar, a mis abuelos y tíos, mi más sincero agradecimiento por su apoyo incondicional en todas las acciones que he emprendido a lo largo de mi vida y en especial en esta aventura llamada tesis doctoral.

En octavo lugar, a Berta Mota, un agradecimiento especial por sus aportes, mejoras y correcciones lingüísticas respecto a esta tesis doctoral, pero sobre todo, por su compañía sincera e incondicional desde hace más de 13 años, gracias de verdad.

Por último, quisiera agradecer el apoyo que me ha dado, no sólo durante la realización de esta tesis doctoral, sino durante toda una vida donde ha sido uno de mis principales apoyos, a mi tío *Txemi* de quien siempre me acordaré.

Muchas gracias,

Alain Sánchez González

febrero 2017

Índice general

Índice de figuras **xi**

Índice de cuadros **xxi**

1 Introducción **1**

1.1 Justificación de la investigación 2
1.2 Hipótesis 5
1.3 Objetivos 5
1.4 Metodología de la investigación 6
1.5 Estructura del documento 8

2 Estudio del estado del arte **11**

2.1 Antecedentes médicos 12
2.1.1 Descripción del aparato digestivo 12
2.1.2 Funciones del colon 13
2.1.3 Anatomía del colon 14
2.1.4 Histología del colon 17
2.1.5 Pólipos en el colon 18
2.1.6 Métodos de clasificación de pólipos colorrectales 19
2.1.6.1 Clasificación histológica 19
2.1.6.2 Clasificación de París 22
2.1.6.3 Clasificación Kudo 23
2.1.6.4 Clasificación de Viena 23
2.1.7 Pruebas diagnósticas 24

2.1.7.1 Colonoscopia 25
2.1.7.2 Colonoscopia virtual 27
2.1.7.3 Sigmoidoscopia 27
2.1.7.4 Enema de bario de doble contraste 28
2.1.7.5 Prueba de sangre oculta en las heces 29
2.1.8 Evaluación de la calidad de ejecución de la colonoscopia . 29
2.1.8.1 Indicadores de calidad de la colonoscopia . . . 30
2.1.8.2 Escalas para la evaluación de la preparación del colon 33
2.2 Antecedentes técnicos 39
2.2.1 Herramientas para el desarrollo de algoritmos de PDI . . . 40
2.2.1.1 Matlab 41
2.2.1.2 Scientific Python 41
2.2.1.3 OpenCV 42
2.2.1.4 ImageJ 42
2.2.1.5 WEKA 42
2.2.1.6 Elección del entorno de desarrollo 43
2.2.2 Modelos de color 43
2.2.2.1 Modelo RGB 44
2.2.2.2 Modelo HSI 45
2.2.2.3 Modelo HSV 45
2.2.2.4 Comparativa de los modelos de color RGB, HSI y HSV 47
2.2.3 Técnicas y métodos de mejora de imagen 48
2.2.3.1 Problemas en la captura de vídeos e imágenes colonoscópicas 48
2.2.3.2 Técnicas clásicas de mejora de imagen 55
2.2.4 Detectores de bordes 61
2.2.4.1 Uso de la derivada en la detección de bordes . . 63
2.2.4.2 Operadores basados en la primera derivada . . . 64
2.2.4.3 Operadores basados en la segunda derivada . . . 69
2.2.4.4 Técnica *depth of valleys* (DoV) 72
2.2.5 Métodos de segmentación 74

2.2.5.1 Segmentación mediante umbralización 75
2.2.5.2 Segmentación mediante crecimiento de regiones 76
2.2.5.3 Segmentación mediante la división y fusión de regiones 77
2.2.5.4 Transformación watershed 78
2.2.5.5 Algoritmo *fast marching* 79
2.2.5.6 Segmentación mediante modelos deformables . 80
2.2.5.7 Segmentación mediante clasificadores 81
2.2.5.8 Segmentación mediante técnicas de agrupamiento 82
2.2.6 Técnicas de evaluación de la calidad de ejecución de la colonoscopia 84
2.2.7 Resumen de las publicaciones para la evaluación de la calidad de ejecución de la colonoscopia 88
2.2.8 Técnicas de detección automática de pólipos 89
2.2.8.1 Detección de pólipos mediante el análisis de la forma 89
2.2.8.2 Detección de pólipos mediante el análisis de propiedades del color 97
2.2.8.3 Detección de pólipos mediante el análisis de textura 100
2.2.8.4 Detección de pólipos mediante el uso de descriptores *moving picture experts group 7* (MPEG-7) 105
2.2.9 Resumen de publicaciones y técnicas para la detección de pólipos 106
2.2.10 Estadísticas sobre las publicaciones referenciadas 106
2.3 Sumario 113

3 Base de datos **115**
3.1 Descripción de la base de datos 115
3.2 Población de referencia 120
3.3 Criterios de selección 122
3.4 Tamaño muestral 124

3.5 Método utilizado para la clasificación de la base de datos 124
3.6 Sumario 125

4 Diseño **127**
4.1 Diseño de alto nivel 127
4.1.1 Preprocesado de imágenes colonoscópicas (A) 128
4.1.2 Evaluación de la calidad de preparación del colon mediante la ELCB (B) 130
4.1.3 Detección automática de pólipos (C) 133
4.1.4 Generación de informes (D) 135
4.2 Diseño de bajo nivel 137
4.2.1 Preprocesado de imágenes colonoscópicas (A) 137
4.2.1.1 Eliminación de bordes negros (A1) 139
4.2.1.2 Eliminación de reflejos especulares (A2) 145
4.2.1.3 Normalización de la iluminación (A3) 155
4.2.1.4 Imagen preprocesada (A4) 156
4.2.2 Evaluación de la calidad de preparación del colon mediante la ELCB. (B) 156
4.2.2.1 Ajuste de los canales de color (B1) 157
4.2.2.2 Detección de heces (B2) 160
4.2.2.3 Clasificación de heces. (B3) 168
4.2.2.4 Cálculo de la ELCB (B4) 190
4.2.3 Detección automática de pólipos. (C) 194
4.2.3.1 Detección automática de pólipos mediante el análisis de bordes (C1) 195
4.2.3.2 Detección automática de pólipos mediante el análisis de la textura (C2) 234
4.2.3.3 Combinación de la detección de pólipos mediante los análisis de bordes y textura (C3) 239
4.2.4 Generación de informes (D) 242
4.3 Sumario 243

5 Resultados **245**

5.1 Definición del experimento 245

5.2 Evaluación de los resultados 246

5.2.1 Análisis de resultados del sistema de evaluación de la calidad de preparación del colon mediante la ELCB 246

5.2.1.1 Análisis de resultados de la precisión de la detección de heces diseñada (R1) 247

5.2.1.2 Análisis de resultados de la precisión de la clasificación de heces diseñada (R2) 256

5.2.1.3 Análisis de resultados de la precisión del cálculo de la ELCB diseñado (R3) 273

5.2.1.4 Comparativa del método de evaluación de la calidad del colon propuesto respecto a estudios del estado del arte 283

5.2.2 Análisis de la precisión del sistema de detección de pólipos diseñado 284

5.2.2.1 Análisis de la precisión de la clasificación mediante características de los bordes (R4) 285

5.2.2.2 Análisis de la precisión del área del pólipo detectada mediante el análisis de bordes (R5) . . . 294

5.2.2.3 Análisis de la precisión de la detección de pólipos mediante el análisis de bordes (R6) 295

5.2.2.4 Análisis de la precisión de la clasificación de las características de la textura (R7) 296

5.2.2.5 Análisis de la precisión del área del pólipo detectada mediante el análisis de la textura (R8) . 305

5.2.2.6 Análisis de la precisión de la detección de pólipos mediante el análisis de la textura (R9) . . . 306

5.2.2.7 Análisis de la precisión del área del pólipo detectada mediante el análisis combinado (R10) . 307

5.2.2.8 Análisis de la precisión de la detección de pólipos mediante el análisis combinado (R11) . . . 309

5.2.2.9 Comparativa del método de detección automática de pólipos propuesto respecto a estudios del estado del arte 310
5.3 Sumario 317

6 Conclusiones **319**
6.1 Revisión de los objetivos propuestos 319
6.2 Conclusiones técnicas 324
6.3 Conclusiones médicas 324
6.4 Impacto científico 325
6.4.1 Artículos en revistas científicas 325
6.4.2 Artículos en congresos y conferencias internacionales . . 325
6.4.3 Capítulos de libros 326
6.4.4 Proyectos relacionados 327
6.5 Líneas futuras 327

Bibliografía **331**

Índice de figuras

1.1 Principales motivos precursores de la pérdida de lesiones. a) Pliegues y recovecos en el colon. b) Imágenes con mala preparación. 4
1.2 Ciclo investigación-acción. 7

2.1 Órganos que componen el sistema digestivo. Fuente: goo.gl/aNL44q . . . 14
2.2 Anatomía del colon. Fuente:goo.gl/MCF6aS 15
2.3 Estructura histológica del colon. Fuente: goo.gl/4BUrzF 17
2.4 Clasificación de lesiones de París. Fuente: goo.gl/cZc58T 22
2.5 Colonoscopio. Fuente: goo.gl/6qtSW9 26
2.6 Elementos de las imágenes colonoscópicas. 26
2.7 Colonoscopia virtual. Fuente: goo.gl/S65MZd 28
2.8 Enema de bario de doble contraste. Fuente: goo.gl/fu73XA 29
2.9 Proyección de los píxeles de materia fecal y creación de los planos clasificadores. a) Proyección de los píxeles en el cubo RGB. b) Creación de los planos clasificadores. 38
2.10 Apariencia y forma no uniforme de los pólipos. a) Pólipo diminuto. b) Pólipo pediculado. c) Pólipo en pliegue lateral. d) Pólipo plano. 40
2.11 Modelo de color RGB. Fuente: goo.gl/xfsAOp 44
2.12 Modelo de color HSI. Fuente: goo.gl/le4aIQ 46
2.13 Modelo de color HSV. Fuente: goo.gl/sGtEUC 46
2.14 Máscara negra en las imágenes colonoscópicas. 49
2.15 Fantasmas de color en las imágenes colonoscópicas. 50
2.16 Efecto del entrelazado en las imágenes colonoscópicas. 51
2.17 Borde ideal de tipo rampa. Fuente: goo.gl/Y0XYDF 62

2.18 Concepto de primera y segunda derivada en la detección de bordes. Fuente: goo.gl/O103Hd 63
2.19 Simulación del efecto de la iluminación sobre un objeto. a) Incidencia de la fuente de luz sobre el objeto. b) Valles de intensidad que rodean al objeto. 72
2.20 Umbralizado del histograma. Fuente: goo.gl/dJOnj5 75
2.21 Crecimiento de regiones. Fuente: goo.gl/PDX7XQ 76
2.22 División y fusión de regiones. Fuente: goo.gl/ddYtNF 77
2.23 Segmentación mediante el algoritmo watershed. a) Imagen original. b) Vista topográfica. c) Inicio de la inundación. d) Fin de la inundación. Fuente: goo.gl/W52Gpq 79
2.24 Segmentación mediante *fast marching*. Fuente: goo.gl/SDs3tJ 80
2.25 Segmentación mediante modelos deformables. Fuente: goo.gl/8wDO1F . . 80
2.26 Clasificación de imágenes colonoscópicas en claras y borrosas mediante su análisis frecuencial. a) Imagen clara. b) Patrón de Fourier para una imagen clara. c) Imagen borrosa. d) Patrón de Fourier para una imagen borrosa. 85
2.27 Descomposición de los movimientos de inserción y extracción de la colonoscopia. a) Fases de inserción y extracción. b) Segmentación de la colonoscopia. 86
2.28 Identificación de los elementos del colon mediante patrones de encasillamiento. a) Elementos de una imagen colonoscópica encasillados. b) Patrones de los diferentes elementos colonoscópicos. . . 91
2.29 Pasos del algoritmo EF-DOVA. a) Selección del punto de inicio. b) Cálculo de los ejes de la elipse. c) Cálculo de los puntos de la elipse. d) Obtención de la vecindad. e) Acumulación. 93
2.30 Pasos del algoritmo SA-DOVA. a) Cálculo de los sectores circulares. b) Acumulación de los sectores. 95
2.31 Acumulación de los sectores en función de la orientación de los máximos. 96

2.32 Principios del algoritmo WM-DOVA. a) Completitud en la imagen original. b) Completitud en los resultados de la acumulación. c) Robustez en la imagen original. d) Robustez en los resultados de la acumulación. e) Continuidad en la imagen original. f) Continuidad en los resultados de la acumulación. g) Concavidad en la imagen original. h) Concavidad en los resultados de la acumulación. . . . 97

2.33 Proceso de cálculo del algoritmo WM-DOVA. a) Cálculo de S_i^{max} bajo el sector S_i. b) Definición de la ventana de los sectores y cálculo de S_n^{max} c) Obtención de las distancias d_n desde S_n^{max} al centro p y el cálculo de la acumulación final $\hat{S}_i^{max}$. 98

2.34 Transformada contourlet. Fuente: goo.gl/tSmhNa 105

2.35 Clasificación de las publicaciones por su temática principal. 108

2.36 Clasificación de las publicaciones de la categoría "Detección de anomalías en el colon" en función del tipo de lesión. 108

2.37 Clasificación de las publicaciones de la categoría "Evaluación de la calidad de la colonoscopia" en función de la temática principal. 109

2.38 Clasificación de publicaciones de la categoría "Información médica o técnica adicional" en función de la temática principal. 110

2.39 Clasificación de las publicaciones en base al modelo de color utilizado. 110

2.40 Clasificación de las publicaciones en base al tipo de imagen usado. 111

2.41 Clasificación de las publicaciones en base al enfoque de detección de anomalías utilizado. 112

2.42 Clasificación de las publicaciones en base al enfoque de extracción de características utilizado. 112

3.1 Descomposición de un vídeo en fotogramas. Fuente: goo.gl/zn7w9M . . . 116

3.2 Clasificación de los tipos de vídeos e imágenes colonoscópicas de la base de datos principal. a) Imagen colonoscópica sin pólipo. b) Imagen colonoscópica con pólipo. c) Imagen colonoscópica con mala preparación. 117

3.3 Imágenes disponibles en la base de datos *CVC Colon Database*. a) Imagen con pólipo. b) Máscara de detección del pólipo. c) Contorno del pólipo. 119
3.4 Diagrama de selección de la muestra. 121

4.1 Diseño de alto nivel. 128
4.2 Preprocesado de imágenes colonoscópicas. 129
4.3 Evaluación de la calidad de preparación del colon haciendo uso de la ELCB. 131
4.4 Detección automática de pólipos. 133
4.5 Generación de informes. 136
4.6 Módulo A. Preprocesado de imágenes colonoscópicas. 138
4.7 Máscaras negras con diferentes características: a) Máscara negra en las esquinas. b) Máscara negra circular y con información. c) Máscara negra bordeando a la imagen. 139
4.8 Eliminación de bordes negros. 140
4.9 Umbralizado para la detección de bordes negros: a) Umbralización del canal V resaltado en rojo. b) Resultado de la umbralización. . 141
4.10 Umbralizado para la detección de bordes negros: a) Bordes negros con información resaltada en rojo. b) Resultado de la apertura morfológica. 142
4.11 Proceso de recorte de los bordes negros. 143
4.12 Resultado de la eliminación de los bordes negros: a) Imagen original con bordes negros. b) Resultado de la eliminación de los bordes negros. 144
4.13 Eliminación de los reflejos especulares. 145
4.14 Detección de los reflejos especulares. μ representa el valor medio de la imagen sin bordes negros y W el factor multiplicador (0.3 por defecto). 146
4.15 Sistema de eliminación de los reflejos especulares. 149
4.16 Mezcla de la reconstrucción de los reflejos especulares. 150

4.17 Convolución de las imágenes con núcleos gaussianos. a) Imagen sin reflejos especulares. b) Imagen sin reflejos especulares convolucionada con un núcleo gaussiano. c) Máscara de los reflejos especulares dilatada. d) Máscara de los reflejos especulares dilatada y convolucionada con un núcleo gaussiano. 151
4.18 Mezcla de las imágenes. a) Máscara de los reflejos especulares dilatada gaussiana multiplicada por la imagen reconstruida. b) Inversa de la máscara de los reflejos especulares dilatada gaussiana multiplicada por la imagen reconstruida. 152
4.19 Resultado final de la eliminación de los reflejos especulares. a) Imagen con reflejos especulares reconstruidos sin suavizado. b) Imagen con reflejos especulares reconstruidos con suavizado. . . . 153
4.20 Resultado de la eliminación de los reflejos especulares. a) Imagen original. b) Imagen sin bordes negros ni reflejos especulares. c) Bordes de la imagen original (bordes especulares en rojo). d) Bordes de la imagen sin máscara negra ni reflejos especulares. 154
4.21 Normalización de la iluminación. 155
4.22 Resultado de la normalización de la iluminación. a) Imagen sin bordes negros ni reflejos especulares. b) Resultado de la normalización de la iluminación. 157
4.23 Módulo B. Evaluación de la calidad de preparación del colon mediante la ELCB. 158
4.24 Ajuste de los canales de color. 159
4.25 Rangos de colores de las heces en el canal H. 160
4.26 Resultado de la redistribución del canal H. a) Imagen sin la redistribución del canal H. b) Imagen con la redistribución del canal H. 160
4.27 Detección de las heces mediante el umbralizado del color. 161
4.28 Clasificación de las heces. 169
4.29 Varianza a la rotación. La imagen de la izquierda muestra una mujer joven y la de la derecha una mujer mayor. Ambas son la misma imagen variando la rotación de la misma. Fuente: goo.gl/9xBQQU 170
4.30 Ejemplo gráfico de la rotación y escalado de las ventanas. 171

4.31 Extracción de las características de la textura. Para el caso de los descriptores GLCM, LBP y SIFT es necesaria la rotación y escalado de las ventanas, en cambio los momentos de color no se ven afectados por tal aspecto. 172
4.32 Proceso de construcción de una matriz de co-ocurrencia de nivel de gris (GLCM). Fuente: goo.gl/XY2HV0 173
4.33 Operación de umbralizado en LBP. Fuente: goo.gl/VWPVnI 174
4.34 Diferentes escalas de una imagen. Fuente: goo.gl/BZtq8Z 175
4.35 Detección a nivel de subpíxel. Fuente: goo.gl/UT7Mjr 176
4.36 Regiones para el cálculo del descriptor SIFT alrededor de un punto. Fuente: goo.gl/eyaUzg 177
4.37 Proceso de reducción de características. 179
4.38 Reducción de características. 179
4.39 Descripción de la realización de la combinación mediante voto mayoritario. 182
4.40 Proceso de creación de las agrupaciones para la clasificación de las heces. 184
4.41 Creación de las agrupaciones para la clasificación de las heces. . . 187
4.42 Reordenación de la salida del clasificador. 188
4.43 Imágenes necesarias para el cálculo de la ELCB. 191
4.44 Metodología diseñada para el cálculo de la ELCB. W y $\%$ representan los pesos y porcentajes de heces de cada tipo. 192
4.45 Módulo C. Detección automática de pólipos. 195
4.46 Bloque C1. Detección automática de pólipos mediante el análisis de los bordes. 196
4.47 Efectos del ajuste de parámetros en el algoritmo de Canny. a) Imagen colonoscópica original. b) Bordes detectados sin el ajuste de parámetros. c) Bordes detectados con el ajuste de parámetros. . . . 197
4.48 Preprocesado de bordes. 198
4.49 Resultado de la eliminación de los bordes negros. a) Imagen con bordes originales. b) Imagen sin bordes de la máscara negra ni especulares. 200

4.50 Resultado de la eliminación de los bordes rectos. a) Imagen sin bordes de zonas oscuras ni especulares. b) Imagen sin bordes rectos. 201
4.51 Resultado de la eliminación de los bordes pequeños. a) Imagen sin bordes rectos. b) Imagen sin bordes pequeños. 202
4.52 Resultado de la eliminación de los bordes espurios. a) Imagen sin bordes pequeños. b) Imagen sin bordes espurios. 203
4.53 Resultado de la eliminación de los bordes rotos. a) Imagen con borde roto. b) Imagen con borde unido. 204
4.54 Cálculo de la curvatura de los bordes. 205
4.55 Resultado de aplicar un suavizado gaussiano a los bordes. a) Bordes preprocesados sin suavizado gaussiano. b) Bordes preprocesados con suavizado gaussiano. 206
4.56 Resultado del adelgazamiento de los bordes. a) Bordes preprocesados con suavizado gaussiano sin adelgazar. b) Bordes preprocesados con suavizado gaussiano adelgazados. 207
4.57 Resultado de la eliminación de las ramificaciones. a) Borde con una ramificación en color rojo. b) Borde con la ramificación eliminada. 208
4.58 Resultado de la reordenación de los puntos. a) Borde con puntos desordenados. b) Borde con puntos ordenados. 210
4.59 Resultado del cálculo de la curvatura. 212
4.60 Extracción de propiedades de la curvatura y los bordes. 213
4.61 Extracción de propiedades de la curvatura. 214
4.62 Extracción de propiedades de los bordes. 221
4.63 Metodología empleada para realizar la clasificación de los datos. . 223
4.64 Determinación del área del pólipo. 230
4.65 Resultado de la creación del área del pólipo. a) Bordes detectados como pertenecientes al pólipo en rojo. b) Máscara con el área del pólipo generada. 231
4.66 Detección automática de pólipos mediante el análisis de la textura. 235
4.67 Resultado de la creación del área del pólipo mediante el análisis de la textura. a) Imagen original. b) Máscara con el área del pólipo generada. 238

4.68 Metodología diseñada para la integración de las detecciones mediante el análisis de los bordes y de la textura. A y B corresponden a las detecciones de pólipos mediante el análisis de los bordes y de la textura de forma respectiva. 240
4.69 Módulo D. Generación de informes. 243

5.1 Distribución de los datos de los porcentajes totales de heces. a) Datos del especialista 1. b) Datos del especialista 2. c) Datos del método propuesto. d) Datos de las valoraciones reales. 249
5.2 Análisis de los errores de los porcentajes de heces determinados por los especialistas y el método propuesto. De aquí en adelante, la gráfica verde corresponderá al especialista 1, la azul al especialista 2 y la amarilla al método propuesto, siendo a) el EAM, b) la mediana del error y c) la desviación típica del error. 255
5.3 Distribución de los datos de los porcentajes totales de cada tipo de heces. a) Datos de heces líquidas del especialista 1. b) Datos de heces líquidas del especialista 2. c) Datos de heces líquidas del método propuesto. d) Datos de heces líquidas de las valoraciones reales. e) Datos de heces tintadas del especialista 1. f) Datos de heces tintadas del especialista 2. g) Datos de heces tintadas del método propuesto. h) Datos de heces tintadas de las valoraciones reales. i) Datos de heces sólidas del especialista 1. j) Datos de heces sólidas del especialista 2. k) Datos de heces sólidas del método propuesto. l) Datos de heces sólidas de las valoraciones reales. . . 258
5.4 Análisis de los errores de los porcentajes de heces líquidas determinados por los especialistas y el método propuesto. 270
5.5 Análisis de los errores de los porcentajes de heces tintadas determinados por los especialistas y el método propuesto. 271
5.6 Análisis de los errores de los porcentajes de heces sólidas determinados por los especialistas y el método propuesto. 272
5.7 Distribución de las valoraciones de la ELCB a analizar. a) Datos del especialista 1. b) Datos del especialista 2. c) Datos del método propuesto. d) Datos de las valoraciones reales. 275

5.8 Análisis de los errores de las valoraciones de la ELCB proporcionadas por los especialistas y el método propuesto. a) Las gráficas verde, azul y amarillo corresponden al EAM del especialista 1, especialista 2 y el método propuesto respecto a la valoración real de la ELCB. b) Siguiendo la misma nomenclatura que el apartado a) se muestran las desviaciones típicas de los errores. La unidad de medida de ambas gráficas es representada en puntos de la ELCB. . 281
5.9 Distribución de los valores de CAA y CD a lo largo de las imágenes de la base de datos para el análisis de los bordes. El eje de ordenadas representa los valores de CAA y CD. El de abscisas representa las imágenes de la base de datos. 295
5.10 Distribución de los valores de CAA y CD a lo largo de las imágenes de la base de datos para el análisis de la textura. El eje de ordenadas representa los valores de CAA y CD. El de abscisas representa las imágenes de la base de datos. 306
5.11 Distribución de los valores de CAA y CD a lo largo de las imágenes de la base de datos para el análisis combinado. El eje de ordenadas representa los valores de CAA y CD. El de abscisas representa las imágenes de la base de datos. 309
5.12 Distribución de la detección de pólipos. Los valores "1" y "0" indican la detección y fallo en la detección de pólipos de forma respectiva, correspondiéndose el eje de abscisas con las imágenes de la base de datos. a) Representa la detección de pólipos realizada por el análisis de propiedades de los bordes. b) Representa la detección de pólipos realizada por el análisis de textura. c) Representa la detección de pólipos realizada por el análisis combinado. 311

Índice de cuadros

2.1 Clasificación histológica de los pólipos. 21
2.2 Clasificación macroscópica de los pólipos. 22
2.3 Clasificación de pólipos de Kudo. 23
2.4 Clasificación de lesiones de Viena. 24
2.5 Adaptación de la clasificación de Viena según las GECCDC. . . . 25
2.6 Comparativa de los métodos para la clasificación de pólipos. . . . 25
2.7 Resumen de las pruebas diagnósticas de cáncer de colon. 30
2.8 Comparativa de las escalas de evaluación de la calidad de preparación del colon. La fila "Principio" indica el tipo de evaluación, "Zonas" la zona a evaluar, "Total" el rango de puntuación total, "Zona" el rango de puntuación por zona y "Líquido" la puntuación asignada a la cantidad de líquido. 38
2.9 Ventajas e inconvenientes de los modelos RGB, HSI y HSV. . . . 47
2.10 Comparativa de los métodos de detección de bordes descritos. . . 73
2.11 Comparativa de los métodos de segmentación descritos. 83
2.12 Resumen de las publicaciones de evaluación de la calidad de ejecución de la colonoscopia descritas. 89
2.13 Resumen de las técnicas de detección de pólipos. 107

3.1 Centros de salud y endoscopistas participantes en la creación de la base de datos principal. 118
3.2 Tamaño muestral de la base de datos principal. 124
3.3 Tamaño muestral de la base de datos secundaria *CVC Colon Database*. 124

3.4 Clasificación de los vídeos e imágenes de la base de datos. 125

4.1 Valoración de la concordancia según los valores del CCI. 167

5.1 Valores y significancia estadística del test de Kolmogorov-Smirnov. De aquí en adelante E1, E2, MP, R, K-S y *p* representarán al especialista 1, especialista 2, método propuesto, valores reales, el valor del test y la significancia estadística de forma respectiva. 249

5.2 Resultados del test de la suma de rangos por parejas de Wilcoxon para los porcentajes de heces totales detectados. De aquí en adelante la columna "dupla" representará todas las posibles parejas entre los grupos disponibles, siendo *p* el valor de la significancia. En todas las tablas de resultados relacionadas con el presente test, el valor de *p* para las duplas [E1, R], [E2, R] y [MP, R] será mejor cuanto más alto sea ya que indicará la no existencia de diferencias significativas con la realidad, demostrándose una mayor precisión. 250

5.3 Resultados obtenidos por el CCI para todas las duplas de los grupos disponibles. De aquí en adelante el valor del CCI para las duplas [E1, R], [E2, R] y [MP, R] será mejor cuanto más alto sea. Esto será un indicativo de una alta analogía con la realidad. 252

5.4 Resultados obtenidos para el análisis del error en la determinación del porcentaje de heces presente en las imágenes por parte de los especialistas y el método propuesto. De aquí en adelante EAM indicará el error absoluto medio, M_e la mediana del error y σ la desviación típica del error. 254

5.5 Valores y significancia del test de Kolmogorov-Smirnov de cada tipo de heces. De aquí en adelante H representará a las heces. . . . 257

5.6 Resultados del test de la suma de rangos por parejas de Wilcoxon para los porcentajes determinados de cada tipo de heces. 259

5.7 Resultados obtenidos por el CCI para todas las duplas de los grupos disponibles. 264

5.8 Resultados obtenidos en el análisis de los errores cometidos por los especialistas y el método propuesto en la determinación de las heces líquidas. 269

5.9 Resultados obtenidos en el análisis de los errores cometidos por los especialistas y el método propuesto en la determinación de las heces tintadas. 271
5.10 Resultados obtenidos en el análisis de los errores cometidos por los especialistas y el método propuesto en la determinación de las heces sólidas. 272
5.11 Rangos de las valoraciones definidas para el cálculo de la ELCB. . 274
5.12 Valores y significancia del test de Kolmogorov-Smirnov. 276
5.13 Resultados del test de la suma de rangos por parejas de Wilcoxon para las puntuaciones de la ELCB obtenidas. 276
5.14 Resultados obtenidos por el CCI para las valoraciones de la ELCB de todas las duplas de grupos disponibles. 278
5.15 Resultados obtenidos para el análisis del error en las puntuaciones de la ELCB obtenidas por los especialistas y el método propuesto. 281
5.16 Comparativa de los resultados obtenidos por el sistema propuesto para el cálculo de la ELCB respecto a la alternativa existente en el estado del arte. 283
5.17 Correspondencia de los diminutivos con los nombres de los clasificadores en las tablas de resultados. 286
5.18 Clasificación del conjunto original de las características extraídas de los bordes. De aquí en adelante las filas corresponderán a los diferentes clasificadores utilizados y las columnas a las diferentes métricas de evaluación de la clasificación, siendo Prec. la precisión, Sens. la sensibilidad, V-F el valor-F, ROC el área ROC, % el porcentaje de acierto, K el valor del estadístico Kappa y EAM el error absoluto medio. 287
5.19 Clasificación del conjunto de las características de los bordes reducidas mediante la técnica ESME. 288
5.20 Clasificación del conjunto de las características de los bordes reducidas mediante la técnica ESAC. 290
5.21 Clasificación del conjunto de las características de los bordes reducidas mediante la técnica PCA. 291

5.22 Clasificación del conjunto de las características de los bordes reducidas mediante la combinación propuesta. 292
5.23 Comparativa de los porcentajes de acierto obtenidos en las clasificaciones de los diferentes conjuntos de características. De aquí en adelante Comb. representará la combinación diseñada. 293
5.24 Indicadores de calidad de la segmentación realizada por el análisis de los bordes. 294
5.25 Correspondencia de los diminutivos con los nombres de los clasificadores en las tablas de resultados. 296
5.26 Clasificación del conjunto original de las características extraídas de la textura. 298
5.27 Clasificación del conjunto de las características de la textura reducidas mediante la técnica ESME. 299
5.28 Clasificación del conjunto de las características de la textura reducidas mediante la técnica ESAC. 300
5.29 Clasificación del conjunto de las características de la textura reducidas mediante la técnica PCA. 301
5.30 Clasificación del conjunto de las características de la textura reducidas mediante la combinación diseñada. 303
5.31 Comparativa de los porcentajes de acierto obtenidos en las clasificaciones utilizando los diferentes conjuntos de características. . . 304
5.32 Indicadores de la calidad de la segmentación realizada por el análisis de la textura. 305
5.33 Indicadores de la calidad de la segmentación realizada por la combinación propuesta del análisis de los bordes y de la textura. . . . 307
5.34 Comparativa de las tasas de detección de pólipos alcanzadas por los análisis de bordes, textura y su combinación. 309
5.35 Comparativa de la efectividad de las características de los bordes y de la textura extraídas respecto a los estudios existentes en la literatura. 312
5.36 Comparativa de la calidad de segmentación conseguida por el método propuesto respecto a los estudios existentes en la literatura. . . 315

5.37 Comparativa de la tasa global de detección de pólipos conseguida por el método propuesto respecto a los estudios existentes en la literatura. 316

6.1 Publicación 1. 325
6.2 Publicación 2 (en revisión). 326
6.3 Publicación 3 (en revisión). 326
6.4 Contribución en congreso. 326
6.5 Contribución en conferencia web. 327
6.6 Capítulo de libro (en revisión). 327
6.7 Proyecto relacionado con la tesis doctoral que se presenta. 328

ABC	Área bajo la curva.
AC	Ascenso de colinas.
AECC	Asociación Española Contra el Cáncer.
API	*Application programming interface* (Interfaz de programación de aplicaciones).
ARFF	*Attribute-relation file format* (Formato de fichero atributo-relación).
ASGE	*American Society of Gastrointestinal Endoscopy* (Sociedad Americana de Endoscopia Gastrointestinal).
BP	*Bandwidth power* (Potencia del ancho de banda).
BUMC	*Boston University Medical Center* (Centro Médico de la Universidad de Boston).
CAA	Cobertura de área anotada.
CCI	Coeficiente de correlación intraclase.
CCR	Cáncer colorrectal.
CD	Coeficiente de Dice.
CLBP	*Complete local binary patterns* (Patrones locales binarios completos).
CWC	*Color wavelet covariance* (Covarianza de color wavelet).
DE	Densidad espectral.
DEE	Densidad espectral de energía.
DoG	*Difference of gaussians* (Diferencia de gaussianas).
DoV	*Depth of valleys* (Profundidad de valles).
E1	Especialista 1 (Utilizado en tablas de resultados).
E2	Especialista 2 (Utilizado en tablas de resultados).
EAM	Error absoluto medio.
EF-DOVA	*Ellipse fiting depth of valleys accumulation* (Acumulación de profundidad de valles mediante el ajuste de elipses).
ELCA	Escala de limpieza del colon de Aronchick.
ELCB	Escala de limpieza del colon de Boston.
ELCO	Escala de limpieza del colon de Ottawa.
ENBW	*Equivalent noise bandwidth* (Ancho de banda de ruido equivalente).
ESAC	Evaluación de subconjuntos mediante el análisis de la correlación.
ESME	Evaluación de subconjuntos mediante envoltorios.
ESGE	*European Society of Gastrointestinal Endoscopy* (Sociedad Europea de Endoscopia Gastrointestinal).
FDA	*Food and Drug Administration* (Administración de Alimentos y Medicamentos).
FFT	*Fast Fourier transform* (Transformada rápida de Fourier).

FN	Falsos negativos.
FP	Falsos positivos.
GECCDC	Guías Europeas de Calidad en el Cribado y Diagnóstico Colorrectal.
GLCM	*Gray level co-ocurrence matrixes* (Matrices de co-ocurrencia del nivel de gris).
HA	Hipótesis alternativa.
H0	Hipótesis nula.
HOG	*Histogram of oriented gradients* (Histograma de gradientes orientados).
HSI	*Hue, saturation, intensity* (Tonalidad, saturación, intensidad).
HSV	*Hue, saturation, value* (Tonalidad, saturación, valor).
ISODATA	*Iterative self-organizing data analysis technique yAy!* (Técnica de análisis de datos iterativa auto-organizada).
IA	Inteligencia artificial.
L*a*b	*CIE 1976 color model* (Modelo de color CIE 1976).
LBP	*Local binary patterns* (Patrones locales binarios).
LoG	*Laplacian of gaussian* (Laplaciano del gaussiano).
MP	Método propuesto (Utilizado en tablas de resultados).
MPEG-7	*Moving picture experts group 7* (Grupo de expertos de movimiento de imágenes 7).
MSA-DOVA	*Maximum sector accumulation depth of valleys accumulation* (Acumulación de profundidad de valles de acumulación máxima de sectores).
NBI	*Narrow band imaging* (Imagen de banda estrecha).
NIH	*National Institutes of Health* (Instituto Nacional de la Salud).
NTSC	*National television system committee* (Comité nacional de sistema de televisión)
OBM	*Occupied bandwidth mesasure* (Medida del ancho de banda ocupado).
OC-LBP	*Opponent color local binary patterns* (Patrones locales binarios de color oponente).
OC-RGB	*Opponent color red, green, blue* (Rojo, verde, azul oponente).
OMS	Organización Mundial de la Salud.
PAL	*Phase alternating line* (Línea de fase alternada).
PDI	Procesado digital de imagen.
PCA	*Principal component analysis* (Análisis de componentes principales).
PM	Primero el mejor.
PSD	*Power spectral density* (Densidad espectral de potencia).
R	Realidad (Utilizado en tablas de resultados).

RFP	Ratio de falsos positivos.
RGB	*Red, blue, green* (Rojo, verde, azul).
RIULBP	*Rotation invariant uniform local binary patterns* (Patrones locales binarios uniformes invariantes a la rotación).
ROC	*Receiver operating characteristic* (Característica operativa del receptor).
RVP	Ratio de verdaderos positivos.
S-RGB	*Standard red, green, blue* (Rojo, verde, azul estándar).
SA-DOVA	*Sector accumulation depth of valleys accumulation* (Acumulación de profundidad de valles en sectores).
SFDR	*Spurious free dynamic range* (Rango dinámico libre de espurios).
Shape-UCM	*Shape ultrametric contour map* (Mapa de contornos de forma ultramétricos).
SINAD	*Signal to noise and distortion ratio* (Relación señal a ruido y distorsión).
Snakes	*Active contours deformable models segmentation* (Segmentación mediante modelos deformables).
SNR	*Signal to noise ratio* (Relación señal a ruido).
SVM	*Support vector machines* (Máquinas de soporte vectorial).
SIFT	*Scale-invariant feature transform* (Transformada de características invariantes a escala).
THD	*Total harmonic distortion* (Distorsión armónica total).
TIC	Tasa de intubación cecal.
TSL	*Tint, saturation, lightness* (Matiz, saturación, luminosidad).
VO-DOVA	*Vector orientation depth of valleys accumulation* (Acumulación de profundidad de valles de vectores orientados).
VP	Verdaderos positivos.
VPP	Valor predictivo positivo.
WM-DOVA	*Window median depth of valleys accumulation* (Mediana de la ventana de acumulación de profundidad de valles).
WEKA	*Waikato environment for knowledge analysis.*
YUV	*Luminance, chrominance, value* (Luminancia, crominancia, valor).

"You don't write because you want to say something; you write because you've got something to say."

F. Scott Fitzgerald

CAPÍTULO

1

Introducción

El incesante incremento en la incidencia del cáncer colorrectal (CCR) en las últimas décadas ha desembocado en un aumento de la realización de pruebas médicas, en el caso que nos ocupa, la colonoscopia. Esto tiene como resultado un mayor volumen de trabajo para los especialistas, quienes se ven desbordados. A consecuencia de esta problemática, en los últimos años se han realizado numerosas investigaciones centradas en el desarrollo de herramientas de ayuda al diagnóstico que sirvan de apoyo a los especialistas.

Esta tesis se centra en el desarrollo de métodos de procesamiento digital de imagen (PDI) para su aplicación en imágenes colonoscópicas. Se pretende realizar una **evaluación de la calidad de preparación del colon del paciente basada en parámetros objetivos**, así como una **detección y segmentación automática de pólipos**.

El proceso necesario para la aplicación de métodos de PDI en imágenes colonoscópicas sufre de diversas complicaciones que pueden influir de forma negativa en los resultados finales de la investigación. Por tanto, esta tesis se centra en primer lugar en la realización de un estudio completo de las principales técnicas de PDI. Tras ello, se realiza un análisis y evaluación de las mismas con el fin de seleccionar

aquellas que mejor se ajusten a la problemática a abordar. A continuación se propone un método a partir de las técnicas elegidas. Para finalizar, se realiza un análisis que comprueba su eficacia mediante métodos estadísticos.

Con la finalidad de validar y estudiar de manera adecuada el proceso llevado a cabo, toda la investigación está centrada dentro del CCR e imágenes colonoscópicas. De esta manera se pueden comprobar y establecer resultados reales y precisos a partir de un conjunto de datos de entrada ya verificados. Las bases de datos de imágenes y vídeos colonoscópicos utilizadas pertenecen a sujetos de estudio participantes en programas de cribado colorrectal, cuyo objetivo es la detección y extirpación de pólipos precancerosos. De esta forma se previene el desarrollo de tumores malignos y/o su detección en estadios precoces. Gracias a ello no solo se puede diagnosticar el cáncer de colon en estados tempranos y tratarlo en sus fases iniciales, donde la supervivencia es mucho más elevada, sino que incluso se puede evitar la aparición misma de la enfermedad.

El resto del capítulo se encuentra organizado como sigue. La sección 1.1 ≪Justificación de la investigación≫ describe la justificación de la investigación realizada. La sección 1.2 ≪Hipótesis≫ formula la hipótesis de esta tesis. La sección 1.3 ≪Objetivos≫ expone los objetivos principales y secundarios identificados para la consecución de la tesis. La sección 1.4 ≪Metodología de la investigación≫ plantea la metodología seguida durante la investigación. Por último, la sección 1.5 ≪Estructura del documento≫ describe la estructura del documento.

1.1 Justificación de la investigación

El CCR es el tumor maligno de mayor incidencia en España si se tiene en cuenta a hombres y mujeres. Según la Asociación Española Contra el Cáncer (AECC) [AEC] cada año son diagnosticados entre 28.500 y 33.800 nuevos casos, detectándose alrededor de 20.000 de ellos en hombres y 14.000 en mujeres. Además, se estima que afectará a 1 de cada 20 hombres y a 1 de cada 30 mujeres antes de cumplir los 74 años, lo que supone una gran incidencia para la población. En cuanto a su mortalidad, es la segunda causa principal de fallecimientos asociados con el cáncer en España cuando se considera a ambos sexos juntos y por separado, estimándose alrededor de 15.000 muertes en el año 2015.

La tasa de mortalidad a causa del CCR ha disminuido tanto en hombres como en mujeres durante las últimas décadas. Esto es debido a dos motivos principales, en primer lugar, los tratamientos médicos son cada vez más efectivos, lo que incrementa las tasas de supervivencia de los afectados y en segundo lugar, existe una mayor difusión de campañas para el diagnóstico precoz del CCR, lo que hace que se detecten muchos más casos y además, multitud de ellos en fases iniciales, cuando las tasas de supervivencia son mayores.

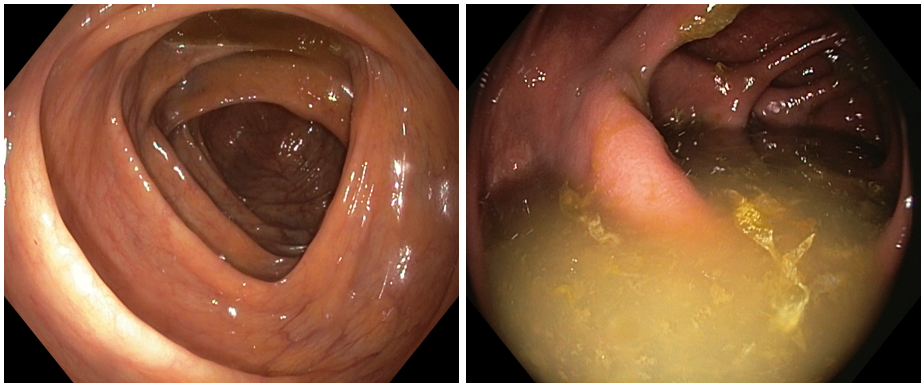
La mayor esperanza de vida de las personas diagnosticadas de cáncer de colon, junto con la emergente difusión de campañas de diagnóstico precoz, hace que cada día se requiera de la realización de un mayor número de pruebas diagnósticas, lo que supone un incremento de costes económicos, además de una saturación de los servicios médicos.

Debido a la problemática generada, en los últimos años se ha dado una tendencia a desarrollar herramientas de ayuda al diagnóstico médico. Éstas sirven de apoyo a los especialistas, aportándoles datos objetivos que ayudan en la interpretación de las pruebas, consiguiendo unos diagnósticos más exactos, además de facilitar la labor de los médicos, que en muchos casos se ven desbordados por la cantidad de trabajo.

La investigación que se presenta se centra en el desarrollo de una herramienta de ayuda al diagnóstico para especialistas en endoscopia digestiva baja. La endoscopia es una técnica que consiste en la introducción de una cámara o lente dentro de un tubo o endoscopio a través de un orificio natural, incisión quirúrgica o lesión para la visualización del interior de un órgano, hueco o cavidad corporal. En el caso del cáncer de colon, la prueba diagnóstica más utilizada es la colonoscopia, que permite la inspección del colon y el recto del paciente, permitiendo la detección y extirpación de lesiones.

La principal problemática de la colonoscopia son las denominadas **lesiones perdidas**. Las lesiones perdidas son aquellas que no han sido detectadas por el endoscopista durante la realización de la prueba diagnóstica, de forma que al no localizar anomalía alguna se planifica una revisión del paciente a largo plazo, periodo en el que aquella lesión no detectada puede derivar en cáncer de intervalo. Éstas se deben a dos motivos primordiales:

- Dificultad del entorno de exploración: el colon es un órgano con multitud de pliegues y recovecos lo que dificulta las tareas de exploración (véase figura 1.1(a)).
- Mala preparación del colon: el paciente debe someterse a una dieta previa a la realización de la colonoscopia para limpiar su colon. Por diversos motivos esta recomendación no es llevada a cabo en gran cantidad de casos (véase figura 1.1(b)).



(a) (b)

Figura 1.1: Principales motivos precursores de la pérdida de lesiones. a) Pliegues y recovecos en el colon. b) Imágenes con mala preparación.

Por todas estas razones se considera que existen motivos más que suficientes para justificar la investigación que se presenta. Estos se resumen de la siguiente forma:

- Dada la gran incidencia mundial del CCR es necesario desarrollar herramientas innovadoras que proporcionen una ayuda al diagnóstico médico, aportando datos objetivos a los especialistas.
- Es indispensable disponer de una herramienta que permita la evaluación objetiva de la calidad de preparación del colon del paciente. La limpieza del colon es un factor crucial para la ejecución de una colonoscopia con garantías. En la actualidad los especialistas indican en el informe de endoscopia la valoración de la limpieza observada haciendo uso de diversas escalas, siendo la

más utilizada la escala de limpieza del colon de Boston (ELCB) [LCD+09]. En este aspecto existe una gran controversia, ya que es una valoración subjetiva. Esto imposibilita la realización de comparativas entre centros de salud y la evaluación de las dietas propuestas a los pacientes para realizarse la colonoscopia. Por estos motivos se hace necesario contar con herramientas que evalúen la calidad de preparación del colon basándose en parámetros objetivos.

- Se requiere contar con herramientas que permitan disminuir la tasa de lesiones perdidas. Como ya se ha comentado con anterioridad, las lesiones perdidas derivan en un agravamiento de la salud del paciente, por lo que se requiere de la implementación de algoritmos para la detección y segmentación automática de pólipos.

Tras exponer la justificación de la investigación propuesta, se procede a describir la hipótesis de la misma.

1.2 Hipótesis

La justificación de la investigación muestra las razones más destacadas para la realización de esta tesis, de las cuales se extrae la siguiente hipótesis:

> *"Es posible diseñar algoritmos de PDI que ayuden a la detección y segmentación automática de pólipos en imágenes colonoscópicas tras la verificación y evaluación de la calidad de preparación del colon del paciente."*

1.3 Objetivos

Una vez formulada la hipótesis se determinará el objetivo principal y los secundarios. El objetivo principal de la investigación propuesta es:

> *"Diseñar y validar algoritmos de PDI para la verificación y evaluación de la calidad de preparación del colon basada en parámetros objetivos y detección automática de pólipos en imágenes colonoscópicas."*

Este objetivo principal se divide en varios subobjetivos más específicos. Estos son los siguientes:

1. Crear una base de datos de vídeos e imágenes colonoscópicas.

2. Diseñar un método para la evaluación automática de la calidad de preparación del colon del paciente basado en la ELCB.

3. Validar la eficacia del método diseñado para la evaluación automática de la calidad de preparación del colon del paciente basado en la ELCB.

4. Diseñar un método para la detección y segmentación automática de pólipos en imágenes colonoscópicas.

5. Validar la eficacia del método diseñado para la detección y segmentación automática de pólipos en imágenes colonoscópicas.

1.4 Metodología de la investigación

La metodología empleada para la realización de la presente tesis doctoral está basada en el modelo de investigación-acción [L$^+$92] de Whitehead [Lat03]. Éste la definió como:

> *"Una forma de cuestionamiento autorreflexivo, llevada a cabo por los propios participantes en determinadas ocasiones con la finalidad de mejorar la racionalidad y la justicia de situaciones, de la propia práctica social educativa, con el objetivo también de mejorar el conocimiento de dicha práctica y sobre las situaciones en las que la acción se lleva a cabo"*

La investigación-acción es un enfoque de investigación colaborativa que proporciona a la gente los medios para llevar a cabo acciones sistemáticas que resuelvan sus problemas; se formulan los procedimientos consensuados y participativos que permiten investigar problemas, formular interpretaciones, analizar situaciones y elaborar planes para resolverlos.

1) Dónde nos encontramos, 2) dónde queremos llegar y 3) cómo vamos a llegar allí.

Se puede considerar la palabra investigación para referirse a una mejora a la hora de entender la problemática a tratar y la palabra acción para referirse al cambio que se trata de poner en práctica. La investigación-acción es un ciclo de investigación y reflexión. Es un proceso cíclico de exploración, actuación y valoración de resultados. Durante todo el proceso, se formularán una serie de preguntas, las cuales se irán contestando a medida que se avanza en el ciclo (véase figura 1.2).



Figura 1.2: Ciclo investigación-acción.

En términos generales, el ciclo investigación-acción se compone de los siguientes elementos:

1. Identificar el problema: el proceso comienza con la identificación de alguna pregunta o problema que se quiere abordar. La investigación-acción es más exitosa cuando se trata de abordar un problema detectado por la persona que va a realizar la investigación. Aprender a desarrollar las preguntas correctas conlleva un tiempo. Es importante acotar el alcance del problema a abordar, debido a que si no es así, el área de acción será demasiado amplia y la acción no será efectiva.

2. Desarrollar un plan de acción: una vez identificado el problema, es necesario tener una visión de cómo resolverlo revisando la literatura pertinente. De esta forma se obtienen técnicas y estrategias válidas para abordar el problema. El

plan de acción muestra cómo se va a implementar la solución y cómo se van a abordar cada una de las variables definidas.

3. Recopilar datos: antes de empezar a poner en práctica el plan de acción, es necesario determinar qué datos ayudarán a validar el éxito o no del plan y cómo se van a recopilar. Hay muchas maneras para llevar a cabo la recolección de datos. La elección de las mejores metodologías de recolección de información dará lugar a datos más precisos, significativos y confiables. Fuentes de información claras son la observación y las entrevistas. También se pueden obtener datos de registros y/o revistas.

4. Analizar datos y extraer conclusiones: una vez obtenidos los datos, el siguiente paso es analizarlos para extraer conclusiones. Analizar los datos durante la recogida de los mismos es un proceso que puede ayudar a redefinir el plan de acción, puesto que puede ayudar a conocer si los datos obtenidos son suficientes o hay que ampliar los mismos. Una vez analizados los datos, es momento de sacar conclusiones y confirmarlas mediante el análisis. Es importante seguir obteniendo datos a pesar de obtener las conclusiones, para reforzar éstas.

5. Modificar la teoría y repetir el ciclo: tras obtener los resultados, el ciclo vuelve a comenzar. A la luz de lo obtenido, se puede ajustar la teoría y hacerla más específica, obteniendo nuevos datos y validándola.

6. Informar de los resultados: compartir los resultados es una tarea indispensable en cualquier trabajo de investigación. Esto ayuda a la comunidad en sus planteamientos y los motiva a seguir con sus investigaciones.

1.5 Estructura del documento

La presente tesis doctoral se compone de seis capítulos que se describen a continuación:

- Capítulo 1 ≪Introducción≫: este capítulo describe una aproximación de la investigación realizada para esta tesis doctoral. Para ello se describe la justificación de la hipótesis, la propia hipótesis, los objetivos fijados que son

necesarios para su consecución, así como la metodología de la investigación llevada a cabo.

- Capítulo 2 ≪Estudio del estado del arte≫: este capítulo presenta en primer lugar un conjunto de conceptos y definiciones necesarios para entrar en la temática de esta tesis. En segundo lugar, se describen en detalle los antecedentes tanto médicos como técnicos evaluados con anterioridad al desarrollo de la investigación. Por último, se realiza una comparativa entre los más relevantes, indicando en las conclusiones finales del capítulo la necesidad real existente en este campo de investigación.

- Capítulo 3 ≪Base de datos≫: en este capitulo se describe el conjunto de vídeos e imágenes colonoscópicas disponibles para la realización de esta investigación. Se especifica tanto la cantidad de vídeos, como de imágenes disponible, además de realizar una clasificación de ellos.

- Capítulo 4 ≪Diseño≫: este capítulo describe los métodos desarrollados para la realización de esta tesis, tanto en alto como en bajo nivel. Para ello, en primer lugar se definen las técnicas de extracción de características, detección de bordes, segmentación, reducción de características y clasificación utilizadas. En segundo lugar, se detalla la arquitectura propuesta para la consecución de los objetivos fijados. Por último, se detallan los procesos a seguir para la validación de los métodos desarrollados.

- Capítulo 5 ≪Resultados≫: este capítulo muestra los resultados conseguidos por los métodos propuestos en el capítulo anterior. Se detalla cada uno de los resultados parciales generados y su evaluación.

- Capítulo 6 ≪Conclusiones≫: por último, este capítulo reúne las conclusiones obtenidas en la tesis doctoral junto a una discusión basada en los resultados conseguidos, haciendo referencia a los puntos más notables. Para finalizar se exponen las líneas futuras que se pretenden llevar a cabo para profundizar en los métodos de análisis automático de colonoscopias.

"Information is not knowledge. Knowledge is not wisdom. Wisdom is not truth. Truth is not beauty."

Frank Zappa

CAPÍTULO

2

Estudio del estado del arte

El desarrollo de algoritmos para la ayuda al diagnóstico médico, evaluación de la calidad de la ejecución de las colonoscopias y la realización de un seguimiento óptimo del paciente, requiere conocimientos previos. El capítulo que nos ocupa se compone de los apartados: 2.1 ≪Antecedentes médicos≫ y 2.2 ≪Antecedentes técnicos≫. En ellos se presenta una revisión de la bibliografía más relevante que sienta las bases de la investigación propuesta.

El apartado de antecedentes médicos realiza una breve descripción de la funcionalidad del aparato digestivo, en especial de uno de sus integrantes, el colon. Para ello se describirán sus funciones, anatomía e histología. A continuación, se abordará el impacto que tienen los pólipos en el colon, describiéndose la problemática que suponen y las diferentes clasificaciones existentes. Más adelante, se explicarán diversas pruebas diagnósticas, haciendo hincapié en la colonoscopia, ya que los algoritmos desarrollados están basados en imágenes de este tipo de prueba. Por último, se explican los diferentes indicadores de la calidad de ejecución de la colonoscopia y las escalas de valoración de la preparación del colon del paciente, destacando sobre ellas la ELCB [LCD+09] debido a que se implementarán algoritmos para su cálculo automático.

El apartado técnico por su parte, lleva a cabo una revisión de técnicas y tecnologías utilizadas en investigaciones que implican un desarrollo de algoritmos de

PDI. Se comenzará describiendo algunas de las diferentes herramientas de desarrollo disponibles, exponiendo sus ventajas e inconvenientes. De forma posterior, se detallarán los principales modelos de color existentes para el procesamiento de imagen, realizando una comparativa entre ellos. Después, se exponen las técnicas de restauración de imagen más relevantes para la mejora de los problemas derivados de la captura de imágenes colonoscópicas, teniendo en cuenta también técnicas clásicas. Más adelante, se describen los algoritmos de detección de bordes y segmentación más utilizados en la literatura. Por último, se exponen los métodos más relevantes para la evaluación de la calidad de ejecución de la colonoscopia y la detección automática de pólipos, haciendo referencia a las publicaciones más destacadas.

2.1 Antecedentes médicos

Este apartado realiza una descripción del aparato digestivo, haciendo especial énfasis en el colon. Se describirán las principales funciones de éste, así como su anatomía e histología. A su vez, se explicará la problemática que suponen los pólipos colorrectales, exponiéndose las diferentes pruebas diagnósticas existentes y los métodos para su clasificación.

2.1.1 Descripción del aparato digestivo

El aparato digestivo está compuesto por los órganos encargados del proceso de digestión, es decir, de la absorción de los alimentos que puedan ser utilizados por las células del organismo. El procedimiento que realiza se resume en cuatro tareas: transporte de alimentos, secreción, absorción y excreción. Sus componentes son los siguientes:

- Boca: es el orificio de entrada al aparato digestivo y está compuesta por dientes, lengua y glándulas salivales.
- Faringe: es una estructura en forma de tubo situada en el cuello y revestida por una membrana mucosa que conecta la boca con la laringe.
- Esófago: es un conducto muscular que conecta la faringe con el estómago.

- Estómago: es un órgano músculo-membranoso situado bajo el diafragma, a la izquierda del hígado y que se comunica con el esófago e intestino delgado. Su función es la de almacenar y procesar los alimentos y nutrientes que serán consumidos.

- Intestino delgado: es el componente del aparato digestivo que comunica el estómago con el intestino grueso. Se compone de duodeno, yeyuno e íleon. Tiene una longitud de entre 5 y 7 m encargándose de la absorción de nutrientes.

- Intestino grueso o colon: es un tubo muscular con una longitud aproximada de 1.5 m que se une con el intestino delgado mediante la válvula ileocecal. Su funcionalidad es la absorción de agua y nutrientes de los alimentos y el almacenamiento de las heces.

- Hígado: es la mayor estructura glandular del organismo. Se localiza bajo el diafragma, en el lado derecho. Sus funciones son las siguientes: síntesis de proteínas plasmáticas, función desintoxicante, almacenaje de vitaminas y glucógeno, además de realizar la secreción de bilis.

- Páncreas: es un órgano con forma cónica que se encarga de segregar enzimas digestivas que pasan al intestino delgado. Asimismo produce hormonas tales como la insulina, glucagón, polipéptidos pancreáticos y somatostatina que pasan a la sangre.

Todos los órganos del sistema digestivo pueden verse en la figura 2.1.

2.1.2 **Funciones del colon**

El colon almacena los productos de desecho producidos por el sistema digestivo, reabsorbiendo y manteniendo el balance de agua en el cuerpo. Es el lugar de crecimiento de bacterias y otros microorganismos beneficiosos que ayudan a fermentar el material no digerido, absorber alimentos y sintetizar nutrientes vitales como el ácido fólico. Estos ayudan a controlar el crecimiento de bacterias dañinas y mantener el equilibrio del pH en el cuerpo. Electrolitos vitales y algunas vitaminas, como

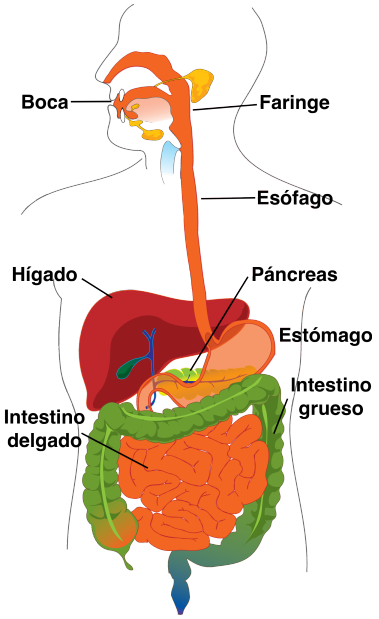


Figura 2.1: Órganos que componen el sistema digestivo. Fuente: goo.gl/aNL44q

por ejemplo las B y K que se requieren para la coagulación de la sangre se absorben en esta parte del intestino grueso.

La función más importante del colon es la expulsión de residuos tóxicos en forma de heces a través del recto. Esto se realiza mediante la contracción en forma de onda de sus músculos que hacen pasar las heces por el recto. De forma general, las heces son líquidas cuando entran en la primera zona del colon y a medida que el movimiento de los residuos de material líquido pasa a través de este órgano, el exceso de agua se absorbe y se convierten en semisólidas. En su parte descendente, el material de desecho se almacena hasta que es expulsado por el recto.

Cuando las funciones normales de este órgano se rompen pueden experimentarse diversos problemas de salud, de forma principal debidos a la acumulación de los residuos tóxicos y el deterioro de la absorción de algunos nutrientes vitales.

2.1.3 Anatomía del colon

El colon se divide en diferentes zonas en lo que a anatomía se refiere. A continuación se muestra en la figura 2.2 dicha partición, llevándose a cabo una descripción de cada uno de los elementos que lo componen.

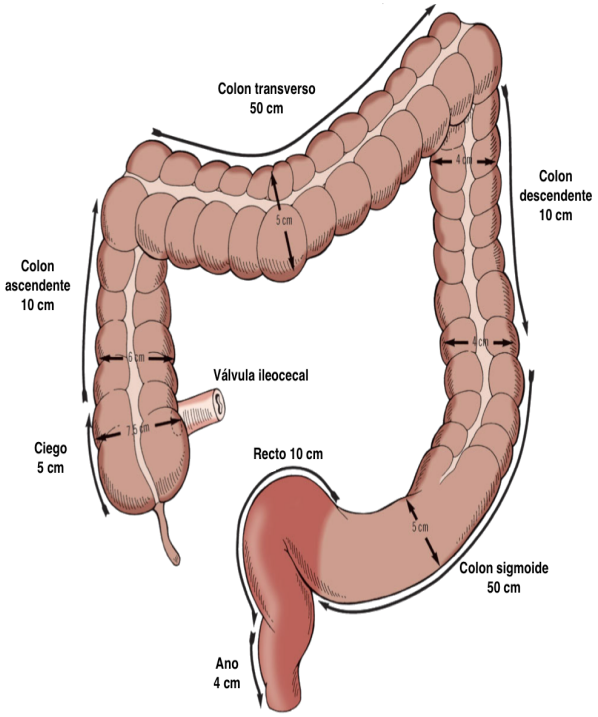


Figura 2.2: Anatomía del colon. Fuente:goo.gl/MCF6aS

- Válvula ileocecal: es un anillo muscular que regula el paso de materia fecal desde el intestino delgado al grueso. Está situada junto al ciego, a la altura de la ingle derecha. Su importancia estriba en la capacidad de regulación gradual del paso de materia fecal entre el intestino delgado y grueso, en los cuales existen diferentes tipos de bacterias. Es por ello necesario contar con mecanismos que mantengan un equilibrio entre las floras intestinales de ambos órganos.

- Ciego: es la primera porción del intestino grueso y se encuentra situado junto a la válvula ileocecal. Su función es retrasar el progreso del contenido intestinal hacia el intestino grueso. Además realiza parte del proceso de digestión mediante las numerosas bacterias que posee, las cuales contribuyen a la reducción de sustancias de difícil absorción por otros órganos del aparato digestivo.

- Apéndice vermiforme: es un pequeño divertículo tubular hueco que se lo-

caliza en el ciego y que cuenta con un fondo de saco sin salida. Tiene una longitud de entre 5 a 10 cm y un diámetro de unos 0.8 cm. Cuenta con un pliegue mucoso para impedir que el contenido fecal penetre en su interior. Asimismo, cuenta con formaciones linfoides que crean un sistema de defensa contra infecciones.

- Colon ascendente: es la continuación del ciego, por lo general tiene un diámetro menor que éste y cuenta con una longitud de 10 a 15 cm. Sube desde su unión con el ciego hasta la superficie inferior del lóbulo derecho del hígado, a la derecha de la vesícula biliar en donde se curva hacia la izquierda formando la flexura cólica derecha y uniéndose con el colon transverso.

- Colon transverso: es el segmento más grande y móvil del intestino grueso, con una longitud que va desde los 30 a 60 cm. Pasa por debajo de la convexidad, desde el hipocondrio derecho, cruzando el abdomen hasta más allá del epigastrio al hipocondrio contralateral. Se curva por debajo de la porción inferior del bazo formando la flexura cólica izquierda.

- Colon descendente: continúa del colon transverso hacia abajo por el lado izquierdo del abdomen, seguido por el colon sigmoide a la altura de la pelvis. Tiene una longitud de 25 a 30 cm y es la parte del intestino grueso donde se compactan las heces.

- Sigma: tiene forma de "S" y está situado entre el colon descendente y el recto. Tiene una longitud de entre 25 y 40 cm, siendo su principal función el acumular y canalizar los desechos generados en el proceso de digestión hacia el ano.

- Recto: es el último tramo del tubo digestivo situado tras el colon sigmoide. Su función es recibir los materiales de desecho que quedan tras el proceso de digestión de los alimentos. Tiene una longitud aproximada de 15 cm y a partir de él las heces salen del cuerpo por el ano.

- Conducto anal: es el orificio que se encuentra en el extremo terminal del tubo digestivo. Está constituido por el músculo esfínter voluntario y está cubierto

de mucosa. Se trata de la abertura por la que los materiales de desecho salen del cuerpo.

2.1.4 Histología del colon

El colon tiene una composición histológica de cuatro capas: mucosa, submucosa, muscular y serosa. A continuación se realiza una descripción de cada una de ellas, mostrándose su representación gráfica en la figura 2.3.

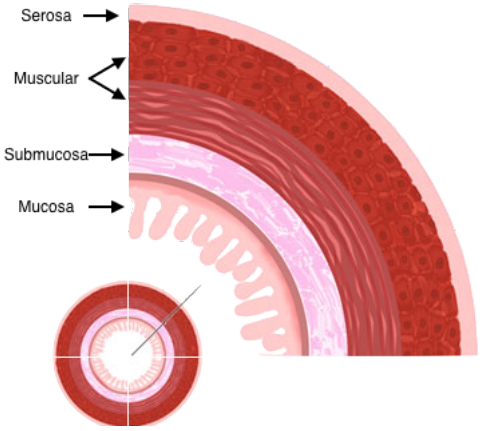


Figura 2.3: Estructura histológica del colon. Fuente: goo.gl/4BUrzF

- Mucosa: está formada por epitelio y tejido conjuntivo laxo subyacente que reviste las paredes internas de ciertos órganos, en el caso que nos lleva, el colon. Suele estar asociada a glándulas secretoras de moco que realizan funciones de protección, secreción y absorción, albergando sistemas inmunológicos desarrollados y especializados. Esta capa se compone de:

  - Epitelial: realiza labores de secreción y absorción revistiendo el interior del intestino grueso.
  - Lámina propia: es tejido conectivo areolar que contiene numerosos vasos sanguíneos y linfáticos por los cuales se absorben los nutrientes. Ésta sirve de unión entre las capas epitelial y muscular de la mucosa.

  - Muscular de la mucosa: se trata de una delgada capa de músculos lisos cuya función es que la mucosa del intestino grueso presente numerosos y pequeños pliegues que incrementan el área de superficie para la digestión y absorción.

- Submucosa: es la capa de tejido que se sitúa sobre la mucosa. En el tubo digestivo ocupa el espesor de la pared entre las capas muscular de la mucosa y mucosa propia.

- Muscular: es la responsable de las principales fuerzas propulsivas de la pared intestinal. Se encuentra situada entre la submucosa y la serosa.

- Serosa: tapiza las cavidades corporales y recubre los órganos que se encuentran en ella, además de secretar un fluido acuoso que reduce la fricción y actúa de lubricante en el roce entre los distintos elementos de esa cavidad. En el caso del aparato digestivo esta capa recibe el nombre de peritoneo que envuelve gran parte de los órganos digestivos, incluyendo el intestino grueso. Se encuentra situada sobre la capa muscular.

2.1.5 Pólipos en el colon

Los pólipos colorrectales son crecimientos anormales de tejido que surgen en la mucosa del intestino. Se trata de uno de los problemas más comunes que afectan a colon y recto, ya que los presentan entre un 15 y un 20 % de la población adulta. A pesar de que la mayoría de estos pólipos son benignos, se ha demostrado su relación con el CCR, al cual se llega mediante la secuencia adenoma-carcinoma [DM77].

La mayoría de los carcinomas del intestino grueso se desarrollan a partir de un adenoma mediante un proceso que tiene una duración de alrededor de 10 años. A pesar de que sólo un pequeño porcentaje de adenomas se convierten en carcinoma [JM51], es recomendable extirpar todos los pólipos detectados, ya que no existe un método infalible para predecir su evolución. La gran mayoría de los pólipos pueden ser extraídos cortándolos con un lazo de alambre electrometálico que se pasa a través del instrumento de exploración que se esté utilizando.

A continuación se detallarán los criterios más utilizados a la hora de clasificar los pólipos en función de sus características.

2.1.6 Métodos de clasificación de pólipos colorrectales

Este apartado aborda los métodos más importantes de clasificación de pólipos colorrectales. Cada uno de ellos está basado en diferentes características, como pueden ser la forma o estructura interna.

2.1.6.1 Clasificación histológica

La clasificación histológica se basa en el estudio de los tejidos orgánicos, es decir, su estructura microscópica, desarrollo y funciones. En el caso de los pólipos colorrectales, estos pueden ser clasificados en neoplásicos y no neoplásicos, componiéndose cada uno de ellos de diferentes subtipos.

Pólipos neoplásicos: los pólipos neoplásicos se dividen en adenomas y pólipos aserrados. Los adenomas por su parte se dividen en tubulares, vellosos y tubulovellosos. Los pólipos aserrados en cambio se dividen en hiperplásicos, adenomas sésiles aserrados, adenomas aserrados y pólipos mixtos aserrados. A continuación se describen estos tipos:

- Adenomas: son neoplasias de las mucosas intestinales con potencial maligno. En la población occidental tienen una prevalencia de un 40 % en series endoscópicas y de un 25 % en series autópsicas. La secuencia adenoma-carcinoma está relacionada de forma directa con este tipo de pólipos, ya que se estima que el 95 % de los adenocarcinomas de colon proceden de un adenoma. La Organización Mundial de la Salud (OMS) [OMS] clasifica los adenomas en tubulares, tubovellosos y vellosos. Todos estos tipos tienen algún grado de displasia, bien sea de alto o bajo grado. En el caso del carcinoma, se corresponde con la displasia de alto grado, en el que los focos de neoplasia no superan la muscularis mucosa y por lo tanto no pueden diseminarse, mientras que los pólipos malignos representan un adenoma con áreas de transformación carcinomatosa que se extienden a la submucosa y tienen capacidad de diseminación. A continuación se realiza una breve descripción de cada uno de los tipos de adenomas:

  - Adenomas tubulares: tienen una estructura similar a un tubo con un 75 % del epitelio dispuesto de forma tubular. La mayoría de estos pólipos resultan no ser cancerosos. Se cree que sólo el 5 % de ellos se convierte en CCR, pero el riesgo va incrementándose con el transcurso del tiempo.
  - Adenomas vellosos: tienen una apariencia aterciopelada con varias proyecciones similares a dedos llamadas vellosidades del epitelio. De forma general están situados en el recto, siendo de mayor tamaño y riesgo para la salud. Se estima que en torno al 40 % de este tipo de pólipos se convierte en CCR.
  - Adenomas tubulovellosos: comparten características con los dos tipos anteriores suponiendo un riesgo de convertirse en CCR del 20 %.

- Pólipos aserrados: están caracterizados por estar compuestos de células epiteliales de aspecto aserrado o dentado. Es importante la identificación de este tipo de pólipos por el hecho de que representan un 10-20 % de todos los cánceres colorrectales y el 30 % de los cánceres de intervalo. Los pólipos aserrados se pueden clasificar de la siguiente forma:

  - Pólipos hiperplásicos: su prevalencia oscila entre el 5 y 11 % en estudios autópsicos y del 30 al 70 % en revisiones endoscópicas. Su tamaño varía entre 2 y 5 mm, distribuyéndose por el recto-sigmoide. No suelen tener potencial maligno, aunque estudios recientes han descubierto que pueden ser precancerosos si crecen en el lado derecho o colon ascendente.
  - Adenoma sésil aserrado: tienen una arquitectura aberrante, proliferación atípica, epitelio hipermucoso y predilección por el colon proximal.
  - Adenomas aserrados: muestran características histológicas similares a los adenomas y endoscópicas similares a los pólipos hiperplásicos.
  - Pólipos mixtos aserrados: presentan características de pólipos hiperplásicos pero debido a su atipia nuclear se los considera adenomas. Presentan con frecuencia focos de displasia y carcinoma.

Pólipos no neoplásicos: son lesiones mucosas o submucosas de carácter benigno que tienen componentes histológicos que en la mayoría de los casos existen en la estructura del colon. Hay diferentes tipos de pólipos no neoplásicos que se describen a continuación:

- Pólipos hamartomatosos: están formados por componentes normales de la pared del intestino pero con una arquitectura irregular. En cuanto a su estructura histológica están formados por una matriz de lámina propia y glándulas quísticas. En cuanto a sus efectos, pueden provocar sangrado y prolapso rectal.

- Pólipos agregados linfoides: involucran o reemplazan a las glándulas gástricas propias, las cuales han sido diferenciadas de folículos linfoides.

- Pólipos inflamatorios: surgen como complicación de la enfermedad inflamatoria intestinal crónica (colitis ulcerosa y enfermedad de Crohn) con afectación del colon. Son inocuos aunque a veces se pueden confundir con los pólipos adenomatosos.

A modo de resumen se muestra la tabla 2.1 con la clasificación histológica.

Tabla 2.1: Clasificación histológica de los pólipos.

Tipo	**Categoría**	**Subcategoría**
Neoplásicos	Adenomas	Tubulares
		Vellosos
		Tubovellosos
	Aserrados	Hiperplásicos
		Sésiles aserrados
		Adenomas aserrados
		Mixtos aserrados
No neoplásicos	Hamartomatosos	
	Agregados linfoides	
	Inflamatorios	

2.1.6.2 Clasificación de París

La clasificación de París [IKK+03] se basa en la apariencia endoscópica de la lesión. Desde el punto de vista morfológico se ha consolidado como la nomenclatura estándar para la descripción y tipificación de neoplasias superficiales (tipo 0). La figura 2.4 presenta las variantes de las lesiones neoplásicas superficiales de tipo 0 descritas por la clasificación de París.

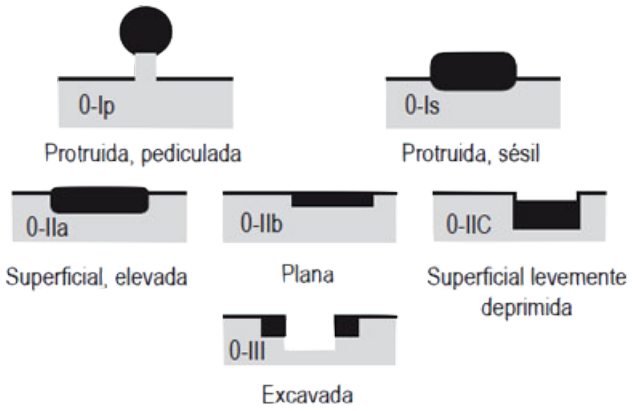


Figura 2.4: Clasificación de lesiones de París. Fuente: goo.gl/cZc58T

Proporciona una descripción endoscópica detallada de las lesiones superficiales de esófago, estómago y colon. De forma macroscópica las lesiones superficiales pueden ser divididas en tres grupos según indica la tabla 2.2.

Tabla 2.2: Clasificación macroscópica de los pólipos.

Protruidas	**Planas**	**Excavadas**
Pediculado (0-Ib)	Planas elevadas (0-IIa)	Úlcera o lesión excavada (0-III)
Sésil (0-Is)	Totalmente planas (0-IIb)	
	Excavadas (0-IIc)	

Esta clasificación reconoce que pueden presentarse patrones mixtos con elevación y depresión. Estos son clasificados en dos grupos:

- **Lesiones (0-IIc + 0-IIa):** la mayor parte de la superficie es deprimida y la elevación sólo está presente en la periferia.

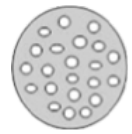
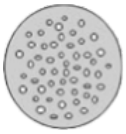
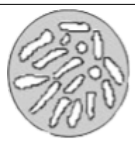
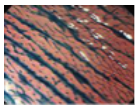
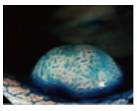
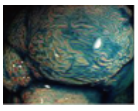
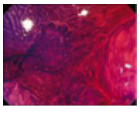
- **Lesiones (0-IIa + 0-IIc):** existe una depresión central en una lesión elevada.

Por otra parte, los patrones mixtos de combinación para las lesiones excavadas y deprimidas son denominadas 0-III + 0-IIc o 0-IIc + III.

2.1.6.3 Clasificación Kudo

La clasificación de Kudo (véase tabla 2.3) está basada en el estudio de los patrones de cripta de la mucosa mediante endoscopios de magnificación y técnicas de cromoendoscopia [KHN+94]. Permite una mayor precisión diagnóstica dada su buena correlación con los estudios histopatológicos. En primer lugar, permite diferenciar la mucosa normal (patrón I) o con cambios hiperplásicos (patrón II) de las lesiones de las mucosas con cambios displásicos (patrones III, IV y V). Además proporciona información sobre el riesgo del carcinoma con infiltración submucosa, presente en la mayoría de las lesiones que muestran un patrón VII no estructural.

Tabla 2.3: Clasificación de pólipos de Kudo.

I	II	III	IV	V	VI	VII
						
						
Mucosa normal	Pólipo hiperplásico	Adenoma tubular, displasia alto grado	Adenoma tubular	Adenoma velloso	Irregular	No estructural Vn

Cabe reseñar que esta clasificación está basada en el empleo de endoscopios de magnificación óptica y que no se ha estudiado en profundidad su utilidad y exactitud diagnóstica empleando visión convencional o magnificación electrónica. Esto es de extremada importancia en el momento de analizar aquellos patrones más difíciles de caracterizar, es decir, los invasivos.

2.1.6.4 Clasificación de Viena

La clasificación de Viena para neoplasia epitelial gastrointestinal [SRK+00] ha logrado un consenso mayoritario para clasificar las neoplasias a lo largo de todo el

trayecto gastrointestinal, o sea, esófago, estómago y colon. La categorización que propone se muestra en la tabla 2.4.

Tabla 2.4: Clasificación de lesiones de Viena.

Categoría	Diagnóstico
1	Negativo para neoplasia.
2	Cambios indefinidos para neoplasia.
3	Neoplasia en mucosa de bajo grado. Adenoma/displasia de bajo grado.
4	Neoplasia en mucosa de alto grado.
4.1	Adenoma/displasia de alto grado.
4.2	Carcinoma no invasivo.
4.3	Sospecha de carcinoma invasivo.
4.4	Carcinoma intramucoso.
5	Carcinoma con invasión de submucosa.

Es importante comentar que la presente clasificación tiene su base en el hallazgo de la severidad de la arquitectura del tejido y del aspecto citológico, así como de la profundidad de la lesión.

En la actualidad las Guías Europeas de Calidad en el Cribado y Diagnóstico Colorrectal (GECCDC) [SPvK$^+$10] proponen una modificación de esta clasificación para las lesiones colónicas. En ella se incluye el carcinoma no invasivo en la misma categoría que la displasia de alto grado. Esta adaptación se muestra en la tabla 2.5.

Para finalizar este apartado se presenta la tabla 2.6 que realiza un breve resumen de las diferentes clasificaciones descritas.

2.1.7 Pruebas diagnósticas

En la actualidad existe una gran variedad de pruebas diagnósticas que permiten evaluar el estado de salud del paciente. Cada una de ellas está basada en diferentes conceptos y tiene sus ventajas e inconvenientes. A continuación se describen las más utilizadas en la evaluación del CCR.

Tabla 2.5: Adaptación de la clasificación de Viena según las GECCDC.

Adaptación	Clasificación de Viena
No neoplasia	Categoría de Viena 1 (negativo para neoplasia).
	Categoría de Viena 3.
Neoplasia mucosa bajo grado	Otra terminología: displasia moderada.
	OMS: neoplasia intraepitelial de bajo grado.
Neoplasia mucosa alto grado	Categoría de Viena 4.1-4.4.
	Otra terminología: displasia severa.
Carcinoma invasivo	Carcinoma confinado a la submucosa.

Tabla 2.6: Comparativa de los métodos para la clasificación de pólipos.

	París	**Kudo**	**Viena**
Año	2002	1994	2000
Clasificación	Morfológica.	Patrones de cripta.	Neoplasia epitelial.
Ventajas	Más extendida. Unificación de Kudo y Viena.	Información del riesgo.	Adopción mayoritaria en la clasificación de neoplasias.
Inconvenientes		No unificada.	No unificada.

2.1.7.1 Colonoscopia

La colonoscopia es el método de referencia para el diagnóstico, tratamiento de enfermedades colónicas y de forma esencial, para el cribado y vigilancia del cribado colorrectal. Se trata de una exploración que permite la visualización del intestino grueso al completo, además de permitir la extracción de biopsias y extirpación de lesiones.

Se ha demostrado que la realización de este estudio disminuye la mortalidad por cáncer de colon. Previo a su procedimiento es necesaria una fase de preparación del paciente, de forma que no queden residuos sólidos en el colon. Para su ejecución se introduce un colonoscopio por el ano (véase figura 2.5). Éste es un tubo flexible con una cámara en el extremo. En algunos casos se utiliza sedación para realizar el estudio sin molestias. Es el mejor estudio para la detección de CCR, ya que permite su localización y en la mayoría de las ocasiones la inmediata extirpación.

A pesar de su correcta realización no está exenta de sufrir complicaciones co-



Figura 2.5: Colonoscopio. Fuente: goo.gl/6qtSW9

mo la perforación del colon o hemorragia, aunque se da en el 0.1 % de las exploraciones realizadas. Tras realizar una descripción de la colonoscopia y teniendo en cuenta que es la prueba diagnóstica a utilizar en la investigación que se propone, es necesaria la descripción de los elementos presentes en ella. Esto se aborda a continuación.

Identificación de los elementos de las imágenes colonoscópicas

Las imágenes colonoscópicas están formadas por diferentes elementos que es necesario definir. A continuación se realiza una breve descripción de cada uno de ellos mostrándose la figura 2.6 para facilitar su identificación.

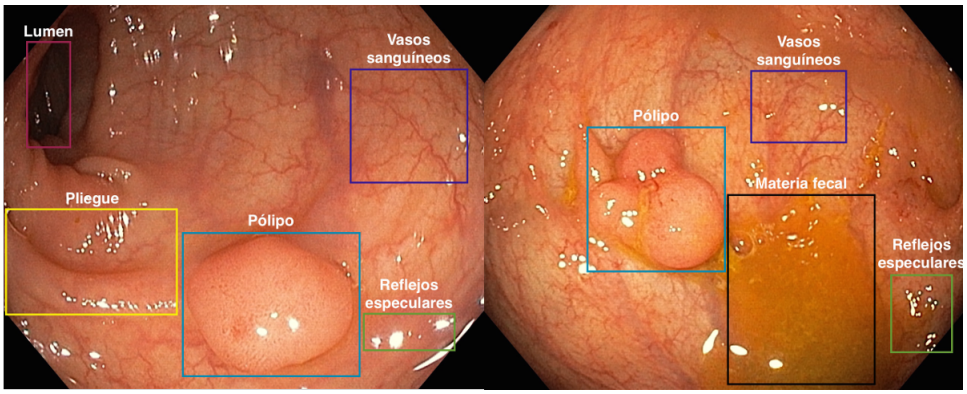


Figura 2.6: Elementos de las imágenes colonoscópicas.

- Lumen: en el contexto de la biología, luz o lumen es definido como el interior de una estructura tubular, el colon en el caso que nos ocupa.

- Pliegues haustrales: representan pliegues de la mucosa del colon. Se forman por la contracción circunferencial de la capa muscular interna.
- Vasos sanguíneos: son parte del sistema circulatorio y pueden ser detectados por su forma ramificada.
- Pólipos: son crecimientos anormales de tejido en la mucosa del colon, aunque pueden aparecer en más lugares. Si se unen con la pared del colon mediante un tallo se les denomina pediculados, en caso contrario, se les considera sésiles. En el caso de no ser tratados pueden derivar en CCR.
- Materia fecal: son desechos del sistema digestivo que son expulsados por el ano en el proceso de defecación.
- Reflejos especulares: son puntos brillantes de luz que aparecen debido a la reflexión de ésta sobre el colon.

2.1.7.2 **Colonoscopia virtual**

La colonoscopia virtual (véase figura 2.7), también llamada colonografía por tomografía computarizada, usa un equipo especial de rayos X para producir imágenes del colon y recto. Una computadora ensambla las imágenes consiguiendo una representación detallada que puede mostrar pólipos y otras anomalías. Es una prueba menos invasiva que la colonoscopia regular, ya que no requiere la utilización de sedantes. Al igual que en otros tipos de pruebas diagnósticas es necesaria la completa limpieza del colon para su ejecución. Durante el proceso se bombea aire dentro del colon para expandirlo y así ver mejor su revestimiento interior.

Tiene una precisión similar a la colonoscopia regular, suponiendo un menor riesgo de complicaciones que ésta. Su principal inconveniente es que en caso de detectarse pólipos o tumores se requiere de la realización de una colonoscopia regular o intervención quirúrgica para poder extirparlos.

2.1.7.3 **Sigmoidoscopia**

La sigmoidoscopia trata de examinar el recto y colon sigmoide mediante el uso de un tubo iluminado y flexible denominado sigmoidoscopio. Este dispositivo dispone

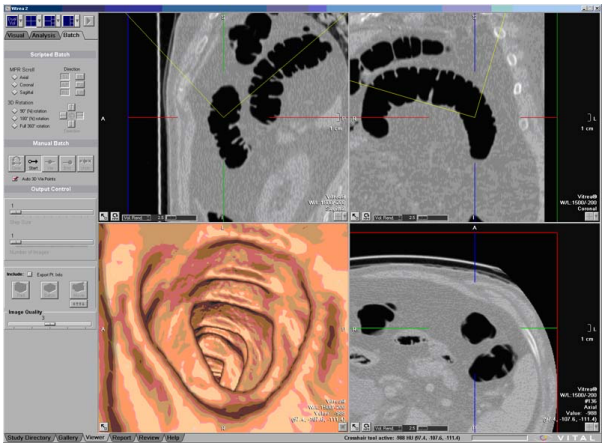


Figura 2.7: Colonoscopia virtual. Fuente: goo.gl/S65MZd

de una lente para observar y una herramienta para extraer el tejido necesario. El sigmoidoscopio es introducido a través del ano dentro del recto y colon sigmoide, al mismo tiempo que se bombea aire en el colon para expandirlo, de forma que el médico pueda observar el interior con claridad. Es necesario que el colon inferior esté exento de materia fecal antes de la prueba, pero la preparación del paciente no es tan rigurosa como en el caso de la colonoscopia. Para esta prueba, en general, no es necesario que la persona reciba sedantes. Es una prueba similar a la colonoscopia con la diferencia de que la sigmoidoscopia sólo examina el tercio inferior del colon.

2.1.7.4 **Enema de bario de doble contraste**

El enema de bario de doble contraste (véase figura 2.8) se realiza mediante la toma de imágenes de rayos X de todo el colon y recto después de que el paciente reciba un enema con una solución de bario.

El bario es utilizado para delinear el colon y recto en las imágenes. Esta prueba se realiza en muy pocas ocasiones debido a que es menos sensible que la colonoscopia en la detección de cánceres y pólipos pequeños, por lo que es la alternativa utilizada cuando la persona a tratar no puede ser sometida a una colonoscopia regular por tener un riesgo especial de sufrir complicaciones. Como inconvenientes se pueden destacar que, al igual que en la colonoscopia virtual, en caso de detectarse lesiones no se tiene la posibilidad de extirparlas, además de que el sujeto recibe radiación en la ejecución de la prueba.



Figura 2.8: Enema de bario de doble contraste. Fuente: goo.gl/fu73XA

2.1.7.5 **Prueba de sangre oculta en las heces**

Tanto los pólipos como el CCR pueden sangrar. Dada esta particularidad, el presente método diagnóstico se basa en la búsqueda de pequeñas cantidades de sangre oculta en la materia fecal. A día de hoy existen dos tipos de pruebas de sangre oculta en la materia fecal para la detección de CCR aprobadas por la Administración de Alimentos y Medicamentos (FDA) [FDA], éstas son las siguientes:

- Prueba con guayacol: utiliza un compuesto químico para detectar el hemo, un componente de la hemoglobina de la sangre.
- Prueba inmunoquímica: utiliza anticuerpos para detectar la hemoglobina.

Ambos tipos de pruebas requieren del seguimiento de una dieta específica para obtener unos resultados con garantías. Al igual que ocurre con el enema de bario de doble contraste y la colonoscopia virtual, sólo son útiles para la detección de CCR, teniendo que recurrir a otras soluciones para su extirpación.

A continuación la tabla 2.7 realiza un resumen de las diferentes pruebas diagnósticas descritas, indicando su método de diagnóstico, ventajas e inconvenientes.

2.1.8 **Evaluación de la calidad de ejecución de la colonoscopia**

El rápido y progresivo aumento de los procedimientos realizados en los últimos años, junto con los riesgos inherentes que ello supone, obligan a la definición de criterios de evaluación para su indicación y realización. Los criterios deben estandarizarse para todos los endoscopistas y unidades de endoscopia. Además, sería

Tabla 2.7: Resumen de las pruebas diagnósticas de cáncer de colon.

	Método exploración	Ventajas	Inconvenientes
Colonoscopia	Exploración del colon mediante colonoscopio.	Exploración completa del colon. Extirpación de lesiones.	Riesgo de perforación y sangrado.
Colonoscopia virtual	Exploración del colon mediante rayos X.	Exploración completa del colon.	Radiación del paciente. Imposibilidad de extirpar lesiones.
Sigmoidoscopia	Exploración del recto y colon sigmoide mediante sigmoidoscopio.	Extirpación de lesiones.	No explora el colon completo. Riesgo de perforación y sangrado.
Enema bario doble contraste	Exploración del colon mediante rayos X y contraste.	Exploración completa del colon.	Radiación del paciente. Imposibilidad de extirpar lesiones.
Sangre oculta en heces	Exploración de restos de sangre en las heces.	Bajo riesgo.	Imposibilidad de extirpar lesiones.

adecuada la continua evaluación de los actores y áreas en las que se realizan estas exploraciones.

En los siguientes subapartados se realiza una descripción tanto de los principales indicadores para la evaluación de la calidad de las exploraciones, como de las principales escalas de valoración existentes.

2.1.8.1 Indicadores de calidad de la colonoscopia

La American Society of Gastrointestinal Endoscopy (ASGE) [ASG] y la European Society of Gastrointestinal Endoscopy (ESGE) [ESG] han propuesto diversas variables para la determinación de la calidad de ejecución de la colonoscopia [RHR+12]. A continuación se describen las más relevantes:

- Tiempo de inserción: es el tiempo que transcurre desde la introducción del colonoscopio por el ano hasta la llegada al ciego. De forma general este proceso tiene una duración de entre 4 y 6 minutos.

- Tiempo de extracción: es el tiempo que transcurre en la retirada del colonoscopio, es decir, su extracción desde el ciego al exterior del paciente. En el 90 % de los casos su duración es mayor a 6 minutos. Hay que tener en cuenta que la duración de este proceso es muy variable ya que puede ser necesaria

la extirpación de lesiones, limpieza del colon, etc. El tiempo empleado para realizar procedimientos no diagnósticos como biopsias o polipectomías debe sustraerse del tiempo total. La mayoría de los endoscopistas realizan una observación detallada de la mucosa colónica durante la retirada, por lo que se considera la fase más importante para la detección de adenomas.

- Tiempo de extracción enfocada: es importante determinar la calidad de visualización del colon en la fase de retirada. Esta métrica calcula el ratio entre imágenes bien enfocadas y desenfocadas, de forma que se determine la calidad de imagen obtenida por el especialista.

- Preparación del paciente: se trata de la evaluación de la limpieza del colon del paciente. Para ello se han definido diferentes escalas que serán descritas en el apartado 2.1.8.2 ≪Escalas para la evaluación de la preparación del colon≫.

- Tasa de detección de adenomas: es el indicador de calidad en la colonoscopia de cribado más importante. Se encuentra relacionado de forma directa con la aparición del cáncer de intervalo. Se trata de la proporción de pacientes sometidos a colonoscopia en los que se ha detectado como mínimo un adenoma. Se establecen tasas mayores al 25 y 15 % para hombres y mujeres de forma respectiva.

- Tasa de intubación cecal (TIC): se trata de la tasa de colonoscopias en las que el endoscopio llega hasta un punto proximal a la válvula ileocecal, lo que permite explorar el polo cecal incluida su pared medial. Su cálculo se realiza mediante la ecuación 2.1, excluyéndose del denominador las exploraciones incompletas por mala preparación, colitis grave o exploraciones con fines terapéuticos.

$$TIC = (\frac{colonoscopias\ con\ intubación\ cecal}{colonoscopias\ totales}) \times 100 \qquad (2.1)$$

- Número de movimientos de cámara: el especialista suele realizar movimientos con la cámara para inspeccionar con mayor grado de detalle zonas difíciles de explorar. Este es un indicador de una buena calidad de ejecución.

- Tasa de sangrado: todos los casos de hemorragia inmediata y tardía tras la polipectomía deben ser registrados. Para una buena calidad menos del 5 % de los casos de sangrado deben requerir una intervención quirúrgica.

- Tasa de perforación: los detalles de las perforaciones producidas hasta 2 semanas después de la endoscopia que complican los procedimientos de diagnóstico y que además requieren de reparación quirúrgica deben ser registrados. Es recomendable que menos del 0.1 % de las pruebas resulten en una perforación que requiera reparación quirúrgica.

- Tasa de reingresos no programados: es recomendable la recogida de detalles de los ingresos de pacientes en los 30 días posteriores a la colonoscopia.

- Marcado de zonas con cáncer o pólipos: se recomienda que los programas de cribado establezcan normas relativas al marcado de zonas en las que se han detectado pólipos o lesiones.

- Limpieza y desinfección: seguir las recomendaciones de desinfección de los fabricantes y estándares europeos y nacionales, ademas de realizar análisis microbiológicos de rutina a intervalos no superiores a tres meses.

- Planificar la extracción de pólipos grandes: la extirpación de los pólipos más grandes se aplazará a una sesión clínica dedicada a ello.

- Lesiones de intervalo significantes: se recomienda el monitoreo por parte de los programas de cribado del tamaño, aspecto, ubicación e histología de todos los pólipos mayores de 1 cm y cánceres que se encuentran entre los exámenes de detección, así como después de que el paciente ha sido dado de alta de un programa de cribado.

- Tasa de recuperación de pólipos: los programas de detección anticipan que todos los pólipos extirpados se recuperan para el análisis histológico. Se recomienda que al menos el 90 % de los pólipos extirpados deben ser recuperados para el análisis histológico.

- Sedación, analgesia y confort: se auditan las prácticas de sedación, incluyendo dosis medias utilizadas de la medicación junto con las puntuaciones de confort. Es recomendable que no más de un 1 % de los pacientes se convierta en hipóxico (saturación por debajo del 85 % durante más de 30 segundos) o que por otros motivos se requiera la administración de un agente de reversión.

- Experiencia del endoscopista: se tiene en cuenta los años de experiencia del especialista, además debe ser acordado un número mínimo de colonoscopias anuales.

- Aceptación del consentimiento: se trata de auditar el número de pacientes que rechazan la colonoscopia en el día del procedimiento o en mitad de la ejecución. Es recomendable que en menos del 5 % de los casos se retire el consentimiento el día del procedimiento y menos del 1 % durante el procedimiento.

2.1.8.2 **Escalas para la evaluación de la preparación del colon**

Es una necesidad hacer constar la calidad de preparación del colon en todas las colonoscopias realizadas. El criterio que se impone es alcanzar una preparación buena o muy buena en más del 95 % de las exploraciones [GHFH10][JHA+12] [MTE+09]. Los especialistas deben indicar en el informe de la endoscopia la calidad de la exploración basada en escalas de evaluación validadas.

Es considerada una buena o muy buena exploración aquella en la que se tiene la impresión de haber podido observar con precisión aceptable la existencia de pólipos de tamaño igual o mayor a 5 mm. Una exploración con mala preparación es uno de los mayores impedimentos para realizar una exploración adecuada, ya que reduce la capacidad de detección de pólipos, empeora la relación coste/eficacia y alarga el tiempo de exploración. En este sentido se han definido varias escalas que han sido validadas para la evaluación de la calidad de exploración: Aronchick [Aro04], Ottawa [RJ04] y Boston [LCD+09]. A continuación se hace una breve descripción de cada una de ellas.

Escala de limpieza del colon de Aronchick (ELCA)

La escala Aronchick es la más antigua y sencilla de las tres escalas de valoración de la limpieza del colon que se describirán. Se otorgan valoraciones de entre 1 y 5 puntos sobre la totalidad del colon de la siguiente forma:

- Excelente: se dará 1 punto cuando sea visible más del 95 % de la mucosa y existan mínimos restos líquidos.
- Buena: se darán 2 puntos cuando sea visible más del 90 % de la mucosa y existan restos líquidos de entre el 5 y 25 % del colon.
- Justa: se darán 3 puntos cuando se visualice menos del 90 % de la mucosa y existan restos líquidos o semisólidos que puedan ser aspirados o lavados.
- Mala: se darán 4 puntos cuando se visualice menos del 90 % de la mucosa y existan restos semisólidos que no puedan ser aspirados o lavados.
- Inadecuada: se darán 5 puntos cuando existan restos sólidos que impidan la exploración.

Una de las desventajas de esta escala es la gran variabilidad interobservador que sufre, ya que está basada en la interpretación subjetiva del especialista, además de no realizar una división en segmentos del colon.

Escala de limpieza del colon de Ottawa (ELCO)

La escala Ottawa fue desarrollada y validada con el fin de posibilitar la evaluación de la limpieza del colon por segmentos. La puntuación que se otorga está dentro del rango de 0 a 14 puntos. Los aspectos que se han tenido en cuenta son los siguientes: grado de limpieza por segmento del colon (colon izquierdo, colon transverso y colon derecho) y la cantidad de líquido en todo el colon. Las puntuaciones por segmento se dan en el rango de 0 a 4 puntos de la siguiente manera:

- Excelente: se darán 0 puntos cuando la mucosa esté visible en su totalidad y existan mínimos restos líquidos.

- Buena: se dará 1 punto cuando se tenga una buena visión de la mucosa y existan algunos restos líquidos que no sea necesario aspirar o lavar.
- Justa: se darán 2 puntos cuando se tenga una visión razonable de la mucosa y existan restos líquidos o semisólidos y no se necesite aspirar o lavar.
- Mala: se darán 3 puntos cuando se disponga de una escasa visión de la mucosa y existan restos semisólidos que precisen de aspiración o lavado.
- Inadecuada: se darán 4 puntos cuando los restos sólidos impidan la exploración.

Las valoraciones de la cantidad de líquido en el colon se dan de la siguiente forma:

- Escaso: se darán 0 puntos.
- Moderado: se dará 1 punto.
- Mucho: se darán 2 puntos.

Al igual que ocurre con la escala ELCA existe una gran variabilidad interobservador, ya que no existen herramientas que objetiven las mediciones, de forma que todas ellas quedan bajo la interpretación de los especialistas.

En cuanto al cálculo de la ELCO, los autores de [ARGF+12] proponen un método de evaluación de la limpieza del colon basándose en dicha escala. Pretenden estandarizar la medición de la calidad de preparación del colon del paciente mediante una detección de heces basada en el color. Para ello realizan el siguiente procedimiento:

1. Incrementar el contraste en el modelo de color *red, green, blue* (RGB): mediante el incremento del contraste en el modelo de color RGB (véase apartado 2.2.2.1 ≪Modelo RGB≫) se permite una mejor discriminación entre la pared del colon y la materia fecal.
2. Conversión al modelo de color *hue, saturation, value* (HSV) y separación de sus componentes: realizan una conversión al modelo de color HSV (véase apartado 2.2.2.3 ≪Modelo HSV≫), ya que es más eficiente y consistente que

RGB para la detección de color. Cada uno de sus componentes es evaluado por separado especificando para cada una de las componentes los rangos de valores en los que se encuentran los píxeles que contienen materia fecal. Esto es realizado de la siguiente forma: $H_{min} < H < H_{max}$, $S_{min} < S < S_{max}$ y $V_{min} < V < V_{max}$. Para realizar este proceso inspeccionan los histogramas de cada componente HSV, determinando los rangos de valores de la materia fecal.

3. Realizar un suavizado de la imagen: todos los objetos menores a un tamaño fijado con anterioridad son eliminados de la imagen para evitar la segmentación de elementos no relevantes y no saturar la imagen.

4. Calculo del porcentaje de píxeles de materia fecal: se realiza un cierre morfológico en la imagen y se calcula el ratio de píxeles negros (materia fecal) respecto al total de los píxeles.

5. Integración con la escala ELCO: una vez obtenido el porcentaje de píxeles que contienen heces en las imágenes realizan el cálculo automatizado de la escala ELCO.

Mediante este proceso han conseguido desarrollar un método automático de evaluación de la preparación del colon de los pacientes que se someterán a una colonoscopia, estandarizando el proceso y evitando la variabilidad interobservador.

Escala de limpieza del colon de Boston (ELCB)

La ELCB ha sido desarrollada por la sección de gastroenterología del Boston University Medical Center (BUMC) [BUM] con el ánimo de proporcionar un instrumento estandarizado para calificar la calidad de preparación del intestino durante una colonoscopia. Al igual que en la ELCO se dan puntuaciones a diferentes tramos del colon, siendo estos los siguientes: izquierdo (ciego y colon ascendente), transverso (incluyendo ángulo hepático y esplénico) y derecho (colon sigmoide, descendente y recto). Las puntuaciones son otorgadas de la siguiente forma:

- 0 puntos: segmento del colon mal preparado debido a la presencia de heces sólidas.

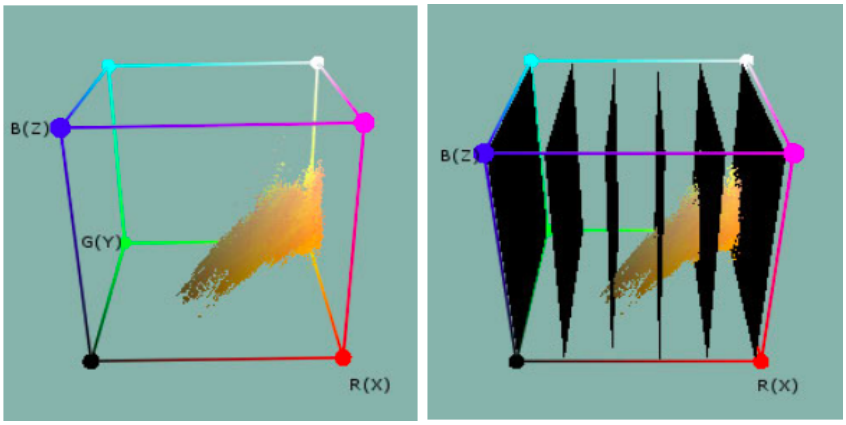
- 1 punto: áreas del segmento del colon no visualizadas debido a la presencia de contenido fecal líquido y semisólido.
- 2 puntos: segmento del colon con buena visibilidad de la mucosa y escaso contenido fecal líquido.
- 3 puntos: segmento del colon con excelente visualización y sin la presencia de restos líquidos.

La puntuación otorgada por el especialista dependerá de la cantidad de heces presente en el colon, además del tipo de las mismas. Esta es la principal particularidad que distingue a la ELCB del resto de escalas para la evaluación de la calidad de preparación del colon.

El trabajo [MOT+12] presenta un método automático para determinar el porcentaje de heces presente en las imágenes colonoscópicas y de esta manera calcular la ELCB. Para ello proponen un método basado en dos etapas: entrenamiento y detección.

Las imágenes digitales en color son modeladas en el espacio RGB, en el que cada componente se representa con 8 bits que van de 0 a 255, lo que genera un total de 256^3 colores posibles. Como primer paso realizan una proyección de los píxeles que contienen heces en un cubo de color RGB (véase figura 2.9). Hacen uso del hecho de que cada píxel de color tiene una ubicación única en el cubo de color RGB determinado por las coordenadas R, G y B. Para mayor comodidad, al modelo RGB se le asigna el sistema de coordenadas XYZ. Como segundo paso, colocan 256 planos en el cubo a lo largo del eje X, de manera que cada posición en el mismo tiene un plano paralelo al eje YZ. Se asigna un número entre 0 y 255 a cada plano y de esta forma cada uno de ellos puede comportarse como un clasificador bidimensional para detectar píxeles con materia fecal. A partir de este principio realizan el cálculo automatizado de la ELCB.

La principal problemática de esta investigación es la baja fidelidad con la que representa la ELCB. Esto es debido a que no realiza una clasificación de las heces detectadas en el colon, característica especificada en la propia escala. Sin una categorización de las heces no es posible realizar una estandarización fidedigna de la ELCB que es lo buscado en la tesis doctoral que se presenta.



(a) (b)

Figura 2.9: Proyección de los píxeles de materia fecal y creación de los planos clasificadores. a) Proyección de los píxeles en el cubo RGB. b) Creación de los planos clasificadores.

En la tabla 2.8 se realiza un resumen de las diferentes características de las escalas descritas.

Tabla 2.8: Comparativa de las escalas de evaluación de la calidad de preparación del colon. La fila "Principio" indica el tipo de evaluación, "Zonas" la zona a evaluar, "Total" el rango de puntuación total, "Zona" el rango de puntuación por zona y "Líquido" la puntuación asignada a la cantidad de líquido.

	ELCA	**ELCO**	**ELCB**
Principio	Limpieza del colon.	Limpieza del colon y cantidad de líquido	Limpieza del colon.
Zonas	Colon completo.	Colon izquierdo, derecho y transverso.	Colon izquierdo, derecho y transverso.
Total	[1-5]	[0-14]	[0-9]
Zona	-	[0-4]	[0-3]
Líquido	-	[0-2]	-

Problemas de las escalas de evaluación de limpieza del colon

Como se ha podido observar las diferentes escalas propuestas sufren de una gran variabilidad interobservador. Esto es debido a que los especialistas no disponen

de herramientas para realizar mediciones objetivas de los aspectos que tienen en cuenta las diferentes escalas, por lo que todo se hace en base a la interpretación del endoscopista. Por este motivo se hace necesario ofrecer herramientas de apoyo que permitan obtener mediciones cuantificables que estandaricen las valoraciones. En este sentido las publicaciones [ARGF+12] y [MOT+12] realizan una importante aportación quedando justificada la investigación propuesta.

2.2 Antecedentes técnicos

En este apartado se realizará una revisión del estado del arte a nivel técnico. Se describirán las tecnologías, técnicas y métodos más utilizados en la literatura para superar las dificultades de la problemática planteada.

El desarrollo de algoritmos para la evaluación de la calidad de la colonoscopia y detección automática de pólipos es una tarea compleja. Por un lado, la evaluación de la calidad de la preparación del colon requiere de la utilización de escalas basadas en la interpretación subjetiva de los especialistas, lo que incrementa la complejidad de los algoritmos desarrollados. Por otro lado, la detección automática de pólipos hace necesario superar las siguientes dificultades:

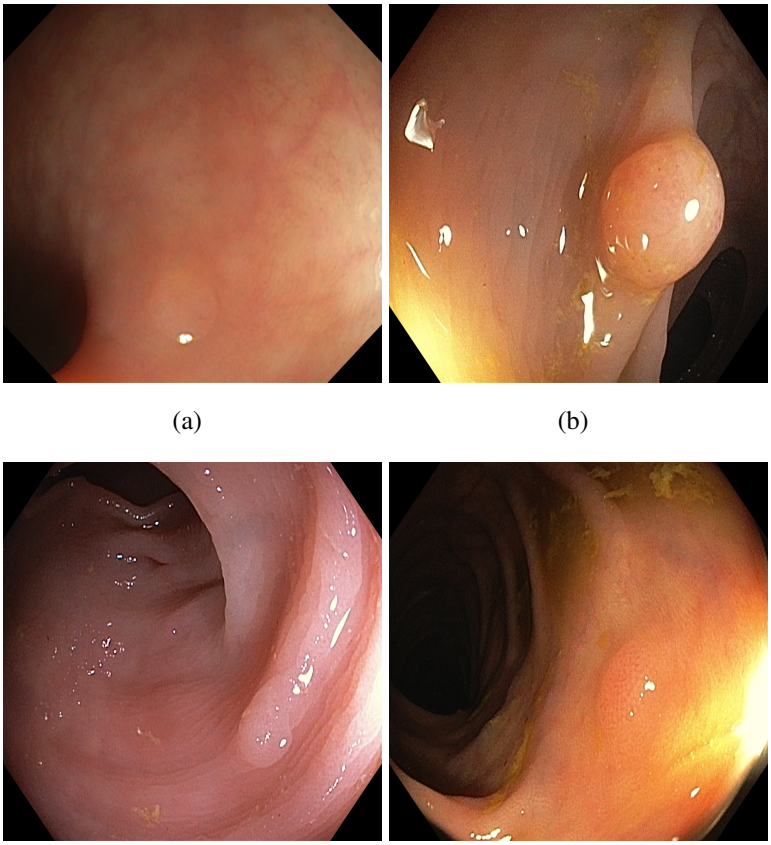
- Lugar de aparición no uniforme de los pólipos: el lugar de crecimiento de los pólipos en el colon es muy diverso, lo que genera mayores dificultades a la hora de desarrollar algoritmos de detección automática. En la figura 2.10 se puede apreciar el lugar de aparición no uniforme de los pólipos.

- Diversidad de forma: los pólipos pueden ser sésiles o pediculados lo que supone una dificultad añadida, ya que los algoritmos desarrollados deben ser capaces de detectar pólipos que no tienen una forma particular. La figura 2.10 muestra un ejemplo de pólipos con diferente forma.

- Efectos adversos en la adquisición: la adquisición de imágenes colonoscópicas se ve afectada por una serie de efectos que degradan la calidad de las mismas, dificultando el desarrollo de algoritmos para su análisis. Algunos ejemplos de estos efectos son: reflejos especulares, ruido, iluminación no homogénea etc. En el apartado 2.2.3.1 ≪Problemas en la captura de vídeos

e imágenes colonoscópicas» se realiza una descripción exhaustiva de ellos y de las técnicas más utilizadas en el estado del arte para su eliminación.

- Similitud de tejidos: en muchas ocasiones los tejidos interiores y exteriores a los pólipos tienen una gran similitud, esto hace que la dificultad de su detección sea mucho más elevada.



(a) (b)

(c) (d)

Figura 2.10: Apariencia y forma no uniforme de los pólipos. a) Pólipo diminuto. b) Pólipo pediculado. c) Pólipo en pliegue lateral. d) Pólipo plano.

2.2.1 Herramientas para el desarrollo de algoritmos de PDI

Dado que la tesis doctoral que se presenta consiste en la implementación de algoritmos de PDI que posibiliten la evaluación de la calidad de preparación del colon

de los pacientes y la detección de pólipos, es necesario contar con herramientas software para su desarrollo. En el mercado existen diferentes alternativas que han sido evaluadas con el fin de seleccionar las que más se ajustan a las necesidades. La elección ha sido basada en los siguientes parámetros:

- Conocimientos previos.
- Librerías de PDI disponibles.
- Eficiencia computacional.
- Capacidad de integración con diferentes tecnologías.

Las herramientas para el desarrollo de algoritmos de PDI evaluadas han sido las siguientes: Matlab, Scientific Python, OpenCV, ImageJ y WEKA.

2.2.1.1 **Matlab**

Matrix Laboratory (Matlab) [Mat] es una herramienta de software matemático que ofrece un entorno de desarrollo integrado con su propio lenguaje. Permite la realización de cálculos complejos de una forma más rápida que lenguajes como C, C++ o Java. Dispone de una gran variedad de librerías para el desarrollo de algoritmos de PDI, lo que facilita las labores de implementación. La representación de los datos es matricial de forma nativa, lo que agiliza la ejecución de algoritmos. Ofrece un entorno de desarrollo propio que permite la ejecución y depuración del código haciendo mucho más rápidos y sencillos los desarrollos.

Por otra parte, es muy utilizado por la comunidad científica, lo que permite la reutilización de código, así como dotar de una mayor aceptación a todos los trabajos derivados de la tesis doctoral desarrollada.

2.2.1.2 **Scientific Python**

Scientific Python [Sci] es una librería de código libre del lenguaje de programación Python. Estas librerías están orientadas al desarrollo de aplicaciones matemáticas y científicas. Más en concreto *Scientific Python* dispone de la librería *Python Imaging Library* que proporciona funcionalidades para el desarrollo de algoritmos de PDI.

El lenguaje de programación Python es cada vez más utilizado en el ámbito del procesamiento de señal debido a su sencillez y eficiencia.

2.2.1.3 OpenCV

OpenCV [Ope] es una *application programming interface* (API) para el desarrollo de algoritmos de visión artificial desarrollada por Intel. Su principal virtud es que provee un entorno de desarrollo intuitivo, además de eficiente. Esto se ha logrado realizando su programación en código C y C++ optimizados, aprovechando además las capacidades que proveen los procesadores multinúcleo. OpenCV puede utilizar el sistema de primitivas de rendimiento integradas de Intel, un conjunto de rutinas de bajo nivel específicas para procesadores Intel. Debido a su eficiencia computacional es un entorno idóneo para ser utilizado en aplicaciones de tiempo real aunque este no es uno de los objetivos principales que se persiguen.

2.2.1.4 ImageJ

ImageJ [Ima] es una API de PDI de dominio público programada en Java y desarrollada por el National Institutes of Health (NIH). Dispone de múltiples complementos que están a disposición del público general en su página web, ampliando sus funcionalidades y ajustándose a las necesidades de los desarrolladores.

El desarrollo de algoritmos de PDI utilizando *ImageJ* tiene el inconveniente de que Java no es un lenguaje de programación orientado al cómputo matricial, además requiere una compilación que genera un código interpretable por una máquina virtual, por lo que la eficiencia computacional no es tan alta como en otros entornos.

2.2.1.5 WEKA

Waikato environment for knowledge analysis (WEKA) es un entorno de experimentación que permite aplicar, analizar y evaluar las técnicas más relevantes de análisis de datos, en particular las provenientes del aprendizaje automático sobre cualquier conjunto de datos del usuario. Para ello sólo se requiere que los datos a analizar se almacenen con un cierto formato, conocido como *attribute-relation file format* (ARFF). WEKA se distribuye como software de libre distribución desarrollado en

Java. Está constituido por una serie de paquetes de código abierto con diferentes técnicas de preprocesado, clasificación, agrupamiento, asociación, y visualización, así como facilidades para su aplicación y análisis de prestaciones cuando son aplicadas a los datos de entrada seleccionados. Estos paquetes pueden ser integrados en cualquier proyecto de análisis de datos e incluso pueden extenderse con contribuciones de los usuarios que desarrollen nuevos algoritmos. Con objeto de facilitar su uso por un mayor número de usuarios, WEKA incluye una interfaz gráfica de usuario para acceder y configurar las diferentes herramientas integradas.

2.2.1.6 **Elección del entorno de desarrollo**

Tras sopesar las diferentes alternativas se ha llegado a la conclusión de que el entorno de desarrollo más adecuado es Matlab. Los factores determinantes a la hora de realizar la elección han sido el conocimiento previo, su eficiencia computacional en la ejecución de algoritmos y su amplia aceptación por la comunidad científica. Dado que el objetivo principal de esta tesis doctoral es el desarrollo y prueba de algoritmos, no se ha creído que sea un factor a tener en cuenta que Matlab pierda eficiencia en aplicaciones orientadas a gestión. Además, este inconveniente puede ser solucionado mediante su integración con Java, el cual es fuerte en este aspecto.

Para abordar el análisis de los resultados obtenidos por los algoritmos diseñados se ha optado por utilizar WEKA. Esto se debe a la facilidad de manejo que ofrece su interfaz gráfica, su fácil integración con Matlab, además de los conocimientos previos poseídos.

2.2.2 **Modelos de color**

El propósito de los modelos de color es realizar una especificación estándar de los colores. Son representaciones en un sistema de coordenadas 3D y un subespacio dentro del mismo, en el cual, cada color se representa por un punto. Cada modelo de color tiene una representación y características propias, por lo que es necesario elegir de forma apropiada el más indicado para cada proceso de desarrollo de algoritmos de PDI. Una lectura recomendada para entender las características de los diferentes modelos de color es [IHKM12] que realiza una detallada descripción de diferentes modelos de color.

Relacionado con la elección de modelos de color, el estudio [LMH12] aborda una detección de pólipos basada en la textura. Para ello utiliza diferentes modelos de color, de los cuales realiza una comparativa.

A continuación se introducen las características básicas de los modelos RGB, *hue, saturation, intensity* (HSI) y HSV, que son las representaciones más utilizadas en la literatura para la evaluación de la calidad de preparación del colon y la detección de pólipos.

2.2.2.1 **Modelo RGB**

El modelo RGB representa cada color por sus componentes espectrales primarias: rojo (R), verde (G) y azul (B) basándose en el sistema de coordenadas cartesianas. El subespacio de color de interés es el representado por el tetraedro de la figura 2.11. Los colores R, G y B se encuentran en tres vértices, situándose cian, magenta y amarillo en otros tres vértices, el negro corresponde al origen y el blanco es el punto más alejado del origen.

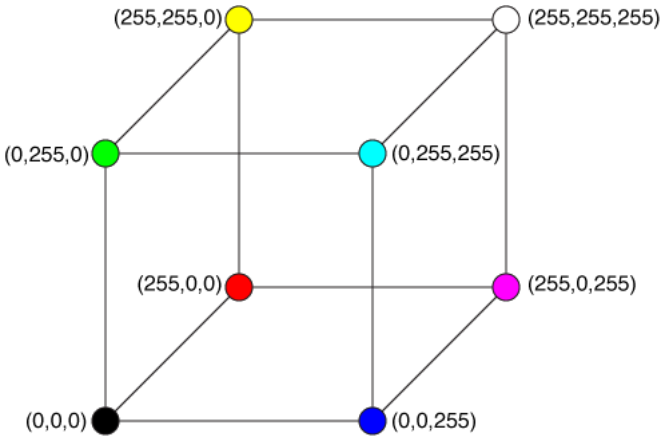


Figura 2.11: Modelo de color RGB. Fuente: goo.gl/xfsAOp

La escala de grises en este modelo se extiende desde el negro al blanco a lo largo de la diagonal que los une y los colores son puntos dentro del tetraedro definidos por vectores desde el origen. Está basado en la síntesis aditiva, ya que la representación del color se realiza mediante la mezcla de los tres colores primarios. Diversos estudios se han basado en este modelo de color con diferentes finalidades.

La investigación [MOT+12] realiza una proyección de los píxeles considerados como heces en las imágenes colonoscópicas en un cubo RGB para después realizar una clasificación de los píxeles basándose en el eje R. Otro estudio que hace uso de este modelo de color es [SAG+09] en el cual usan el canal G para una mejor caracterización de los vasos sanguíneos de los pólipos.

Con base en el modelo RGB existe una variación denominada espacio de color oponente, en el que las componentes pasan a ser: amarillo-azul, rojo-verde y blanco-negro. Cada eje no está correlado de forma mutua, por lo que aporta información independiente. El estudio [ZM11] utiliza este modelo de color para la extracción de los momentos de color. La conversión desde el modelo RGB al espacio de color oponente se realiza mediante la ecuación 2.2.

$$\begin{pmatrix} O_1 \\ O_2 \\ O_3 \end{pmatrix} = \begin{pmatrix} \frac{R-G}{\sqrt{2}} \\ \frac{R+R-2B}{\sqrt{6}} \\ \frac{R+G+B}{\sqrt{3}} \end{pmatrix} \tag{2.2}$$

2.2.2.2 **Modelo HSI**

El modelo HSI está basado en la tonalidad (H), saturación (S) e intensidad (I). La tonalidad es un atributo del color que describe su pureza, mientras que la saturación determina el grado en el que el color puro es diluido con luz blanca. La utilidad del modelo de color HSI es debida a dos motivos, en primer lugar, la componente intensidad se puede separar de la información de color de la imagen y en segundo lugar, las componentes tonalidad y saturación están relacionadas con el modo en el que los seres humanos perciben los colores. Estas características hacen que el modelo de color HSI sea una herramienta ideal para el desarrollo de algoritmos de PDI. Ejemplo de ello es la investigación [DHHM06] que efectúa una segmentación de imágenes utilizando este modelo de color. La figura 2.12 muestra su representación.

2.2.2.3 **Modelo HSV**

El modelo de color HSV (véase figura 2.13) está basado en la tonalidad (H), saturación (S) y brillo (V). Realiza una transformación no lineal del espacio de color RGB y puede ser usado en progresiones de color. Los valores de la tonalidad van

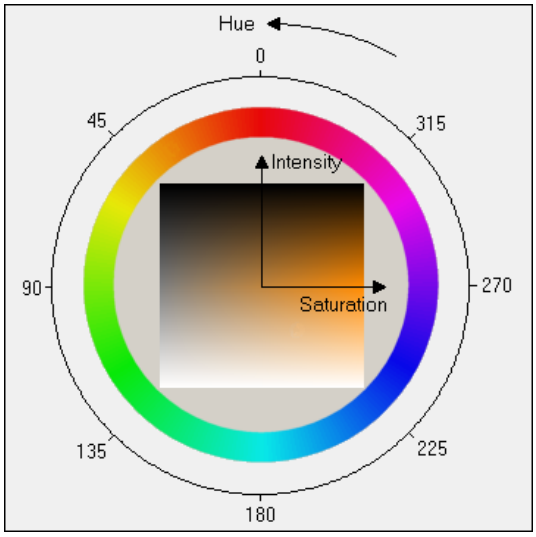


Figura 2.12: Modelo de color HSI. Fuente: goo.gl/le4aIQ

desde 0 a 360º, donde el color rojo se fija en 0º y el negro en 360º. Los valores de la saturación y brillo están en el rango de 0 a 1.

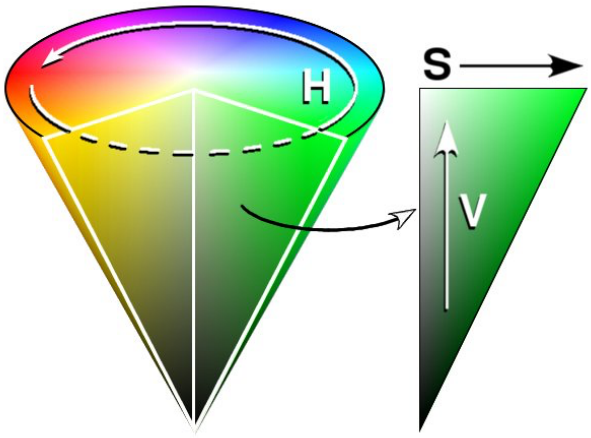


Figura 2.13: Modelo de color HSV. Fuente: goo.gl/sGtEUC

Las características espectrales de los sensores de las cámaras que capturan las imágenes y las condiciones de iluminación son quienes determinan el nivel de color de las imágenes. Su punto fuerte es la consistencia y eficiencia en la detección de colores, ya que la tonalidad es inmune a las condiciones de iluminación, por este motivo es utilizado en multitud de estudios de PDI. El estudio [ARGF+12] utiliza

el modelo de color HSV para diferenciar de una forma más precisa las paredes del colon y el contenido fecal basándose en la tonalidad. Buscando otra finalidad, los estudios [GYS12] y [GPT+12] se basan en este modelo de color para la detección de reflejos especulares debidos a la reflexión directa de luz en la cámara.

2.2.2.4 Comparativa de los modelos de color RGB, HSI y HSV

Como ya se ha mencionado, es necesario tener en cuenta los puntos fuertes y débiles de cada uno de los espacios de color y elegir el más favorable para cada una de las tareas de PDI a realizar. A continuación, en la tabla 2.9 se muestran las ventajas e inconvenientes de los modelos de color descritos.

Tabla 2.9: Ventajas e inconvenientes de los modelos RGB, HSI y HSV.

Modelo	Parámetros	Principal	Ventajas	Inconvenientes
RGB	Rojo Verde Azul	Rojo Verde Azul	No requiere transformación para mostrar información. Eficiencia computacional.	Inútil para segmennaciones. Visualización uniforme. Componentes correlajas.
HSI	Tonalidad Saturación Intensidad	Intensidad	Correlado con la percepción humana. La tonalidad representa el color. Separa valores cromáticos y acromáticos	No uniforme. Singularidad en la tonalidad. Gran sensibilidad de la tonalidad. Necesaria la transformación para su visualización.
HSV	Tonalidad Saturación Brillo	Brillo	Correlado con la percepción humana. La tonalidad representa el color.	Inestable en valores de tonalidad y brillo altos y bajos.

2.2.3 Técnicas y métodos de mejora de imagen

Todo proceso de captura de imágenes se ve afectado en mayor o menor medida por artefactos que deterioran la calidad de éstas. Las imágenes colonoscópicas no son una excepción, por ello se hace necesario aplicar técnicas que ayuden a mejorar su calidad y así obtener una mejor representación.

Se consideran técnicas de mejora de imagen todas aquellas que tienen como objetivo, contrastar, resaltar, acentuar o eliminar efectos no deseados en las imágenes. Este es un proceso de vital importancia en las imágenes médicas, en las que debido a las limitaciones del sistema de captura, en el caso que nos ocupa, el colonoscopio, se obtienen unos efectos no deseados que es necesario eliminar. Es indispensable destacar que mediante la mejora de imágenes:

- No se añade nueva información a la imagen, sólo se resalta para ser utilizada de una forma más eficiente por los algoritmos a desarrollar.

- No existe un criterio exacto de cuantificación del grado de mejora, en muchos casos se basa en opiniones subjetivas y/o en el resultado obtenido por los algoritmos desarrollados.

Este apartado tratará los siguientes artefactos generados en la obtención de imágenes colonoscópicas: mascara negra, fantasmas de color, entrelazado, reflejos especulares, ruido e iluminación no homogénea, así como las soluciones aportadas por la comunidad científica en diferentes investigaciones. Por otro lado, se analizarán diferentes técnicas clásicas de mejora de imagen utilizadas en investigaciones de PDI.

2.2.3.1 Problemas en la captura de vídeos e imágenes colonoscópicas

A continuación se describirán los principales artefactos que afectan a la obtención de las imágenes colonoscópicas, debidos en muchos casos al dispositivo de captura o a la dificultad del entorno.

Máscara negra

Debido a las lentes del sistema de captura de imágenes colonoscópicas, éstas tienen un borde negro en la periferia. En muchos casos es utilizado para mostrar información, bien del paciente, o de la prueba que se está realizando. Este marco dificulta el desarrollo de algoritmos de PDI ya que genera falsos bordes, además de suponer una mayor área a analizar que no aporta información útil. Por estos motivos se hace necesario aplicar diferentes técnicas para eliminar sus efectos. En la figura 2.14 se puede observar la máscara negra de las imágenes colonoscópicas.



Figura 2.14: Máscara negra en las imágenes colonoscópicas.

En la literatura existen tres tendencias para eliminar la máscara negra de las imágenes: restauración de la imagen, la utilización de umbrales y el recorte de la máscara negra. A continuación se realiza una breve explicación de cada uno de los métodos.

- Eliminación de la máscara negra mediante la restauración de la imagen: se trata de reemplazar los píxeles de la máscara negra por la media de los valores de los píxeles de una vecindad determinada. Este enfoque ha sido utilizado en la investigación [BSV13] obteniendo unos resultados satisfactorios.

- Eliminación de la máscara negra mediante la utilización de umbrales: se fija un umbral para detectar los bordes reales de la imagen eliminando la máscara

negra. Este enfoque en muchas ocasiones no consigue una eliminación completa de la máscara negra, quedando líneas residuales por las que se hace necesario aplicar técnicas como la transformada de Hough para su eliminación [DH72]. Esta alternativa ha sido utilizada en la investigación [WCLS12].

- Eliminación de la máscara negra mediante el recorte de la imagen: este es el enfoque más sencillo en el que se elige una región de la imagen y se elimina el resto. Este método trata de obtener una imagen de menor tamaño pero manteniendo la máxima información de la imagen original posible, corriéndose el riesgo de perder información valiosa.

Fantasmas de color

El problema de los fantasmas de color (véase figura 2.15) está asociado con la falta de alineación temporal de los canales de color. Su aparición es debida a que gran parte de los dispositivos de colonoscopia utilizan cámaras monocromáticas, en las que las componentes R, G y B son obtenidas en diferentes instantes de tiempo.

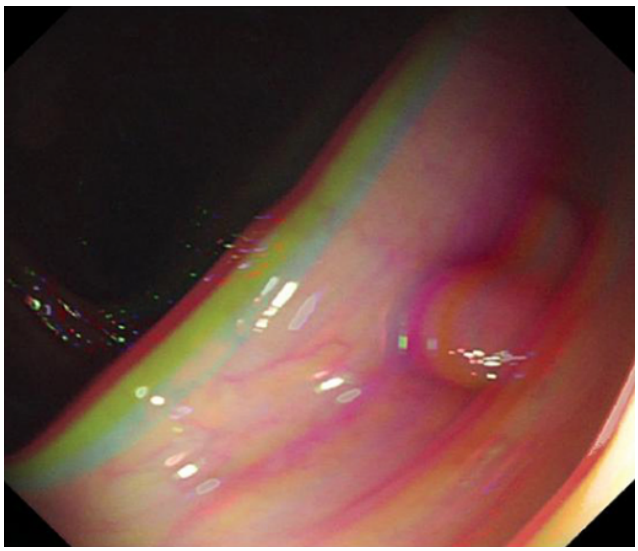


Figura 2.15: Fantasmas de color en las imágenes colonoscópicas.

Esto provoca un deterioro de la calidad de las imágenes, dificultando el posterior desarrollo de algoritmos de PDI. Este problema ha sido abordado en la literatura en la investigación [DVL08] que propone una ecualización de los canales,

además de realizar una estimación y compensación de los movimientos de la cámara. Esta misma solución ha sido tratada en el estudio [AAGL11]. La aplicación de esta técnica corrige este efecto de una forma muy precisa, fallando de forma exclusiva en aquellas imágenes con una calidad inicial muy baja.

Entrelazado

El entrelazado permite doblar el número de fotogramas por segundo percibidos sin consumir un ancho de banda extra. Es usado en formatos estándar como por ejemplo *national television system commitee* (NTSC) o *phase alternating line* (PAL) y visualiza la mitad de las líneas horizontales en cada iteración. Cada fotograma es dividido en dos campos, el primero contiene las líneas de número impar y el segundo las pares. Debido al fenómeno de la persistencia de la visión humana, el cerebro mezcla ambas iteraciones del fotograma entrelazado, identificándola como una única imagen. Los efectos del entrelazado provocan la aparición de falsos bordes en las imágenes (ver figura 2.16) que hacen el desarrollo de algoritmos más complicado. Debido a esto se hace necesario aplicar técnicas para reducir su incidencia.



Figura 2.16: Efecto del entrelazado en las imágenes colonoscópicas.

Los estudios [dNPF10], [BSV11b] y [BSV12b] abordan la eliminación de los efectos del entrelazado realizando un desentrelazado. El procedimiento se basa en la obtención de una de cada dos líneas horizontales, reduciendo el tamaño vertical

de la imagen. Para mantener la proporción de tamaño de la imagen original realizan un redimensionamiento vertical mediante un factor de 0.5.

Reflejos especulares

Los reflejos especulares son puntos de alta intensidad en la imagen debidos a la iluminación de objetos brillantes. Cuando una fuente de luz incide de forma directa sobre un objeto ésta es reflejada y capturada por la cámara. Este proceso genera zonas muy saturadas en la imagen que pueden producir bordes no deseados, dificultando el posterior procesamiento de la imagen. Este efecto es de gran importancia en la investigación que se propone, ya que debido a la forma de los pólipos, que al ser iluminados reflejan la luz y generan reflejos especulares, en general de forma redondeada similar a la de las lesiones, pueden derivar en un mal funcionamiento de los algoritmos desarrollados. Existen multitud de métodos para la detección de los reflejos especulares. A continuación se hace un breve resumen de los más importantes.

La publicación [PSS+12] propone una detección de los reflejos especulares mediante la búsqueda de áreas saturadas y regiones pequeñas con alto contraste. Las áreas saturadas son detectadas aplicando un umbral adaptativo en el histograma de intensidad de la imagen. El valor del umbral viene determinado como la región que rodea el valor máximo del histograma. Las regiones de pequeño tamaño y alto contraste son detectadas mediante el método propuesto en el trabajo [BS87], que aplica un filtro de sombrero de copa, seguido de una operación de reconstrucción y erosión por una estructura de disco de tamaño 5.

El estudio [BSV13] asume que el valor de la intensidad de los píxeles especulares es mayor que el de los píxeles no especulares de su vecindad. Además, indican que los píxeles no especulares vecinos de píxeles especulares tendrán valores de intensidad mayores que píxeles no especulares lejanos a zonas especulares. La detección de reflejos especulares se realiza mediante la resta de la imagen original y su media. Una vez realizado esto, mediante la utilización de umbrales, se pueden detectar los reflejos especulares.

El trabajo [GPT+12] realiza una detección de reflejos especulares basándose en el espacio de color HSV. Los reflejos especulares muestran una alta saturación y

bajo brillo, por lo que se hace sencilla su detección.

El método propuesto en [Gev03] para la detección de reflejos especulares utiliza dos espacios de color diferentes. En el primero de ellos es necesario que se aprecien los bordes generados por los cambios de textura y reflejos especulares. En el segundo sólo tienen que poderse ver los bordes debidos a las texturas. Realizando la resta de estos dos espacios de color se detectan los reflejos especulares. Este método ha sido utilizado en la investigación [SAG+09] con resultados satisfactorios. En ella se sugiere una detección de reflejos especulares basada en la baja saturación del color de los reflejos. Por desgracia, los píxeles con reflejos especulares no son los únicos que pueden cumplir esta condición, por lo que para asegurar la correcta detección de reflejos especulares realizan una comprobación extra basada en la condición 2.3 sobre el brillo de los píxeles.

$$\text{Es reflejo especular} \begin{cases} Sí, if(Saturacion < t_1) \cap (Brillo > t_2) \\ No\ en\ otro\ caso. \end{cases} \tag{2.3}$$

Este método tiende a realizar una baja segmentación, por lo que aplican una dilatación morfológica mediante una estructura de disco de tamaño 5, de forma que se aumenta el tamaño de los reflejos especulares y así se facilita su detección.

La investigación [GYS12] hace uso de este método para la detección de reflejos especulares realizando una breve aportación. Una vez realizado el umbralizado y dilatación vuelven a repetir el proceso actualizando los umbrales. El primer umbralizado consigue píxeles con una alta probabilidad de ser especulares, en cambio, el segundo obtiene píxeles con una baja confianza. La detección final de píxeles especulares se realiza eligiendo de forma exclusiva aquellos detectados como especulares por el segundo umbral y que además estén conectados con píxeles especulares detectados por el primer umbral.

Una vez detectados los reflejos especulares, la opción más utilizada en la literatura para su eliminación es la restauración. Este es un proceso que permite recuperar una parte deteriorada de una imagen mejorando su calidad. En este caso el procedimiento consta de dos pasos:

1. Difusión de los reflejos especulares: una vez detectados los reflejos especulares se sustituye su valor inicial por la media de la vecindad 3x3 de sus

píxeles vecinos que no pertenecen al reflejo especular o ya hayan sido sustituidos. Este proceso se realiza de forma iterativa hasta que la diferencia entre los nuevos píxeles calculados y los iniciales sea menor a un determinado umbral.

2. Obtención de la imagen reconstruida: una vez obtenidos los nuevos valores de los reflejos especulares, estos no deben ser sustituidos de forma directa en la imagen original como se realiza en [AAGL11], ya que se generarían nuevos bordes. Una solución a esta problemática está propuesta en la publicación [BSV13]. En ella realizan una dilatación de la máscara de los reflejos especulares detectados mediante una estructura circular, para a continuación realizar la convolución con un núcleo gaussiano. Una vez obtenida esta nueva máscara, la imagen reconstruida sin reflejos especulares queda definida por la ecuación 2.4:

$$I_{np} = M_I \cdot I_o + (1 - M_I) \cdot I_d \tag{2.4}$$

Donde I_{np} representa la imagen reconstruida, M_I la nueva máscara calculada, I_o la imagen original e I_d la imagen difusa.

Iluminación no homogénea

Las variaciones de intensidad y dirección de la iluminación son determinantes en la apariencia de los objetos en las imágenes digitales. La iluminación del colon mediante el sistema de colonoscopia es variante, lo que debido a la forma tridimensional del colon se generan sombras que acentúan o disminuyen ciertos aspectos de la imagen. Distintas condiciones de iluminación sobre un mismo objeto provocan representaciones desiguales del mismo, por lo que dicha variación de la iluminación no es deseada. En la literatura existen diversas publicaciones que abordan esta problemática.

La investigación [RAMSHR$^+$07] presenta un operador de contraste construido por medio de dos primitivas que involucran a la ley de Weber [WEB]. Con ello mejoran el contraste de la imagen basándose en la detección del fondo de la imagen, parámetro que se calcula a partir del análisis de los mínimos regionales, los cuales se obtienen mediante un cierre morfológico por reconstrucción.

El estudio [SAG+09] realiza una reducción de los efectos de la iluminación no homogénea mediante la normalización local del brillo de la imagen. Para este fin cada píxel es dividido por el máximo valor de su vecindad. En dicha publicación se ha considerado una vecindad de 13x13 píxeles.

Por último, en el trabajo [GPT+12] realizan una ecualización del fondo de la imagen en escala de grises, de forma que potencian el contraste de las diferentes estructuras, además de eliminar las variaciones de iluminación de la imagen.

2.2.3.2 Técnicas clásicas de mejora de imagen

A medida que el PDI ha ido alcanzando una cierta madurez se han desarrollado diferentes técnicas para mejorar ciertos aspectos o efectos no deseados en las imágenes. En este apartado se describirán las técnicas clásicas más utilizadas en investigaciones y desarrollos de PDI.

Transformaciones de intensidad

Las transformaciones de intensidad son los procesos más simples y efectivos dentro del PDI. Es común que el valor de los píxeles de las imágenes esté almacenado en 8 bits, por lo que es habitual trabajar con 256 valores de intensidades (2^8), es decir, valores en el rango [0-255]. Existen diversos métodos para la transformación de la intensidad, a continuación se describirán los más utilizados.

- Negativo de la imagen: el negativo de una imagen con niveles de intensidad en el rango [0, L-1] es útil para mejorar los detalles claros u oscuros en regiones oscuras. Su cálculo se realiza mediante la ecuación 2.5.

$$I_2(x, y) = (L - 1) - I_1(x, y) \tag{2.5}$$

- Transformación logarítmica: esta técnica es muy utilizada para expandir los valores de los píxeles oscuros y comprimir los valores de intensidad altos. En otras muchas ocasiones es empleada para visualizar la transformada de Fourier de una imagen debido a la compresión que realiza de los altos valores de intensidad. La transformación logarítmica se implementa mediante la ecuación 2.6.

$$I_2(x, y) = c \cdot log(1 + I_1(x, y)) \tag{2.6}$$

Realzado de imágenes mediante modificaciones del histograma

El histograma de una imagen digital es una función discreta $h(i_k) = n_k$, donde i_k es el k-ésimo valor de intensidad y n_k el número de píxeles en la imagen con la intensidad i_k. El cálculo del histograma es eficiente en cuanto a su coste computacional y es la base de muchas técnicas de PDI en el dominio espacial.

Los histogramas con una distribución de niveles de gris concentrados en una determinada zona, presentan un bajo contraste, mientras que los histogramas con una distribución más amplia cuentan con un mayor contraste. Los histogramas con los niveles de gris centrados en la parte baja del rango corresponden a imágenes oscuras y los centrados en la parte alta a imágenes brillantes.

Las operaciones más utilizadas sobre el histograma son la corrección gamma, contracción, expansión, desplazamiento, ecualización y emparejamiento. A continuación se hace una descripción de cada una de ellas.

- Corrección gamma: dada la intensidad de un píxel I_p, su valor en la pantalla de un monitor I_m sigue una relación no lineal. El objetivo de la corrección gamma consiste en obtener una relación lineal entre los valores de intensidad del píxel I_p, que en realidad son los valores interpretados por las aplicaciones y algoritmos, con lo mostrado por pantalla. De esta forma se consigue una mayor similitud entre los valores de intensidad de los píxeles reales y los mostrados por pantalla.

- Contracción del histograma: esta técnica no produce un realzado de la imagen, sino que genera una disminución del contraste de la imagen. Para estudiar el efecto y mejora que proporciona la expansión del histograma, que se describirá en el siguiente punto, se hace necesario describir esta técnica. La ecuación 2.7 representa la función de contracción del histograma.

$$g(i,j) = \left[\frac{C_{max} - C_{min}}{f(i,j)_{max} - fi(i,j)_{min}}\right] \left[f(i,j) - f(i,j)_{min}\right] + C_{min} \qquad (2.7)$$

  Donde $f(i,j)$ representa el nivel de gris de la imagen de entrada, $f(i,j)_{max}$ el valor máximo del nivel de gris en la imagen de entrada, $f(i,j)_{min}$ el menor

valor de gris en la imagen de entrada, siendo C_{max} y C_{min} los máximos y mínimos valores deseados en el histograma.

- Expansión del histograma: se trata de la operación contraria a la contracción del histograma. Su efecto es el incremento del contraste de la imagen. En caso de desearse que la expansión no cubra todo el rango de posibles niveles de gris pueden especificarse parámetros para ello. Si muchos valores de una imagen caen dentro de un pequeño rango y existe un cierto número de valores extremos, el histograma abarca todo el rango de valores posibles y la expansión del histograma no mejora la imagen. En este caso es una práctica habitual recortar los niveles de gris en los extremos a los valores de gris más bajo y alto del rango. La ecuación 2.8 representa la función que expande los valores del histograma.

$$g(i,j) = \left[\frac{f(i,j)-f(i,j)_{min}}{f(i,j)_{max}-fi(i,j)_{min}}\right]\left[max - min\right] + min \tag{2.8}$$

  Donde $f(i,j)$ representa el nivel de gris de la imagen de entrada, $f(i,j)_{max}$ el valor máximo del nivel de gris en la imagen de entrada, $f(i,j)_{min}$ el menor valor de gris en la imagen de entrada, correspondiéndose max y min con el máximo y mínimo valor de los niveles de gris.

- Desplazamiento del histograma: es utilizado para aclarar u oscurecer una imagen manteniendo la relación entre los niveles de gris. Esta operación puede llevarse a cabo mediante una adición o sustracción de un número fijo a todos los valores de niveles de gris. La ecuación 2.9 define el desplazamiento del histograma.

$$g(i,j) = f(i,j) + DES \tag{2.9}$$

  Donde DES es el valor de desplazamiento del histograma. En esta ecuación se asume que los valores que sobrepasen el máximo y mínimo se redondean de forma respectiva al máximo y mínimo. Los valores positivos de DES incrementan el brillo, por el contrario los negativos oscurecen la imagen.

- Ecualización del histograma: es utilizada para incrementar el contraste de las imágenes aumentando el rango de valores donde se distribuyen las intensidades del histograma. El método más común de ecualizar el histograma es empleando una función de distribución acumulada de las intensidades (véase ecuación 2.10) como función de transferencia de intensidades.

$$fda(i_k) = \sum_{i=0}^{k} h(i_j) \tag{2.10}$$

- Emparejamiento del histograma: el emparejamiento del histograma es útil cuando se requiere que éste se comporte de una manera determinada. Para ello es necesario generar un modelo de histograma o utilizar una imagen como referencia. Para su cálculo, en el caso de utilizar una segunda imagen como referencia, habría que seguir el siguiente procedimiento:

  1. Obtener el histograma normalizado y acumulado de ambas imágenes.
  2. Dejar los valores de los histogramas acumulados en el rango [0-255].
  3. Ecualizar la imagen que se desea mapear empleando el histograma acumulado. Los rangos de intensidad de la imagen ecualizada deberán estar en el rango [0-255].
  4. Para cada píxel de la imagen ecualizada se busca el valor correspondiente en el histograma acumulado de la imagen referencia y se le asigna el valor de intensidad relacionado con ese valor.

Técnicas de suavizado

Las operaciones de suavizado tienen como objetivo la reducción de ruido y/o efectos espurios que pueden presentarse en una imagen como consecuencia del proceso de captura y digitalización. La aplicación de técnicas de suavizado es práctica habitual como paso previo a la aplicación de detectores de bordes, por lo que tiene una aplicación directa en la tesis doctoral que se presenta. El suavizado puede realizarse en dos dominios, espacial y frecuencial.

- Suavizado espacial: los métodos dentro de este grupo se basan en operaciones locales sobre los píxeles de las imágenes. A continuación se describen los principales métodos que existen dentro de este tipo de operadores.

  - Promediado del entorno: se trata de una técnica del dominio espacial en la que a partir de una imagen $g(i,j)$ se obtiene una imagen suavizada $f(i,j)$ cuya intensidad para cada punto (i,j) se obtiene promediando los valores de intensidad de los píxeles de g incluidos en el entorno de la vecindad predefinido de (i,j). Esta operación puede representarse mediante la ecuación 2.11.

    $$f(i,j) = \frac{1}{p} \sum_{(m,n)\epsilon S} g(m,n) \tag{2.11}$$

    Para todos los píxeles (i,j) de $g(i,j)$, S representa el conjunto de coordenadas de los puntos situados en el entorno de la vecindad (i,j), incluido el propio (i,j) y p es el número total de píxeles en la vecindad.

    Uno de los principales inconvenientes de los métodos de promediado del entorno es que los contornos y detalles de la imagen son desdibujados. Para paliar estas consecuencias se puede aplicar el filtro de la mediana o promediado selectivo que se detallan en los siguientes puntos.

  - Promediado selectivo y ponderado: como alternativa a los métodos de promediado del entorno, que generan efectos no deseables en las imágenes, se presentan los métodos de promediado selectivo y ponderado. Se basan en la realización del promediado, teniendo en cuenta sólo determinados píxeles vecinos. De esta forma se evita el difuminado de bordes, esquinas y líneas de la imagen. El principal inconveniente de estos métodos viene dado por la complejidad computacional que acarrea la adición de un detector de bordes o direcciones.

  - Media simple: este método se basa en, dada una imagen $f(i,j)$, generar una nueva imagen $g(i,j)$ en la que la intensidad de cada píxel se obtiene

promediando los valores de intensidad de los píxeles de $f(i,j)$ incluidos en el entorno de vecindad predefinido. A continuación, la ecuación 2.12 muestra cómo realizar el cálculo de la media simple.

$$g(i,j) = \frac{1}{p} \sum_{(m,n)\epsilon S} f(m,n) \tag{2.12}$$

Donde S es un subconjunto de p píxeles situados en el entorno de (i,j), incluyendo (i,j). El tamaño de la vecindad utilizada es de suma importancia, cuanto mayor sea, más reducción de ruido se realizará, pero a su vez la difuminación de bordes será mayor.

– Filtrado de la mediana: como ya se ha mencionado con anterioridad, uno de los principales problemas de los métodos de promediado del entorno es el desdibujado de bordes, líneas y detalles de la imagen. Una alternativa a estos métodos es el filtrado de la mediana, que consiste en sustituir el nivel de gris de cada píxel por la mediana de los píxeles vecinos. Es un método no lineal, ya que no se basa en la convolución de la imagen con una determinada máscara. Como efecto negativo, la aplicación de este método puede producir el desplazamiento de bordes. Este inconveniente debe ser tenido en cuenta cuando se requiere precisión en la localización de estos.

– Filtro de Gauss: una distribución gaussiana con desviación típica σ y mediana μ viene determinada por la ecuación 2.13.

$$g_\sigma = \frac{1}{\sigma\sqrt{2\pi}} e^{-1/2(\frac{x-\mu}{\sigma})} \tag{2.13}$$

La convolución de la función $g_\sigma(x)$ con una señal $f(x)$ da lugar a una señal suavizada $h(x)$, donde el valor de cada píxel es el resultado de promediar con distintos pesos los valores vecinos de dicho píxel. La desviación típica σ determina el grado de suavizado a aplicar, cuanto mayor sea, mayor influencia tienen los píxeles lejanos y mayor suavizado se realiza. Su extensión para el procesado de imagen viene determinada por la ecuación 2.14.

$$g_\sigma(x,y) = \frac{1}{2\pi\sigma^2} e^{-1/2(\frac{x^2+\mu^2}{\sigma^2})} \tag{2.14}$$

Este método también sufre del efecto de difuminado de bordes y detalles de la imagen siendo menos apreciables que en otros métodos, como por ejemplo en la media simple.

- Suavizado frecuencial: de acuerdo a la teoría de filtrado de señales, el suavizado y reducción de ruido en el dominio frecuencial puede llevarse a cabo mediante la aplicación de un filtro paso bajo. Es conocido que la multiplicación de dos señales en el dominio frecuencial es equivalente a la convolución de éstas en el dominio espacial. Esta igualdad se muestra en la ecuación 2.15.

$$G(W) = F(W) \cdot H(W) \leftrightarrow f(x) \bigotimes h(x) \tag{2.15}$$

Donde $G(W)$, $F(W)$ y $H(W)$ son las transformadas de Fourier de las señales unidimensionales $g(x)$, $f(x)$ y $h(x)$. En el caso que se está tratando, estas funciones serán bidimensionales y discretas.

2.2.4 Detectores de bordes

Los bordes son puntos alrededor de los cuales la imagen presenta una brusca variación en los niveles de intensidad. Estos proporcionan una valiosa información sobre las fronteras de los objetos que aparecen en las imágenes, siendo la base para futuras segmentaciones, reconocimiento de objetos, etc. La aplicación de detectores de bordes en esta tesis es fundamental para la detección de pólipos.

En la figura 2.17 se muestra el modelo unidimensional y continuo de un borde ideal. Se trata de un borde de tipo rampa que va desde un nivel bajo de gris B a un valor alto A, mediante los siguientes parámetros:

- H: variación de intensidad. $H = A - B$.
- α: inclinación de la rampa.

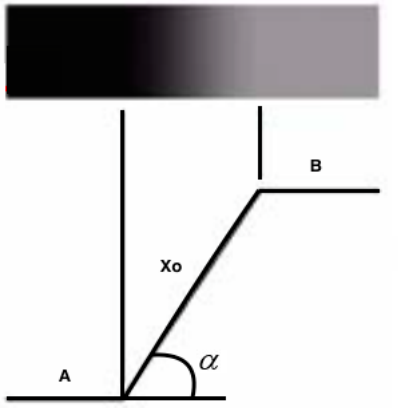


Figura 2.17: Borde ideal de tipo rampa. Fuente: goo.gl/Y0XYDF

- x_0: punto medio de la rampa.

Los operadores de bordes nos proporcionan los valores x_0 y H, de esta forma podemos conocer la amplitud y localización de los bordes dentro de la imagen, siendo de gran utilidad. A la hora de trabajar con imágenes reales, los bordes no se ajustan de forma precisa al modelo descrito por diversos motivos, siendo los más importantes los siguientes:

- Las imágenes se ven afectadas por ruido y artefactos.
- Las imágenes son discretas.
- Los bordes se deben a diversos motivos: superficies con diferente orientación, oclusiones, cambios de textura, etc.

Las circunstancias anteriores dificultan la detección de bordes propiciando la aparición de los siguientes problemas:

- Error de detección: en ocasiones se detectan bordes no deseados o viceversa, por ese motivo es necesario un preprocesado previo de las imágenes.
- Error de localización: en muchos casos la posición del borde localizada por el detector no se corresponde con su posición real.

Los métodos más comunes de detección de bordes están basados en el concepto de la derivada. A continuación se describirán las técnicas más utilizadas en la literatura para los operadores basados en la primera y segunda derivada.

2.2.4.1 Uso de la derivada en la detección de bordes

En la figura 2.18 se observa que los bordes se modelan como una rampa en lugar de hacerlo como un cambio brusco de la intensidad, debido a que en la imagen original suelen estar desdibujados debido al muestreo.

La primera derivada tiene valor 0 para todas las regiones de intensidad constante y valor cambiante en toda la transición de intensidad. La segunda derivada, al contrario, es 0 en todos los puntos, excepto en el comienzo y final de una transición de intensidad. Los cambios de intensidad se muestran como una variación brusca en la primera derivada y representan un paso por 0, es decir, se produce un cambio de signo en la segunda derivada. Por estos motivos son utilizadas las derivadas para la extracción de bordes.

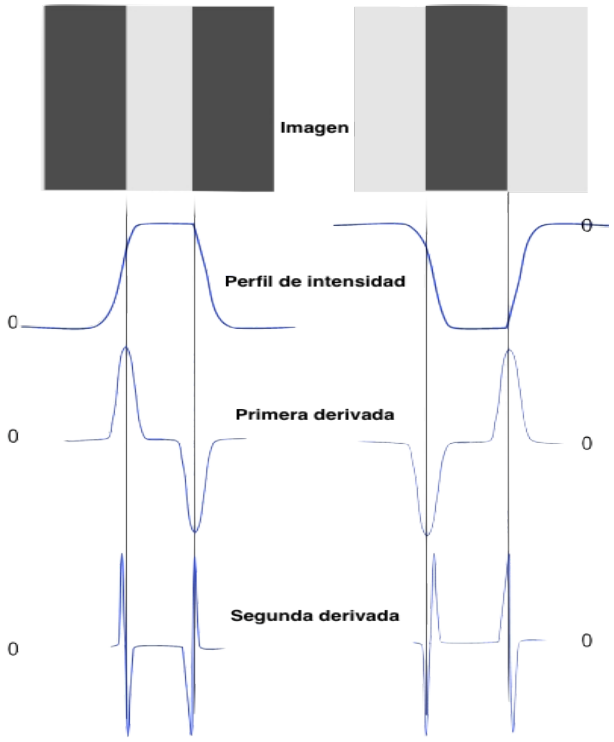


Figura 2.18: Concepto de primera y segunda derivada en la detección de bordes. Fuente: goo.gl/O103Hd

A continuación se realiza una descripción de las técnicas de detección de bordes más utilizadas basadas en los operadores de la primera y segunda derivada.

2.2.4.2 Operadores basados en la primera derivada

La derivada de una señal continua proporciona las variaciones locales con respecto a la variable, de forma que el valor de la derivada es mayor cuanto mas rápidas son estas variaciones.

Operador gradiente

El gradiente de una imagen $f(x, y)$ en el punto (x, y) esta definido por un vector bidimensional perpendicular al borde. La ecuación 2.16 define el gradiente de una imagen.

$$G[f(x,y)] = \begin{bmatrix} G_x \\ G_y \end{bmatrix} = \begin{bmatrix} \frac{\partial}{\partial x} f(x,y) \\ \frac{\partial}{\partial y} f(x,y) \end{bmatrix} \tag{2.16}$$

Donde G apunta en la dirección de máxima variación de f en el punto (x, y) por unidad de distancia con la magnitud y dirección dadas por la ecuación 2.17.

$$\left|G\right| = \sqrt{G_x^2 + G_y^2} \quad ; \phi(x,y) = tan^{-1} \frac{G_y}{G_x} \tag{2.17}$$

Es habitual aproximar la magnitud del gradiente con valores absolutos, ya que el valor de la magnitud del gradiente no es tan importante como la relación entre los diferentes valores. Se decidirá si un punto es borde o no en función de si la magnitud del gradiente supera un determinado umbral. Este cálculo se realiza mediante la ecuación 2.18.

$$|G| \approx |G_x| + |G_y| \tag{2.18}$$

El cálculo de las derivadas se realiza mediante la ecuación 2.19.

$$G_x = \frac{f(x+\Delta x) - f(x-\Delta x)}{2\Delta x} \quad ; G_y = \frac{f(y+\Delta y) - f(y-\Delta y)}{2\Delta y} \tag{2.19}$$

En los siguientes apartados se describirán diversos operadores de extracción de bordes basados en el concepto de la derivada en un punto y que consideran una vecindad de 3x3 píxeles. Dentro de este grupo se incluyen los operadores de Sobel [VF09], Prewitt [Pre70] y Roberts [Rob63]. En otro segundo grupo se incluyen los operadores de Kirsch [Kir71] y Frei-Chen [F$^+$77] que se diferencian de los anteriores en la obtención de sus valores, los cuales son discretos.

Operadores de Sobel

Los valores de G_x y G_y pueden ser calculados mediante la convolución de la imagen con máscaras de 3x3 píxeles. En la ecuación 2.20 se muestran las máscaras de Sobel [VF09].

$$\underset{(a)}{\begin{bmatrix} z_1 & z_2 & z_3 \\ z_4 & z_5 & z_6 \\ z_7 & z_8 & z_9 \end{bmatrix}} \quad \underset{(b)}{\begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix}} \quad \underset{(c)}{\begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix}} \tag{2.20}$$

Donde (a) es la región de la imagen con tamaño 3x3, (b) la máscara usada para calcular G_x en el punto central de la región y (c) la máscara usada para calcular G_y en el punto central de la región.

El operador gradiente en general tiene un efecto de magnificación del ruido en la imagen, lo que genera efectos no deseados. Estos efectos son subsanados mediante los operadores de vecindad que tienen la propiedad de suavizar la imagen.

A partir de las máscaras representadas en la ecuación 2.20, las derivadas basadas en los operadores de Sobel se definen en la ecuación 2.21.

$$\begin{aligned} G_x &= (z_3 + 2z_6 + z_9) - (z_1 + 2z_4 + z_7) \\ G_y &= (z_7 + 2z_8 + z_9) - (z_1 + 2z_2 + z_3) \end{aligned} \tag{2.21}$$

Donde los valores de z de la región de la figura son niveles de gris de los píxeles solapados por las máscaras en cualquier localización de la imagen. Para obtener los valores del vector gradiente en el punto definido por el píxel central de la región, se utilizan las expresiones 2.21, con lo que la magnitud y el ángulo se calculan a partir de las ecuaciones 2.17 y 2.18. Los siguientes valores se obtienen desplazando la máscara a las siguientes posiciones y repitiendo el proceso hasta pasar por todos los píxeles de la imagen.

Operadores de Prewitt

El operador de Prewitt [Pre70] es muy similar al de Sobel, diferenciándose en las máscaras a aplicar (véase ecuación 2.22). La magnitud y valor del gradiente se

obtienen mediante las ecuaciones 2.17 y 2.18.

$$\underset{(a)}{\begin{bmatrix} z_1 & z_2 & z_3 \\ z_4 & z_5 & z_6 \\ z_7 & z_8 & z_9 \end{bmatrix}} \quad \underset{(b)}{\begin{bmatrix} -1 & 0 & 1 \\ -1 & 0 & 1 \\ -1 & 0 & 1 \end{bmatrix}} \quad \underset{(c)}{\begin{bmatrix} 1 & 1 & 1 \\ 0 & 0 & 0 \\ -1 & -1 & -1 \end{bmatrix}} \tag{2.22}$$

Donde la matriz (a) es la región de la imagen de 3x3 píxeles, (b) la máscara usada para calcular G_x en el punto central de la región y (c) la máscara usada para calcular G_y en el punto central de la región.

Operadores de Roberts

El operador de Roberts [Rob63] se diferencia de los dos anteriores en que sólo marca los bordes, sin indicar la orientación de estos. Sus principales ventajas son su simplicidad y eficacia en imágenes binarias, pero en su contra está la no aportación de la orientación de los bordes.
Existen dos formas de aplicación del operador de Roberts, éstas vienen determinadas por las ecuaciones 2.23 y 2.24.

$$\sqrt{[f(x,y) - f(x-1,y-1)]^2 + [f(x,y-1) - f(x-1,y)]^2} \tag{2.23}$$

Esta ecuación se basa en la raíz cuadrada de las diferencias de los vecinos diagonales al cuadrado.

$$\big|f(x,y) - f(x-1,y-1)\big| + \big|f(x,y-1) - f(x-1,y)\big| \tag{2.24}$$

Esta segunda ecuación se basa en la suma de las diferencias de los vecinos diagonales. Es la opción más utilizada debido a su eficiencia computacional.

Operadores de Kirsch

Las máscaras de Kirsch [Kir71], también denominadas brújulas, se definen considerando una máscara simple y rotándola en las ocho direcciones principales de una brújula: Norte, Noroeste, Oeste, Suroeste, Sur, Sureste, Este y Noreste. Las máscaras se definen en la ecuación 2.25.

$$
\begin{array}{cccc}
K_0 \equiv \begin{bmatrix} -3 & -3 & -5 \\ -3 & 0 & 5 \\ -3 & -3 & -5 \end{bmatrix} & K_1 \equiv \begin{bmatrix} -3 & 5 & 5 \\ -3 & 0 & 5 \\ -3 & -3 & -5 \end{bmatrix} & K_2 \equiv \begin{bmatrix} 5 & 5 & 5 \\ -3 & 0 & -3 \\ -3 & -3 & -3 \end{bmatrix} & K_3 \equiv \begin{bmatrix} 5 & 5 & -3 \\ 5 & 0 & -3 \\ -3 & -3 & -3 \end{bmatrix} \\
0^o & 45^o & 90^o & 135^o \\
K_4 \equiv \begin{bmatrix} 5 & -3 & -3 \\ 5 & 0 & -3 \\ 5 & -3 & -3 \end{bmatrix} & K_5 \equiv \begin{bmatrix} -3 & -3 & -3 \\ 5 & 0 & -3 \\ 5 & 5 & -3 \end{bmatrix} & K_6 \equiv \begin{bmatrix} -3 & -3 & -3 \\ -3 & 0 & -3 \\ 5 & 5 & 5 \end{bmatrix} & K_7 \equiv \begin{bmatrix} -3 & -3 & -3 \\ -3 & 0 & 5 \\ -3 & 5 & 5 \end{bmatrix} \\
180^o & 225^o & 270^o & 315^o
\end{array}
\tag{2.25}
$$

Para cada punto de la imagen se obtienen ocho valores resultantes de la convolución con cada una de las máscaras. El valor del módulo del gradiente es el máximo de esos valores y la dirección viene determinada por el ángulo asociado a la máscara que ha generado dicho valor.

Operadores de Frei-Chen

Uno de los principales problemas al que nos enfrentamos a la hora de realizar una detección de bordes es saber si pertenece a un contorno o se trata de un punto aislado producto de otro fenómeno. Una aproximación a esta problemática fue propuesta por Frei-Chen [F$^+$77] y está basada en la aplicación de múltiples operadores de forma simultánea a cada píxel, combinando los resultados. Se trata de una solución con una enfatización más fina que el operador de Sobel, ya que cambia los coeficientes de las máscaras. Se puede considerar una solución intermedia entre los operadores de Sobel y Prewitt.

Se definen nueve máscaras pertenecientes a tres subespacios: bordes, líneas y medio. Los subespacios de bordes y líneas sirven para la detección general, como su propio nombre indica de bordes y líneas, siendo el subespacio medio el encargado de detectar regiones de intensidad uniforme.

A continuación se definen las máscaras ortogonales de Frei-Chen mediante las ecuaciones 2.26, 2.27 y 2.28.

- Subespacio de bordes

$$
f_1 \equiv \frac{1}{2\sqrt{2}} \begin{bmatrix} 1 & \sqrt{2} & 1 \\ 0 & 0 & 0 \\ -1 & -\sqrt{2} & -1 \end{bmatrix} \quad f_2 \equiv \frac{1}{2\sqrt{2}} \begin{bmatrix} 1 & 0 & -1 \\ \sqrt{2} & 0 & -\sqrt{2} \\ 1 & 0 & -1 \end{bmatrix} \quad f_3 \equiv \frac{1}{2\sqrt{2}} \begin{bmatrix} 0 & -1 & \sqrt{2} \\ 1 & 0 & -1 \\ -\sqrt{2} & 1 & 0 \end{bmatrix} \tag{2.26}
$$

- Subespacio de líneas

$$
f_4 \equiv \frac{1}{2\sqrt{2}} \begin{bmatrix} \sqrt{2} & -1 & 0 \\ -1 & 0 & 1 \\ 0 & 1 & \sqrt{2} \end{bmatrix} \quad f_5 \equiv \frac{1}{2} \begin{bmatrix} 0 & 1 & 0 \\ -1 & 0 & -1 \\ 0 & 1 & 0 \end{bmatrix} \quad f_6 \equiv \frac{1}{2} \begin{bmatrix} -1 & 0 & 1 \\ 0 & 0 & 0 \\ 1 & 0 & -1 \end{bmatrix} \tag{2.27}
$$

- Subespacio medio

$$f_7 \equiv \frac{1}{6}\begin{bmatrix} 1 & -2 & 1 \\ -2 & 4 & -2 \\ 1 & -2 & 1 \end{bmatrix} \quad f_8 \equiv \frac{1}{6}\begin{bmatrix} -2 & 1 & -2 \\ 1 & 4 & 1 \\ -2 & 1 & -2 \end{bmatrix} \quad f_9 \equiv \frac{1}{3}\begin{bmatrix} 1 & 1 & 1 \\ 1 & 1 & 1 \\ 1 & 1 & 1 \end{bmatrix} \tag{2.28}$$

La utilización de las máscaras se realiza seleccionando el subespacio de interés y calculando la proyección relativa de la imagen en el subespacio mediante la ecuación 2.29.

$$\cos\Theta = \sqrt{\frac{M}{S}} \quad \text{donde } M = \sum_{K\in\{e_s\}}(I_S, f_k)^2 \quad \text{y } S = \sum_{K=1} 9(I_S, f_k)^2 \tag{2.29}$$

Una vez calculado el valor de M para el subespacio elegido se detectará la presencia de bordes.

Algoritmo de Canny

El algoritmo de Canny [Can86] fue desarrollado en el año 1986 como alternativa a los métodos de detección de bordes existentes, obteniendo mejores resultados a cambio de una mayor complejidad computacional. Está basado en tres criterios principales:

- Criterio de detección: expresa el hecho de evitar la eliminación de bordes importantes, así como de no detectar falsos bordes.
- Criterio de localización: establece que la distancia entre la posición real del borde y la detectada debe ser minimizada.
- Criterio de respuesta única: el detector debe proporcionar un único punto por cada punto de borde verdadero.

El algoritmo de Canny consta de tres pasos que se describen a continuación:

1. Obtención del gradiente: en primer lugar se aplica un filtro gaussiano con el objetivo de suavizar la imagen original eliminando el ruido que pueda existir. El suavizado es obtenido promediando los valores de intensidad de los píxeles del entorno de la vecindad definida mediante una máscara de convolución. Una vez realizado esto calcula la magnitud y módulo del gradiente, obteniendo así dos imágenes.

2. Supresión no máxima al resultado del gradiente: una vez obtenida la imagen gradiente, utilizando ésta y la original se procede a generar una imagen con bordes adelgazados. Este proceso se realiza considerando cuatro direcciones, 0°, 45°, 90° y 135° respecto al eje horizontal. Para cada píxel se considera la dirección que mejor se aproxime a la dirección del ángulo gradiente. Si el valor de la magnitud del gradiente es menor que al menos uno de sus dos vecinos en dirección del ángulo obtenido se asigna valor 0 a dicho píxel, en caso contrario se asigna el valor que tenga la magnitud del gradiente. De esta forma se realiza el adelgazamiento de bordes.

3. Histéresis del umbral a la supresión no máxima: la imagen generada en el punto anterior suele contener máximos locales debidos al ruido. Para eliminar este efecto se aplica la técnica histéresis del umbral. Este proceso se basa en tomar la imagen generada en el punto anterior, obtener la orientación de los puntos pertenecientes al borde y tomar dos umbrales, siendo el primero de ellos menor que el segundo. Para cada punto de la imagen se debe localizar el siguiente punto del borde no explorado que sea mayor que el segundo umbral. A partir de dicho punto, se siguen las cadenas de máximos locales conectados en ambas direcciones perpendiculares a la normal del borde, siempre que sean mayores que el primer umbral. De esta manera se marcan todos los puntos explorados y se almacena la lista de todos los puntos del contorno conectado y se consigue eliminar las uniones con forma de Y de los segmentos que confluyen en un punto.

La principal ventaja de este método es su adaptabilidad para ser aplicado a diferentes tipos de imágenes. Además, su eficiencia no se ve afectada por la presencia de ruido en la imagen original. Su mayor inconveniente se da en el proceso de suavizado de la imagen, ya que se pueden difuminar ciertos bordes. A pesar de ello es uno de los mejores métodos de detección de bordes existentes, prueba de ello ha sido su aplicación en publicaciones como [PLK15].

2.2.4.3 **Operadores basados en la segunda derivada**

En cuanto a los operadores basados en la segunda derivada cabe destacar el laplaciano del gaussiano (LoG) y la diferencia de gaussianas (DoG). En los siguientes

apartados se realiza una descripción de los mismos.

Operador laplaciano

El operador laplaciano calcula la suma de las segundas derivadas en ambas direcciones siendo invariante a la rotación. La ecuación 2.30 define su representación matemática.

$$\Delta f = \nabla^2 f = \frac{\partial^2 f}{\partial x^2} + \frac{\partial^2 f}{\partial y^2} \tag{2.30}$$

El laplaciano tiene valor cero si $f(x, y)$ es constante o cambia de amplitud de forma lineal. Una de sus principales características es su capacidad de localizar bordes de una forma precisa mediante los cruces por cero obtenidos. Cuando una imagen presenta un cambio de intensidad relevante a lo largo de una dirección, existirá un máximo en la primera derivada a lo largo de dicha dirección, además de un paso por cero en la segunda derivada. Al tratarse de imágenes discretas, es poco probable que el paso por cero coincida de forma exacta en un píxel de la imagen, por este motivo se marca como borde aquel que contenga un nivel de gris más próximo a cero, teniendo al menos un píxel vecino con nivel de gris de signo contrario.

Como virtudes del laplaciano habría que destacar su excelente localización de bordes y su buena respuesta a bordes horizontales, verticales y diagonales, siempre que las aristas se encuentren bien separadas y la relación señal/ruido sea alta e independiente a la orientación del borde.

Sus inconvenientes son la sensibilidad al ruido, ya que se basa en el cálculo de la segunda derivada y que sufre de detección de bordes dobles debido a que la anchura de los bordes que genera no es siempre la óptima.

Existen distintas máscaras que realizan aproximaciones del laplaciano. A diferencia de las máscaras de los operadores de la primera derivada, éstas son simétricas respecto a la rotación. Se aplican seleccionando primero la máscara y realizando una operación de convolución sobre la imagen. El signo del resultado de dos píxeles adyacentes proporciona información direccional y del lado más oscuro. A continuación, en la ecuación 2.31 se muestran distintas máscaras para aplicar el operador laplaciano.

$$\begin{bmatrix} 0 & -1 & 0 \\ -1 & 4 & -1 \\ 0 & -1 & 0 \end{bmatrix} \quad \begin{bmatrix} 1 & -2 & 1 \\ -2 & 4 & -2 \\ 1 & -2 & 1 \end{bmatrix} \quad \begin{bmatrix} -1 & -1 & -1 \\ -1 & -8 & -1 \\ -1 & -1 & -1 \end{bmatrix} \tag{2.31}$$

Operador laplaciano del gaussiano (LoG)

El operador LoG fue propuesto por Marr y Hildreth [MH80] quienes introdujeron el concepto de detección de bordes mediante el método de cruces por cero. Consiste en aplicar el laplaciano a la imagen, una vez que ésta ha sido suavizada mediante un filtro gaussiano. Debido al difuminado de bordes que se genera en el suavizado, sólo se considerarán como bordes aquellos píxeles que formen un máximo local en la segunda derivada y que a su vez, el valor de la primera derivada supere un cierto umbral. De esta forma se evita la detección de bordes insignificantes.

El operador LoG calcula la segunda derivada de la imagen, por lo que en áreas con intensidad constante su respuesta será cero, sin embargo, en su vecindad la respuesta será positiva en el lado más oscuro y negativa en el más claro.

A pesar de ser un operador sensible al ruido, sus efectos pueden ser minimizados ignorando aquellos cruces por cero producidos por pequeños cambios de intensidad. Además, proporciona información sobre la dirección de los ejes mediante la dirección del cruce por cero.

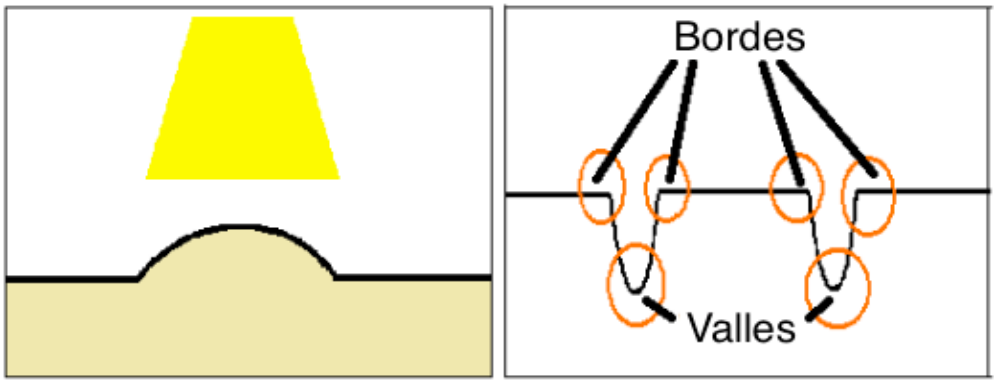
Diferencia de gaussianas (DoG)

Es posible realizar una aproximación al método LoG aplicando un operador de diferencia de gaussianas con múltiples desviaciones estándar, este es el método DoG. De igual forma que en el laplaciano, los cruces por cero suelen crear contornos cerrados, siendo esta característica muy útil para posteriores segmentaciones. Existe una gran variedad de métodos con mayor o menor grado de sofisticación capaces de determinar los cruces por cero con precisión a nivel de subpíxel, aunque estos pueden ser detectados de una forma simple y efectiva que se describe a continuación: un píxel se marca como cruce por cero si su valor en la imagen resultante de aplicar el operador LoG es menor que $-t$ y uno de sus vecinos es mayor que t, o al contrario, siendo t un umbral positivo.

La principal virtud es su simetría, por lo que es capaz de determinar bordes en todas las orientaciones, cosa que no ocurre en los operadores basados en la primera derivada. Como inconveniente está el coste computacional que requiere, además de su mal rendimiento en regiones donde se intersecan bordes con diferentes orientaciones, deformándose las esquinas y desconectándose bordes.

2.2.4.4 Técnica *depth of valleys* (DoV)

Cuando una fuente de luz incide sobre un objeto y la cámara se encuentra en la misma u opuesta dirección, éste suele aparecer rodeado de un valle de intensidad que genera los bordes asociados al objeto (véase figura 2.19). En la literatura científica existen infinidad de estudios que realizan una detección automática de objetos basándose en un detector de bordes, el cual nos determina la posición de los objetos mediante sus contornos, pero no de la intensidad de estos, que puede ser obtenida mediante el operador gradiente. Los autores de [BSV11a] proponen un nuevo método para la detección de objetos, combinando la aplicación de un detector de bordes y el operador gradiente morfológico. De esta forma, puntos en los que tenemos un borde y el valor del gradiente morfológico es alto, también lo será el valor de la profundidad, en cambio en los puntos en los que tenemos un valle pero el valor del gradiente morfológico es pequeño, la profundidad del valle será mínima. La ecua-



(a) (b)

Figura 2.19: Simulación del efecto de la iluminación sobre un objeto. a) Incidencia de la fuente de luz sobre el objeto. b) Valles de intensidad que rodean al objeto.

ción 2.32 muestra la formulación matemática del método DoV, donde V representa el operador de detección de bordes y MG el gradiente morfológico.

$$\forall i, j \in I \quad DV(i,j) = V(i,j) \cdot MG(i,j) \tag{2.32}$$

La idea que persiguen sus autores es complementar la información que provee el detector de bordes con la del gradiente morfológico.

Además de conseguir unos mejores resultados cuando maneja imágenes con mayor presencia de ruido, es muy útil en la detección de pólipos, ya que en muchas ocasiones, debido a su posición en la imagen, sobre todo en posiciones laterales, no se consiguen bordes completos con detectores de bordes, sin embargo la técnica DoV obtiene contornos completos.

A continuación, la tabla 2.10 presenta un resumen de las ventajas e inconvenientes de los diferentes métodos de detección de bordes.

Tabla 2.10: Comparativa de los métodos de detección de bordes descritos.

Operador	Ventajas	Inconvenientes
1º∂	Simplicidad. Cálculo de bordes y orientaciones.	Sensibilidad al ruido. Impreciso. No detectan bordes en todas las orientaciones.
Laplaciano	Cálculo de bordes y orientaciones.	Sensibilidad al ruido.
LoG	Preciso. Uso de una vecindad mayor.	Impreciso en bordes de intensidad variante. No calcula la orientación de los bordes.
DoG	Detección de bordes en cualquier orientación.	Alto coste computacional. Impreciso en intersecciones con diferente orientación.
Canny	Precisión. Buena relación señal ruido.	Alto coste computacional.
DoV	Preciso en imágenes ruidosas. Cálculo de la robustez del borde.	Alto coste computacional.

2.2.5 Métodos de segmentación

La segmentación de imágenes realiza una descomposición de éstas en sus partes constituyentes o regiones, es decir, objetos de interés y fondo. Para ello, los algoritmos de segmentación se basan en diversas características locales como por ejemplo: niveles de gris o textura, que en general son homogéneas para una región dada. La partición de la imagen que se realiza genera regiones homogéneas y disjuntas a partir de su contorno, conectividad o en términos de un conjunto de características de los píxeles de la imagen que permitan discriminar unas regiones de otras. En el caso que nos ocupa, se llevará a cabo una segmentación de imágenes colonoscópicas para la detección de pólipos y heces basándonos en diferentes particularidades de éstas.

Sea una región R que incluye a toda la imagen, se puede ver su segmentación como el proceso de dividir R en n subregiones $R_1, R_2...R_n$ cumpliéndose las siguientes condiciones:

1. $\bigcup_{i=1}^{n} R_i = R$
2. R_i es una región conectada, siendo $i = 1, 2, ..., n$
3. $R_i \bigcap R_j = \phi$ para todo i y j, $i \neq j$
4. $P(R_i) = Verdadero$ para $i = 1, 2, ..., n$
5. $P\left(R_i \bigcup R_j\right) = Falso$ para $i \neq j$

Donde $P(R_i)$ es un predicado lógico definido sobre los puntos del conjunto R_i y ϕ es el conjunto vacío.

La primera condición indica que la segmentación debe ser completa, es decir, todos los píxeles deben pertenecer a una región. La segunda condición obliga a que todos los píxeles de una región estén conectados. La tercera indica que las regiones deben ser disjuntas. La cuarta condición señala que todos los píxeles de una región deben satisfacer una cierta condición. Por último, la quinta indica que las regiones R_i y R_j son distintas según el criterio P.

Una vez expuestas las condiciones de las segmentaciones se realiza una revisión de los algoritmos más utilizados en PDI.

2.2.5.1 Segmentación mediante umbralización

La segmentación mediante umbralización es una de las principales técnicas para la detección de objetos. Se basa en la definición de un umbral, de forma que separe los objetos de interés del fondo. Para su aplicación es necesario que exista una clara diferencia entre los objetos y fondo de la escena. La técnica más utilizada se basa en la umbralización del histograma (véase figura 2.20) teniendo las siguientes posibilidades:

- Umbral único: se da cuando sólo hay dos regiones en la imagen y para separarlas se establece un único umbral. Este método se aplica en histogramas bimodales.
- Umbral multinivel: dada una imagen con múltiples objetos, para lograr su segmentación es necesario aplicar diferentes umbrales de forma que los píxeles que se encuentren entre cada par de umbrales T_i y T_j representarán un objeto.

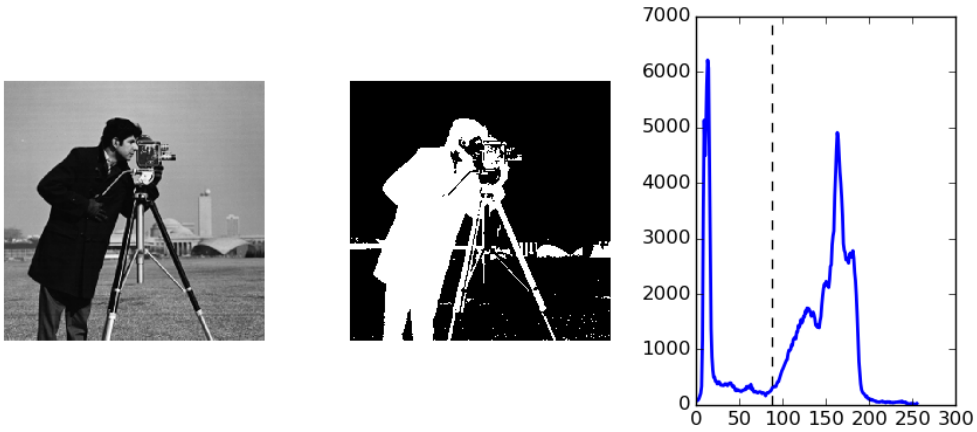


Figura 2.20: Umbralizado del histograma. Fuente: goo.gl/dJOnj5

La principal ventaja de este método es su simplicidad, pero requiere de imágenes con regiones bien diferenciadas para conseguir buenos resultados. Como se observa, es primordial la selección de un correcto umbral, siendo la técnica de Otsu [Ots75] una de las más empleadas para ello.

2.2.5.2 **Segmentación mediante crecimiento de regiones**

Los primeros métodos de segmentación por crecimiento de regiones estaban basados en el uso de semillas. Éstas marcan cada uno de los objetos que se pretenden segmentar en las imágenes, creciendo de forma iterativa mediante la comparación de todos los píxeles vecinos no asignados a ninguna región. La diferencia entre el valor de intensidad de un píxel y el de la media de la región δ se utiliza como medida de similitud. Cada píxel es asignado a la región con la que su diferencia respecto a la media es menor. Este proceso continúa hasta que todos los píxeles son asignados a alguna región. Los resultados de este tipo de segmentación dependen de la elección de las semillas, que en muchas ocasiones no quedan situadas de manera correcta debido al ruido en las imágenes. En la figura 2.21 se puede ver un ejemplo de esta técnica en la que la semilla se expande por los píxeles vecinos.

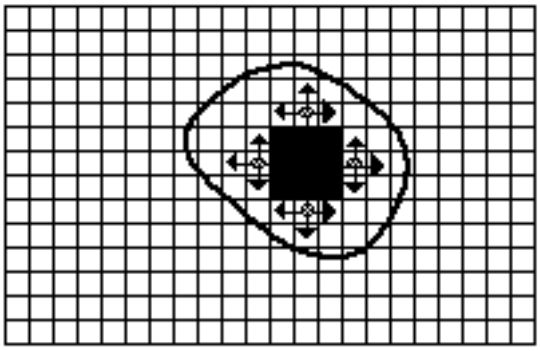


Figura 2.21: Crecimiento de regiones. Fuente: goo.gl/PDX7XQ

Más adelante se desarrollaron métodos de crecimiento de regiones sin semillas. Comienzan con una única región A_1 que contiene un único punto. En cada iteración se consideran todos los píxeles vecinos a esta región de la misma forma que en el caso de los algoritmos con semilla. La diferencia con estos estriba en que si el mínimo δ es menor que un umbral definido T, entonces se agrega a la región respectiva A_j, en caso contrario, el píxel se considera diferente a las regiones existentes y se crea una nueva región con ese píxel.

Una variante existente de este tipo de algoritmos fue propuesta en [HS85], la cual se basa en la intensidad de los píxeles. Se utilizan la media y dispersión de

la intensidad de una región para calcular un test estadístico. Si la significancia estadística es pequeña el píxel se asigna a la región volviéndose a calcular la media y dispersión de la región, de lo contrario, el píxel es rechazado y se utiliza para crear una nueva región.

2.2.5.3 **Segmentación mediante la división y fusión de regiones**

Los métodos de segmentación mediante la división y fusión de regiones comienzan con una división inicial de la imagen en un conjunto de regiones arbitrarias disjuntas. Con posterioridad pueden ser fusionadas y/o divididas con el objetivo de satisfacer ciertas condiciones. La figura 2.22 muestra una representación gráfica de una segmentación mediante la división y fusión de regiones.

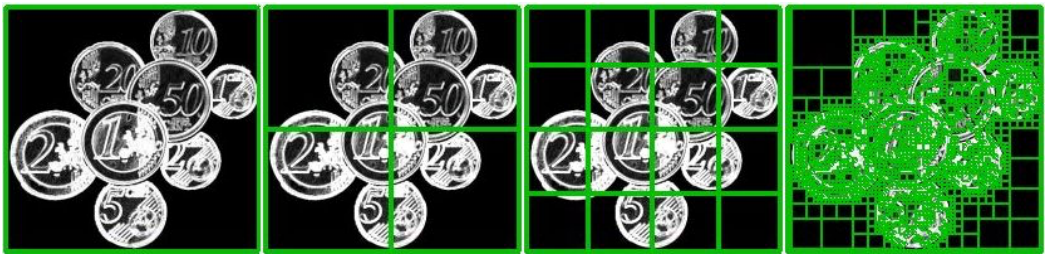


Figura 2.22: División y fusión de regiones. Fuente: goo.gl/ddYtNF

Dada una región R que corresponde a la imagen inicial completa y un predicado P, suponiendo que la imagen es cuadrada, su segmentación consiste en la división sucesiva en regiones cuadradas cada vez más pequeñas de forma que para cualquier región R_i, $P(R_i)$ sea $Verdadero$. El procedimiento comienza con la región R, si $P(R)$ es $Falso$ se divide la imagen en cuadrantes. Si P es $Falso$ para algún cuadrante, subdividimos ese cuadrante en subcuadrantes y así de modo sucesivo.

Si se usase con exclusividad la división, la partición final estaría formada por regiones adyacentes con idénticas propiedades. Esto se puede evitar utilizando la fusión. Para cumplir con las condiciones de segmentación sólo se fusionarán regiones adyacentes cuyos píxeles combinados satisfagan el predicado P, es decir, se fusionarán las regiones R_i y R_j sólo si $P(R_i \bigcup R_j) = Verdadero$. El procedimiento anterior se resume de la siguiente forma:

1. Dividir en cuatro cuadrantes disjuntos aquellas regiones para las que $P(R_i) = Falso$.

2. Fusionar las regiones adyacentes R_i y R_j para las que $P(R_i \bigcup R_j) = Verdadero$.

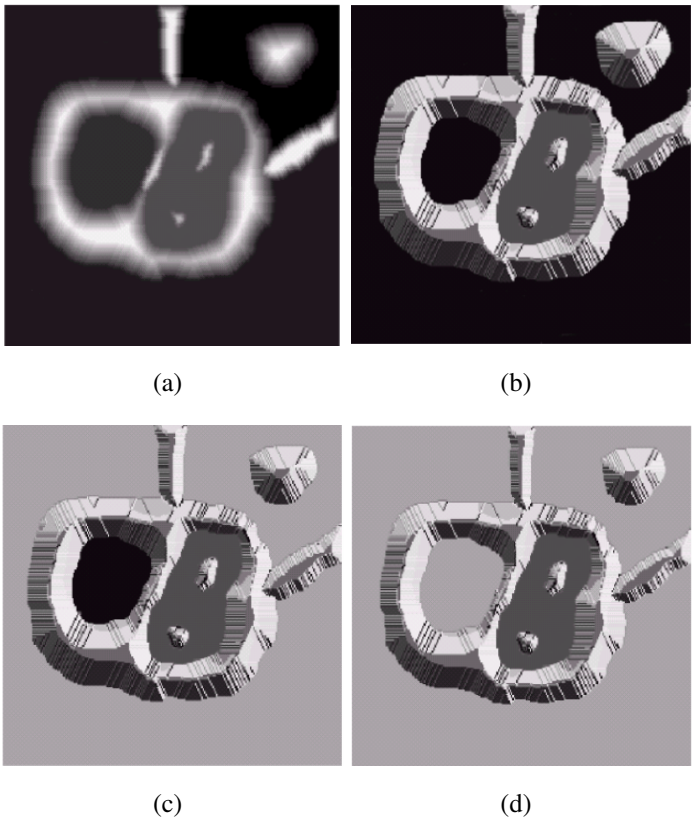
3. Parar cuando no sea posible realizar más fusiones ni divisiones.

2.2.5.4 **Transformación watershed**

La transformada watershed [VS91] es un método de segmentación basado en regiones que clasifica los píxeles según su proximidad espacial, el gradiente de sus niveles de gris y la homogeneidad de sus texturas. Una imagen en escala de grises puede interpretarse como una imagen topográfica, de forma que las intensidades de gris de mayor amplitud se corresponden con llanuras o montañas, mientras que las intensidades de menor valor se corresponden con valles y ríos. A partir de estas características de las imágenes se define la transformada watershed. Mediante la inundación de los valles detecta los contornos de zonas topográficas similares rodeadas por cadenas montañosas. En la figura 2.23 se muestran los conceptos básicos de este tipo de segmentación.

Con el objetivo de segmentar una imagen en niveles de gris, previo a la aplicación del método watershed, a través del gradiente se obtiene una imagen donde los niveles de los contornos de los objetos a segmentar representan una zona de elevada intensidad de gris. Las zonas de baja intensidad dan lugar a los valles por donde fluirá el agua inundando la topografía de la imagen. Las elevaciones en los niveles de gris generadas por los contornos darán lugar a la segmentación de la imagen mediante las lineas watershed resultantes.

Esta técnica inunda la imagen gradiente a partir de sus mínimos regionales. En el caso de imágenes no homogéneas o con ruido, no existe un mínimo regional para cada objeto de interés. Esto hace que se produzca una sobresegmentación. Para evitar este inconveniente se recurre a la definición de marcadores unívocos para cada uno de los objetos de interés. Estos marcadores o semillas inician los algoritmos de inundación indicando los sectores que darán lugar a los valles. Por todo esto, el buen funcionamiento de esta técnica depende de manera primordial de las características de los marcadores.



(a) (b)

(c) (d)

Figura 2.23: Segmentación mediante el algoritmo watershed. a) Imagen original. b) Vista topográfica. c) Inicio de la inundación. d) Fin de la inundación. Fuente: goo.gl/W52Gpq

2.2.5.5 **Algoritmo *fast marching***

Fast marching [Set99] es un algoritmo que expande o contrae bordes de una región respecto a una función de velocidad, pudiéndose definir criterios de parada para limitar el crecimiento. Se trata de un método numérico que proporciona soluciones aproximadas a las ecuaciones eikonales que se muestran en la ecuación 2.33.

$$\begin{gathered} \|\nabla u(x)\| = F(x) \in D, F(x) > 0 \\ u = g(x) \in S \end{gathered} \tag{2.33}$$

Donde el dominio D en R^n compone los N puntos cartesianos de n dimensiones. $F(x)$ es una función conocida que provee las condiciones iniciales de frontera del espacio o plano, y u es igual a la función conocida $g(x)$ dada a través de la curva o superficie S en D. El algoritmo *fast marching* utiliza aproximaciones diferenciales infinitas para los operadores de la función eikonal, de esta forma selecciona

la solución correcta. El dominio D en R_n compone los N puntos cartesianos n-dimensionales y $F(x)$ es una función conocida que provee las condiciones iniciales de frontera del espacio o plano. La figura 2.24 muestra el funcionamiento de este algoritmo.

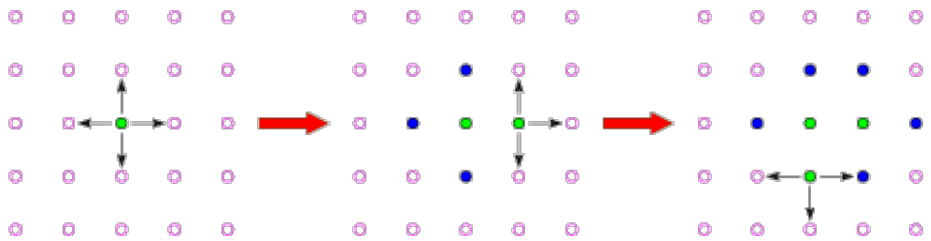


Figura 2.24: Segmentación mediante *fast marching*. Fuente: goo.gl/SDs3tJ

2.2.5.6 Segmentación mediante modelos deformables

El término modelos deformables (*snakes*) (véase figura 2.25) apareció en 1988 en la investigación [TF88], aunque la idea de deformar una figura para encontrar formas en una imagen surgió años antes. Los modelos deformables son curvas o superficies que definidas dentro de una imagen se deforman bajo la influencia de fuerzas internas o externas.

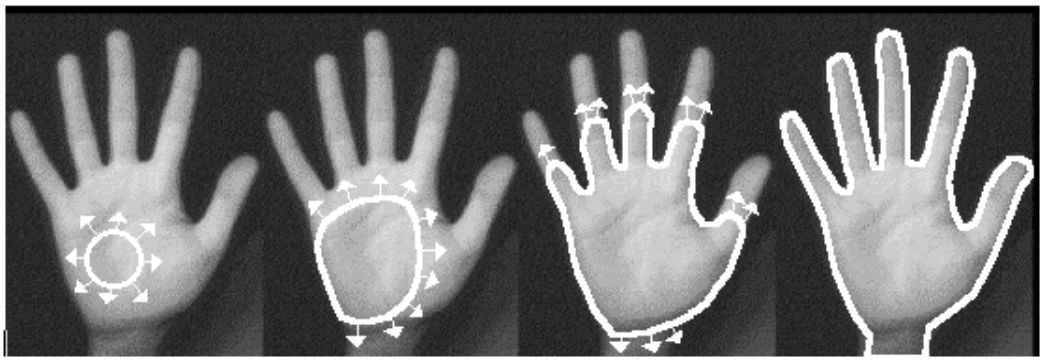


Figura 2.25: Segmentación mediante modelos deformables. Fuente: goo.gl/8wDO1F

Las fuerzas internas están determinadas por la geometría de la curva o superficie deformable y se usan para conservar la estructura del modelo deformable. También define la tensión y rigidez del modelo. Las fuerzas externas están determinadas por

la información de la imagen en la que se encuentra el modelo y se usan para mover el modelo hacia los bordes de un objeto o forma. Este término toma valores más pequeños en los bordes de los objetos o figuras de interés para la deformación del modelo. Están basados en la minimización de energía, que busca una curva en la imagen que minimice la suma de fuerzas internas y externas ejercidas sobre el modelo deformable. Para que el modelo deformable detecte el borde de una figura se inicializa en el interior de la imagen y durante el proceso es forzado a moverse hacia la mínima energía potencial. La formulación matemática de un modelo deformable se define en la ecuación 2.34.

$$X(s) = (X(s), (Y(s)), s \in [0, 1] \tag{2.34}$$

Esta curva se mueve a través de la imagen con el fin de minimizar la ecuación de energía 2.35.

$$\epsilon(X) = S(X) + P(X) \tag{2.35}$$

Donde $S(X)$ define la fuerza interna y el $P(X)$ la fuerza externa. La función que define este segundo término es seleccionada según la naturaleza, forma y color de los objetos de interés que haya en la imagen.

2.2.5.7 **Segmentación mediante clasificadores**

Los clasificadores son técnicas de reconocimiento de patrones que buscan dividir el espacio característico de una imagen usando datos con etiquetas conocidas. Un espacio característico es un rango espacial de cualquier función de la imagen, siendo la intensidad de la imagen el más común de los espacios característicos. Un histograma es un ejemplo de un espacio característico unidimensional.

Los clasificadores supervisados utilizan datos de entrenamiento que son obtenidos mediante la segmentación manual de la imagen y que más tarde son usados en la segmentación automática de nuevos datos.

Los clasificadores requieren que la estructura a ser segmentada posea características cuantificables y distintas. Debido a que los datos de entrenamiento pueden ser etiquetados, los clasificadores transfieren estas etiquetas a los nuevos datos siempre que el espacio característico distinga cada etiqueta de una forma clara. No

actúan de forma iterativa, por lo que son eficientes respecto a su coste computacional, esto hace que puedan ser aplicados a imágenes multicanal. Sus principales inconvenientes son que no obedecen a ningún modelo espacial y que requieren de interacción manual para obtener los datos de entrenamiento. Los conjuntos de entrenamiento pueden ser adquiridos para cada imagen que requiera segmentación, pero esto puede tomar mucho tiempo y esfuerzo. Además, el uso del mismo conjunto de entrenamiento para un gran número de imágenes puede llevar a resultados viciados.

2.2.5.8 **Segmentación mediante técnicas de agrupamiento**

Los algoritmos de agrupamiento (*clustering*) llevan a cabo la misma función que los métodos clasificadores pero sin realizar un entrenamiento previo. Por lo tanto, son métodos no supervisados. Para compensar la falta de los datos de entrenamiento, los métodos de agrupamiento iteran entre segmentar la imagen y caracterizar las propiedades de cada clase. En este sentido, los métodos de agrupamiento se entrenan a si mismos usando los datos disponibles. Un algoritmo de agrupamiento común es el algoritmo *K-Means* o el algoritmo *iterative self-organizing data analysis technique yAy!* (ISODATA). Estos métodos agrupan datos calculando de modo iterativo la media de la intensidad para cada clase, segmentando la imagen mediante la clasificación de cada píxel en la clase con la media más cercana.

Aunque no requieren ser entrenados, es necesaria una segmentación inicial (o de manera equivalente, requieren parámetros iniciales). Como los métodos de clasificación, los algoritmos de agrupamiento no incorporan un modelo espacial de forma explícita, aunque pueden proveer ventajas significativas para realizar los cálculos con velocidad.

En la tabla 2.11 se hace una comparativa de las técnicas de segmentación descritas, teniendo en cuenta sus ventajas, inconvenientes, aplicación y velocidad de ejecución.

Tabla 2.11: Comparativa de los métodos de segmentación descritos.

Método	Ventajas	Inconvenientes	Aplicaciones	Velocidad
Umbralización	Rapidez y simpleza.	Mala respuesta a artefactos. Regiones no continuas.	Imágenes con intensidades diferenciadas.	Muy rápida.
Crecimiento de regiones	Buena respuesta ante artefactos. Regiones continuas.	Eficacia determinada por los puntos de inicio elegidos.	Imágenes con buen contraste.	Rápida.
División y fusión	Simpleza y baja complejidad computacional.	Requiere el ajuste de parámetros. No asegura una buena precisión.	Reconocimiento de objetos y análisis de imágenes médicas.	Rápida.
Transformada watershed	Precisión. Regiones continuas.	Sobresegmentación.	Imágenes con poco ruido y artefactos.	Media.
Fast Marching	No requiere puntos de inicio. Buena de detección de contornos agudos. Eficiencia.	Añade una nueva dimensión al problema.	Segmentación de imágenes médicas.	Alta.
Modelos deformables	Buena respuesta a artefactos y precisión. Regiones continuas.	Requiere el ajuste de parámetros.	Buen funcionamiento con información estadística de la imagen.	Media.
Clasificadores	Los más utilizados.	Alto coste computacional y lentos.	Muy usadas en imágenes por resonancia magnética y tomografía computerizada.	Baja.
Agrupamiento	Fácil implementación. Pueden utilizarse para determinar puntos de inicio de otros métodos.	Requieren restricciones espaciales.	Usadas en imágenes por resonancia magnética.	Media.

2.2.6 Técnicas de evaluación de la calidad de ejecución de la colonoscopia

La colonoscopia es el método de cribado más utilizado para la detección de CCR o sus lesiones precursoras, los pólipos colorrectales. Es un hecho que la colonoscopia ha contribuido en la disminución del número de muertes relacionadas con el CCR, sin embargo, no todas las lesiones en forma de cáncer o pólipos se detectan en el momento de la colonoscopia. Por este motivo, es necesario contar con métodos que investiguen porqué ocurre esto. Por otra parte, al ser una prueba tan extendida, es necesario contar con herramientas para medir su calidad, de forma que se pueda conseguir una mejora constante.

Uno de los problemas más graves que se pueden dar en la realización de una colonoscopia es el **cáncer de intervalo**. El cáncer de intervalo es aquel que se desarrolla entre dos pruebas colonoscópicas programadas y con frecuencia suele deberse a la no visualización de una lesión precursora de cáncer, siendo esto la consecuencia de una mala calidad de la ejecución.

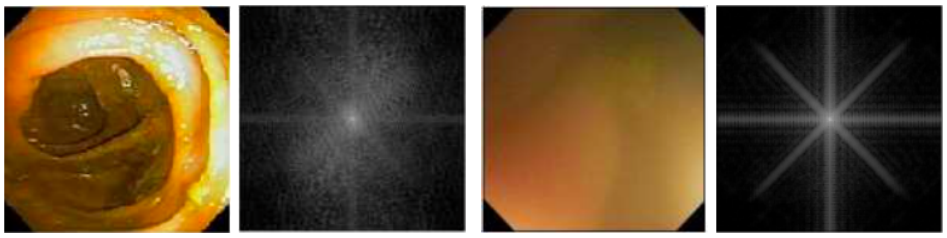
Son varios los factores que afectan a la calidad de la colonoscopia, desde la preparación del colon del paciente, quien debe seguir una dieta los días previos a la prueba para liberar el colon de heces, a la destreza del especialista. En este apartado se aborda esta problemática definiendo las variables que indican la calidad de estas pruebas, describiendo las publicaciones científicas más relevantes en este ámbito.

En el apartado 2.1.8 ≪Evaluación de la calidad de ejecución de la colonoscopia≫ se han reseñado diversas variables para la determinación de la calidad de ejecución de la colonoscopia propuestas por la ASGE y la ESGE. A continuación se describen las publicaciones científicas más relevantes relacionadas con estos indicadores.

La investigación [OHC+09] propone un método para el cálculo automático del tiempo de inserción y extracción, obtención de la imagen de máxima intubación y el ratio de imágenes claras y borrosas. Se trata de la continuación del trabajo [HOL+05] en el que presentan el siguiente procedimiento:

1. Filtrado de imágenes borrosas: las imágenes borrosas no proporcionan ninguna información útil, por ello son descartadas. Entre un 37 y 60 % de las

imágenes de un video colonoscópico son consideradas borrosas. Su distinción es realizada mediante un análisis frecuencial y de textura. El análisis frecuencial se realiza mediante la transformada de Fourier, la cual genera diferentes patrones en imágenes borrosas y claras, un ejemplo de ello se puede ver en las imágenes 2.26(b) y 2.26(d) de la figura 2.26. El análisis de la textura se realiza mediante las matrices de co-ocurrencia, calculando la entropía, contraste, correlación, homogeneidad, segundo momento angular y energía, introduciendo el vector de características en un clasificador *K-Means*. Este área de investigación está cobrando cada vez más relevancia en el análisis de video, ya que éste requiere de una mayor eficiencia. En este sentido, la investigación [MWTH13] realiza una clasificación de fotogramas realizando un análisis de la textura.



(a) (b) (c) (d)

Figura 2.26: Clasificación de imágenes colonoscópicas en claras y borrosas mediante su análisis frecuencial. a) Imagen clara. b) Patrón de Fourier para una imagen clara. c) Imagen borrosa. d) Patrón de Fourier para una imagen borrosa.

2. Estimación de los movimientos de la cámara: el formato de vídeo utilizado es MPEG del cual utilizan los vectores de movimiento para este propósito.

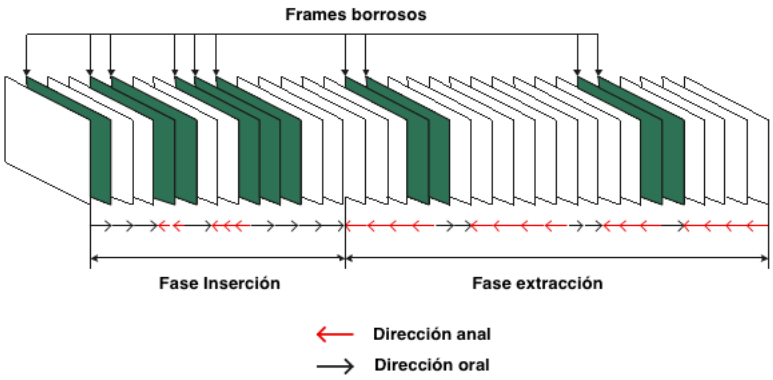
3. Segmentación del vídeo: el movimiento del colonoscopio en la intervención es en dos direcciones, oral en la introducción y anal en la extracción. La fase de introducción del colonoscopio esta compuesta por una combinación de movimientos en dirección oral y anal en los cuales predominan los movimientos orales, lo contrario ocurre en la fase de extracción. La detección del momento de máxima intubación, en el cual se cambia desde la fase de introducción a la de extracción, la realizan buscando el punto máximo de

movimientos. En la figura 2.27 se hace una representación gráfica de este procedimiento.

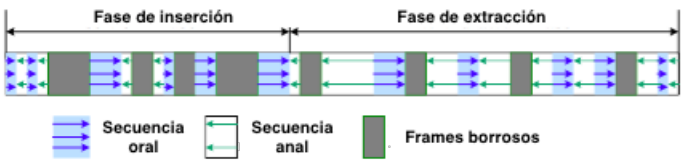
4. Identificación del lumen: realizan una identificación del lumen, ya que la aparición de éste determinará el tipo de imagen que se está capturando. En caso de aparición del lumen, se trata de una vista general, en cambio, su ausencia determina una vista en detalle. A partir de ello calculan los indicadores de las ecuaciones 2.36 y 2.37.

$$Ratio\ inspecciones\ lumen\ pared = \frac{Vistas\ de\ pared}{Vistas\ de\ Lumen} \tag{2.36}$$

$$Ratio\ inspecciones\ pared = \frac{Vistas\ de\ pared}{Imágenes\ claras} \tag{2.37}$$



(a)



(b)

Figura 2.27: Descomposición de los movimientos de inserción y extracción de la colonoscopia. a) Fases de inserción y extracción. b) Segmentación de la colonoscopia.

Por otra parte, es de vital importancia determinar la relación existente entre los diferentes indicadores propuestos y su eficiencia real. En este sentido el trabajo [KRK+10] realiza un análisis estadístico para ver el buen desempeño de la tasa de detección de adenomas e intubación cecal. Para ello proponen la aplicación de la regresión de Cox [Cox72], que permite comprobar la relación de estos dos indicadores con el cáncer de intervalo. Los resultados obtenidos fueron que la tasa de detección de adenomas tenía una significancia estadística de p = 0.008, por lo que su relevancia queda contrastada, en cambio la tasa de intubación cecal obtuvo una significancia de p = 0.5. Gracias a esta publicación se ha podido determinar la validez de estos dos indicadores, aportando una valiosa información a la comunidad científica.

Siguiendo con otro indicador, la preparación del colon del paciente, la investigación [CTS+15] trata de determinar la relación existente entre la preparación del colon del paciente evaluada con la ELCB y la tasa de detección de adenomas y pólipos. La mala preparación del colon es una problemática que genera un mayor tiempo de exploración, mayores tasas de repetición de las colonoscopias, mayores costes y lo que es más importante, una mayor tasa de lesiones perdidas debido a la mala visualización conseguida por la presencia de heces. Es por ello que realizan un análisis estadístico para ver cómo afecta la preparación del colon del paciente en estos indicadores. El estadístico utilizado es χ^2 con el cual han obtenido unos singulares resultados:

- La tasa de detección de adenomas y pólipos para colonoscopias con una puntuación de entre 6 y 8 es mayor que en las que obtienen una puntuación de 9.

- Para pólipos de tamaño mayor a 9 mm la tasa de detección de pólipos en colonoscopias con una puntuación de 6 es mayor que para colonoscopias con una puntuación de 9.

Estos resultados revelan que las grabaciones con una preparación buena o aceptable (de 6 a 8 puntos) según la ELCB obtienen mayores tasas de detección de adenomas y pólipos que aquellas con una valoración excelente (9 puntos).

Continuando con la calidad de preparación del colon del paciente, los autores de [HOT+08] proponen un método para la detección automática de heces en las

colonoscopias. De esta forma se permite la evaluación automática de la preparación del colon, evitando la problemática de la variabilidad interobservador. Para ello proponen un enfoque basado en algoritmos de aprendizaje automático que realizan una extracción de características de color mediante su histograma, aplicando un clasificador de tipo máquina de soporte vectorial (SVM) [CV95] para detectar las heces. El proceso realizado es el siguiente:

1. Selección de datos de entrenamiento: extraen de imágenes colonoscópicas regiones con heces a fin de realizar un entrenamiento del clasificador.

2. Extracción de características: realizan una extracción de características de las regiones extraídas en el punto anterior.

3. Entrenamiento del clasificador: entrenamiento del clasificador con las características de las regiones seleccionadas para el entrenamiento.

4. Prueba del clasificador: prueba de rendimiento del clasificador entrenado con el fin de comprobar la eficacia del método.

Mediante este método se hace posible la detección automática de heces en las colonoscopias permitiendo la evaluación de la calidad de preparación. En esta investigación consideraron mal preparadas aquellas imágenes con más de un 5 % de heces.

2.2.7 Resumen de las publicaciones para la evaluación de la calidad de ejecución de la colonoscopia

A continuación se muestra en la tabla 2.12 un resumen de las publicaciones más relevantes descritas en los apartados 2.1.8 ≪Evaluación de la calidad de ejecución de la colonoscopia≫ y 2.2.6 ≪Técnicas de evaluación de la calidad de ejecución de la colonoscopia≫.

Tabla 2.12: Resumen de las publicaciones de evaluación de la calidad de ejecución de la colonoscopia descritas.

Publicación	Método	Año
[CTS+15]	Relación entre la calidad de preparación según la ELCB y la tasa de detección de adenomas.	2015
[MWTH13]	Clasificación de fotogramas en función de su definición.	2013
[MOT+12]	Cálculo automático de la ELCB.	2012
[ARGF+12]	Cálculo automático de la ELCO.	2012
[KRK+10]	Análisis de la relación entre la tasa de detección de adenomas y la intubación cecal.	2010
[OHC+09]	Determinación de la máxima intubación. Ratio entre imágenes claras y borrosas.	2009
[HOL+05]	Cálculo automático del tiempo de inserción y extracción.	2005

2.2.8 Técnicas de detección automática de pólipos

El principal objetivo que se persigue en la realización de las colonoscopias es comprobar el estado del colon mediante la búsqueda de posibles lesiones en él. Ésta es una tarea laboriosa para los especialistas, a los que se pretende ofrecer herramientas de apoyo. El principal problema de los algoritmos de detección automática de pólipos es la diversidad forma y ubicación de los mismos, que dificultan el desarrollo de métodos eficaces.

En este apartado se describirán las técnicas de detección automática de pólipos más utilizadas en la literatura. A grandes rasgos existen tres enfoques: análisis de forma, textura y color. A continuación se realiza una descripción de cada una de ellas, haciendo referencia a las publicaciones más relevantes.

2.2.8.1 Detección de pólipos mediante el análisis de la forma

El análisis de forma se basa en la observación de la estructura de los pólipos y cómo estos aparecen en las imágenes o vídeos colonoscópicos para tratar de buscar sus formas más comunes. De manera general los pólipos tienen forma sésil o pediculada, aunque no siempre es posible obtener una imagen perfecta del pólipo, por lo

que se dificulta la detección. Por este motivo, muchas de las técnicas no se basan en la detección de formas completas de pólipos, sino que tratan de detectar zonas de la imagen susceptibles de contener un pólipo. Dentro de este grupo de técnicas destacan el análisis de la curvatura y el ajuste de elipses. Éstas se describen a continuación.

Detección de pólipos mediante el análisis de la curvatura

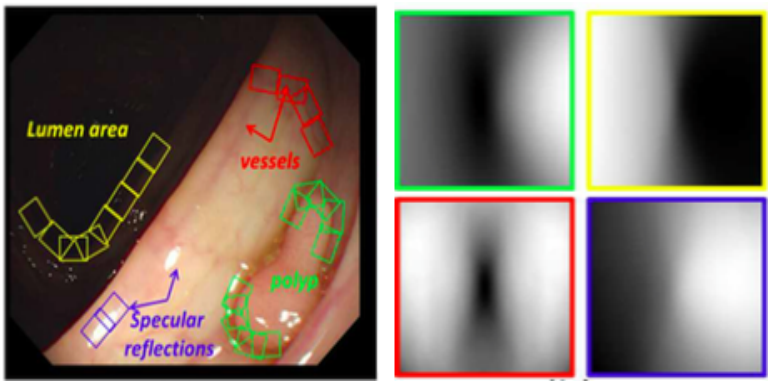
El análisis de la curvatura es utilizado para evaluar superficies en cuanto a su suavidad, continuidad y otras propiedades importantes. Mediante la aplicación de esta técnica es posible obtener patrones de curvatura de los pólipos, lo que permite su detección automática. Dada su eficacia, este enfoque ha sido muy utilizado en la literatura. A continuación se realiza una breve descripción de las publicaciones más relevantes que se basan en esta técnica.

Los estudios [KYC+98] y [JLC+06] presentan una detección automática de pólipos basada en el análisis de la curvatura de los contornos de las imágenes, extraídos en un paso anterior mediante un detector de bordes. Por otro lado [ZFL11] expone una investigación basada en el análisis de la curvatura de las formas locales en la pared del colon. Esta técnica presenta dos inconvenientes, en primer lugar, da pie a cálculos erróneos de la curvatura cuando el núcleo tiene dos superficies y en segundo lugar, aquellas curvaturas que aparecen discontinuas no obtienen resultados concluyentes.

Una alternativa diferente ha sido propuesta en los trabajos [VWVRVVV10] y [TGL13], donde se presentan sendos métodos de detección automática y segmentación de pólipos basándose en si estos son protruidos y en qué grado. Para ello aplican el segundo flujo de la curvatura principal que elimina los elementos salientes en las curvas de dos dimensiones. Un enfoque similar a éste es el utilizado por las investigaciones [HSH05], [FPTF10] y [CBD12] que analizan la curvatura de la imagen de una forma similar a un mapa topográfico con la intención de detectar zonas candidatas a contener pólipos.

Por otra parte, las investigaciones [TCGL14] y [TGL15] han propuesto sendos métodos para la detección automática de pólipos realizando un análisis de los bordes detectados en la imagen. Se realiza un reconocimiento de los elementos de una

imagen colonoscópica en función de la tonalidad de color que se presenta a ambos lados del borde detectado. Para ello generan un vector normal al borde detectado, construyendo unas casillas sobre estos con un solapamiento del 50 % como se muestra en la figura 2.28, donde la imagen 2.28(a) muestra el encasillado de los bordes de los diferentes elementos colonoscópicos y la figura 2.28(b) presenta los patrones de los elementos colonoscópicos, correspondiéndose de izquierda a derecha y de arriba abajo con: pólipo, lumen, vaso sanguíneo y reflejos especulares.



(a) (b)

Figura 2.28: Identificación de los elementos del colon mediante patrones de encasillamiento. a) Elementos de una imagen colonoscópica encasillados. b) Patrones de los diferentes elementos colonoscópicos.

La aplicación de este método hace posible la clasificación de los diferentes elementos presentes en las imágenes colonoscópicas de una forma novedosa, consiguiendo unos resultados satisfactorios.

Detección de pólipos mediante el ajuste de superficies

La idea principal del ajuste de superficies es encajar diferentes formas geométricas sobre los pólipos. En la detección automática de pólipos se utilizan elipses debido a que ambos presentan contornos similares, aunque como ya se ha comentado son muy variantes en forma, lo que dificulta su identificación.

El ajuste de elipses ha sido utilizado en el trabajo de los autores de [KD03] en el que se realiza una detección de bordes en los canales R, G y B para después

ajustar diferentes tipos de elipses en ellos. Para clasificar las regiones de la imagen se basan también en el área y el color.

Combinación de los análisis de la curvatura y ajuste de elipses

La gran variabilidad de forma de los pólipos hace que la eficiencia de la aplicación independiente del análisis de la curvatura y el ajuste de elipses tenga una eficacia limitada, por este motivo una opción es utilizar ambas para lograr mejores resultados. Este enfoque ha sido utilizado por los autores de [HOT+07] obteniendo excelentes resultados.

Detección de pólipos mediante la acumulación en imágenes DoV

Los autores del trabajo [BSV11a] desarrollaron una serie de métodos para la detección automática de pólipos basándose en la acumulación DoV (véase apartado 2.2.4.4 ≪Técnica *depth of valleys*≫) . Su primer trabajo denominado *ellipse fitting depth of valleys accumulation* (EF-DOVA) se describe en cinco pasos:

1. Selección del punto de inicio: se tomará como punto de inicio tanto el valor mínimo en la imagen DoV como el valor mínimo en la imagen de detección de bordes.

2. Cálculo de los ejes de la elipse: a partir del punto de inicio calculado se realiza una búsqueda del valor máximo de la imagen DoV en las direcciones X e Y. La posición de estos máximos determinará los ejes de la elipse que queremos ajustar.

3. Cálculo de los puntos de la elipse: se pretende que la elipse a ajustar coincida como mínimo en una cantidad determinada de puntos con los bordes generados en la imagen DoV. Esta cantidad se determina mediante un umbral. Para ello consideran 8 direcciones que van desde $\Theta = 0$ a $\Theta = 360$ separados por $\Theta = 45$. El cálculo de los puntos se realiza mediante la ecuación 2.38.

$$\begin{aligned} \frac{x^2}{a^2} + \frac{y^2}{b^2} = 1;\ y = tan\theta \cdot x; \\ x = \frac{a \cdot b}{\sqrt{a^2 \cdot m^2 + b^2}};\ y = tan\theta \cdot \frac{a \cdot b}{\sqrt{a^2 \cdot m^2 + b^2}}; \end{aligned} \tag{2.38}$$

4. Obtención de la vecindad de búsqueda: una vez obtenidos los 8 puntos de la elipse se define la vecindad de cada uno de ellos en la que se buscarán los máximos de DoV.

5. Acumulación: contaremos el número de vecindades que coinciden con máximos de DoV.

La imagen 2.29 describe los diferentes pasos del algoritmo descrito ayudando a su correcta interpretación.

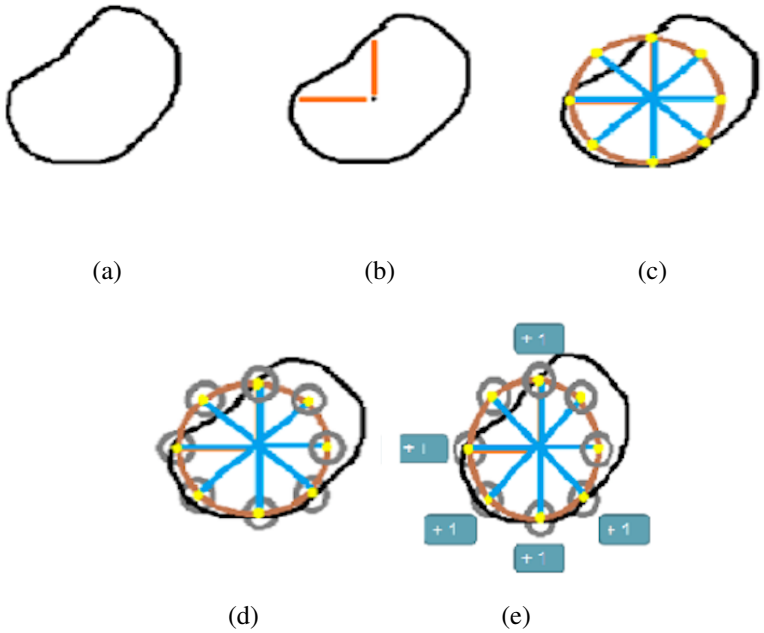


Figura 2.29: Pasos del algoritmo EF-DOVA. a) Selección del punto de inicio. b) Cálculo de los ejes de la elipse. c) Cálculo de los puntos de la elipse. d) Obtención de la vecindad. e) Acumulación.

Más adelante este mismo grupo de investigación publicó el trabajo [BSV12b], en el que presentaban el método denominado *sector accumulation depth of valleys accumulation* (SA-DOVA). Este algoritmo pretende detectar qué píxeles de una imagen están en el interior de un objeto. Para ello, tiene como principio que cualquiera de los píxeles interiores a un objeto debe estar rodeado de un borde que corresponde a altos valores en imágenes DoV. Para conseguir su objetivo realizan

una acumulación de los bordes de la imagen DoV. A diferencia de EF-DOVA, en este caso no sólo se buscan objetos con forma de elipse. Su funcionamiento se describe en los siguientes tres pasos:

1. Selección de un punto de inicio: se acumulan los valores de DoV para cada píxel.

2. Creación de los sectores circulares: para realizar la acumulación de los valores de la imagen DoV se generan unos sectores circulares alrededor de cada píxel de la imagen. Los sectores vienen definidos por su diámetro mínimo, máximo y número de sectores.

3. Acumulación: la acumulación de los sectores se realiza en base a la ecuación 2.39. Para cada sector se acumulará el valor de DoV máximo de su interior.

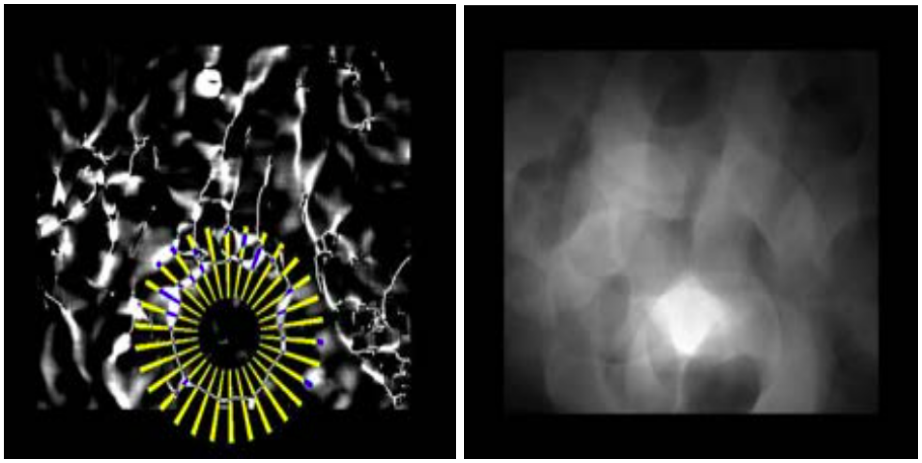
$$Acc(x) = \int_{\alpha=0}^{\alpha=2\pi} max_{r\epsilon[R_{min},R_{max}]} V(x + r \cdot (cos(\alpha), sin(\alpha)))dx \qquad (2.39)$$

Donde V es la imagen de bordes, R_{min} y R_{max} definen el área donde son buscados los máximos y α permite la integración angular de los máximos en todas las direcciones.

En la figura 2.30 se muestra una representación gráfica de la creación de los sectores circulares y la acumulación del algoritmo SA-DOVA.

El método SA-DOVA obtiene unos buenos resultados en la detección automática de pólipos gracias a la utilización de la imagen DoV como base y a ser invariante a la rotación de los objetos. Esto ha sido conseguido mediante la creación de los sectores circulares. Como desventaja, se puede destacar su sensibilidad a imágenes ruidosas o con artefactos, además de no tener en cuenta la orientación de los puntos con valor de DoV máximo.

En estudios posteriores estos autores mejoraron la baja eficiencia en imágenes ruidosas de SA-DOVA presentando el algoritmo *maximum sector accumulation depth of valleys accumulation* (MSA-DOVA) [BNSV14]. Este método soluciona en gran medida su ejecución en entornos ruidosos, aplicando la mediana en vez de la acumulación. Por otra parte, también desarrollaron el método *vector orientation depth of valleys accumulation* (VO-DOVA) [BSV12a] que tenía en cuenta la orientación de los máximos de DoV en los sectores. En este caso sólo son acumulados



(a) (b)

Figura 2.30: Pasos del algoritmo SA-DOVA. a) Cálculo de los sectores circulares. b) Acumulación de los sectores.

aquellos valores cuya orientación está dentro de un rango establecido. La imagen 2.31 hace una descripción visual del algoritmo, mostrando cómo los vectores de color verde son acumulados y los azules descartados.

Por último, en la investigación [BSFE+15] presentan una evolución de los métodos EF-DOVA, SA-DOVA, MSA-DOVA y VO-DOVA. Éste fue denominado *window median depth of valleys accumulation* (WM-DOVA) y realiza una eficaz detección automática de pólipos basándose en cuatro principios:

1. Completitud: un píxel interior a un pólipo debe estar rodeado por un borde competo. Para realizar esta comprobación realizan una acumulación de la imagen DoV mediante sectores radiales.

2. Robustez: se consideran más importantes aquellos bordes con bajo valor de acumulación DoV que se extiendan en la mayoría de las direcciones que aquellos con un alto valor de acumulación pero concentrados en pocas direcciones.

3. Continuidad: se favorece a aquellos bordes que aparecen de forma continua frente aquellos que no.

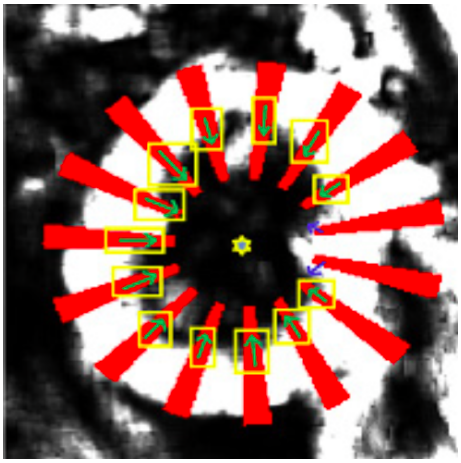


Figura 2.31: Acumulación de los sectores en función de la orientación de los máximos.

4. Concavidad: para un punto interior al pólipo los bordes deben tener una forma cóncava.

A continuación, en la figura 2.32 se puede ver una representación gráfica de los principios que sustentan a este algoritmo.

Para cada píxel de una imagen, el algoritmo WM-DOVA determina el número de sectores $(2w_s + 1)$ a utilizar y realiza el siguiente proceso:

1. Cálculo de los máximos en cada sector: para cada sector S_i calcula:

   a) $S_i^max = max_{si}(DV)$.

   b) $p_{si}^{max} = argmax_{si}(DV)$ como posición del valor máximo de DoV en el sector S_i.

   c) $d_i = dist(p, p_{si}^{max})$ como la distancia entre el píxel actual p y el valor máximo p_{si}^{max}.

2. Determinación del ancho de la ventana: determinación del número de sectores $(2w_s + 1)$ centrados en S_i.

3. Cálculo de la contribución de los máximos: el cálculo de la contribución de los valores máximos S_i^{max} en la acumulación final se da de la siguiente forma: $\tilde{d}_i = Med(d_j)$, donde $j\epsilon[i-w_{s'}, i+w_s]$ y es la mediana angular de las

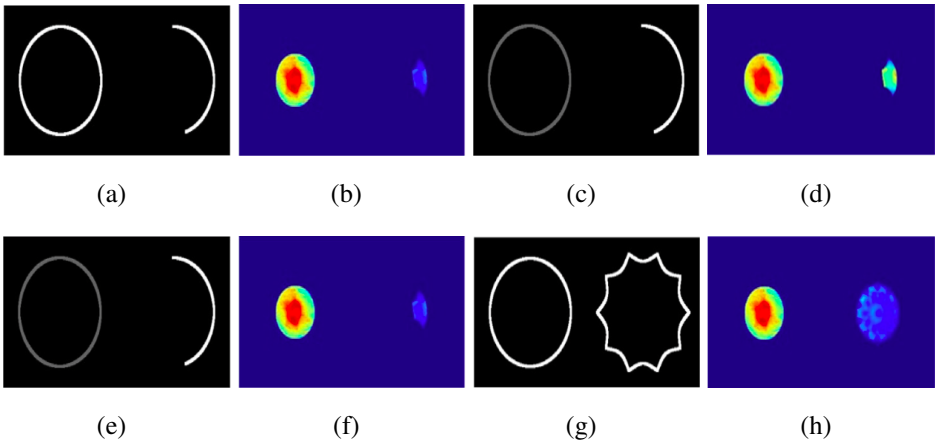


Figura 2.32: Principios del algoritmo WM-DOVA. a) Completitud en la imagen original. b) Completitud en los resultados de la acumulación. c) Robustez en la imagen original. d) Robustez en los resultados de la acumulación. e) Continuidad en la imagen original. f) Continuidad en los resultados de la acumulación. g) Concavidad en la imagen original. h) Concavidad en los resultados de la acumulación.

distancias d_j entre el máximo y el píxel central. Después se calcula el factor de ponderación γ_i mediante la ecuación 2.40.

$$\gamma_i = \frac{1}{1 + \frac{|d_i - \tilde{d}_i|}{\tilde{d}_i}} \tag{2.40}$$

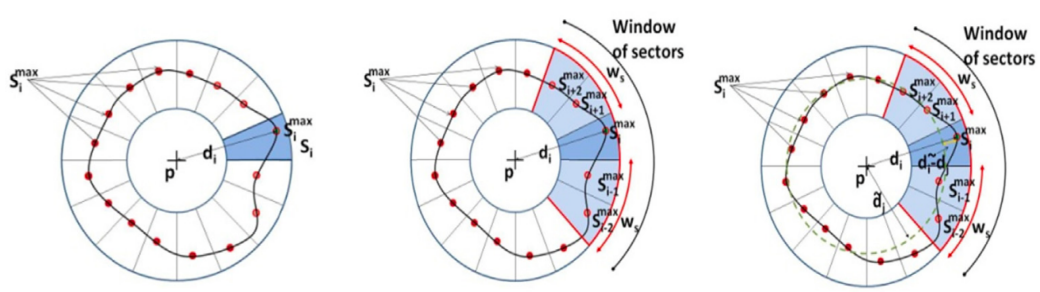
Donde $\gamma_i \epsilon [0, 1]$ y representa un factor de penalización para los valores altos de DoV aislados. La contribución final de los máximos S_i^{max} se calcula de la siguiente forma: $S_i^{max} = \gamma_i \hat{S}_i^{max}$.

4. Cálculo de la acumulación final: se calcula la acumulación final para cada píxel de la siguiente forma: $Acc_p = Med_i(\hat{S}_i^{max})$, donde $i \epsilon [i, n_s]$.

Para el cálculo del método WM-DOVA es necesario definir los siguientes parámetros: radio mínimo, radio máximo y anchura de los sectores circulares. Para una correcta interpretación de este algoritmo se presenta la figura 2.33.

2.2.8.2 **Detección de pólipos mediante el análisis de propiedades del color**

El análisis del color es una alternativa sencilla y eficiente utilizada en PDI y visión por computadora. Es muy útil para la detección de lesiones en tejidos, ya que con



(a) (b) (c)

Figura 2.33: Proceso de cálculo del algoritmo WM-DOVA. a) Cálculo de S_i^{max} bajo el sector S_i. b) Definición de la ventana de los sectores y cálculo de S_n^{max} c) Obtención de las distancias d_n desde S_n^{max} al centro p y el cálculo de la acumulación final $\hat{S}_i^{max}$.

frecuencia se muestran como regiones anormales con mayores o menores diferencias de color comparado con tejidos sanos.

El mayor inconveniente del análisis del color es debido a las variaciones de la iluminación. Este es un problema corriente en la captura de imágenes en pruebas médicas, sobre todo en las colonoscopias, lo que dificulta el análisis.

Existen diferentes enfoques para la realización del análisis del color. A continuación se describen los métodos principales junto con las investigaciones más relevantes que hacen uso de ellos.

Detección de pólipos mediante el análisis de los momentos de color

Los autores de [ZM11] propusieron un análisis del color basándose en sus momentos. Esta técnica ha sido utilizada en la detección de pólipos en imágenes de cápsula endoscópica. Para ello, en primer lugar realizan una conversión de las imágenes desde el modelo RGB al espacio de color oponente. Esto es calculado mediante la ecuación 2.2.

La información del color se representa por las variables O_1 y O_2 mientras que la información de la intensidad se encuentra en O_3. Una vez realizada la transformación se definen los momentos de color como indica la ecuación 2.41.

$$M_{pq} = \sum\sum o_1^p o_2^q \, (o_1, o_2) do_1 do_2 \tag{2.41}$$

Donde $p(o_1, o_2)$ es el histograma bidimensional normalizado en los planos o_1 y o_2 definidos por la ecuación 2.42.

$$p(o_1, o_2) = \frac{Num(o_1, o_2)}{pixNum} \tag{2.42}$$

Donde $pixNum$ es el número de píxeles de la imagen y $Num(r, g)$ es el número de píxeles con el valor o_1, o_2.

Como ya se ha mencionado, las variaciones de la iluminación suponen una problemática para el análisis del color, para ello los autores proponen la ecuación 2.43.

$$\varepsilon_{pq} = \frac{M_{pq}}{(M_{20})^{\frac{p}{2}}(M_{02})^{\frac{q}{2}}} \tag{2.43}$$

Con este proceso se obtiene un conjunto de diez momentos de color oponentes $F^C = \left[\varepsilon^C_{01} \quad \varepsilon^C_{10} \quad \varepsilon^C_{11} \quad \varepsilon^C_{12} \quad \varepsilon^C_{21} \quad \varepsilon^C_{22} \quad \varepsilon^C_{03} \quad \varepsilon^C_{30} \quad \varepsilon^C_{13} \quad \varepsilon^C_{31}\right]$, invariantes a las variaciones de la iluminación y robustos ante el ruido presente en las imágenes.

Detección de pólipos mediante el análisis de la varianza de canales RGB

Los tejidos sanos y los que presentan algún tipo de lesión tienen diferente coloración. Por este motivo, los autores de [ZBG+14] han desarrollado un método de detección automática de pólipos en imágenes de cápsula endoscópica haciendo uso de la varianza del color de los canales RGB. El cálculo de la varianza se realiza mediante la ecuación 2.44.

$$Varianza = \frac{\sum_{y=1}^{Y}\sum_{x=1}^{X}\sum_{i\epsilon I}(\bar{p}(x, y, i) - C_i)}{XY}, I = \left\{RGB\right\} \tag{2.44}$$

Donde C_i es el valor promediado de los canales RGB y p_a corresponde a los píxeles procesados de las imágenes.

Detección de pólipos mediante la caracterización del color

La extracción de características del color de una imagen es una alternativa que ha sido tratada en multitud de investigaciones, un ejemplo de ello son los trabajos [TKD02] y [ACN07]. Es sabido que los tumores malignos presentan una inflamación lo que se traduce en una coloración rojiza. Lo mismo ocurre en el caso de

los tumores benignos que tienen un matiz menos intenso. Otros aspectos de las imágenes, como por ejemplo la materia fecal son buscados por su contenido en tonos verdes, de igual forma que las infecciones que presentan tonos amarillos. En base a esto realizan una extracción de características en el dominio cromático y acromático para los modelos de color RGB y HSI siguiendo la ecuación 2.45.

$$\beta_C = \frac{\sum_{i=L1}^{L2} Hist_c(i)}{\sum_{i=0}^{L-1} Hist_c(i)} \tag{2.45}$$

Donde β_C representa las características del color para las diferentes componentes de color $C = R, G, B, H, S, I$. $Hist_c(i)$ representa el histograma para cada componente, siendo L el número de niveles de gris y $L1$ y $L2$ diferentes umbrales.

Otra investigación que realiza una extracción de características del color es [ISH+13] que utiliza los modelos de color HSV, *luminance, chrominance, value* (YUV), *tint, saturation, lightness* (TSL) y L*a*b para extraer de cada una de sus componentes las siguientes características: máximo, mínimo, media, varianza, moda, mediana, asimetría, curtosis y entropía. Con este conjunto de características alimenta un clasificador SVM con el que realiza una clasificación de los diferentes tejidos en base a su color.

2.2.8.3 **Detección de pólipos mediante el análisis de textura**

La utilización de descriptores de textura para la detección automática de pólipos ha ganado mucha popularidad en los últimos años. Existen multitud de publicaciones basadas en este concepto, como por ejemplo [BY15] y [WTW+14] entre otras. Existen diferentes enfoques que hacen uso de diversos operadores como: wavelets, patrones locales binarios (LBP), patrones locales binarios uniformes invariantes a la rotación (RIULBP), patrones locales binarios completos (CLBP) y la transformada contourlet. A continuación se realiza una descripción de ellas haciendo referencia a las publicaciones más relevantes que las utilizan.

Detección de pólipos mediante el análisis de la textura basado en wavelets

La textura ofrece información capaz de discriminar entre tejidos normales y aquellos con lesiones. La caracterización de la textura se basa en la información lo-

cal que aparece a lo largo de una vecindad definida sobre los valores en la escala de grises. Múltiples estudios han llegado a la conclusión de que la representación espacio-frecuencia mantiene información global y local que es adecuada para la caracterización de la textura, por este motivo es común el uso del enfoque wavelet. Cuando la descomposición wavelet decrece en el dominio del espacio crece en el dominio frecuencial aportando una mayor caracterización local de las imágenes y viceversa. Es sabido que la información de la textura de las imágenes está localizada en los rangos medios de frecuencia, por este motivo estudios como [KIM+03] realizan una transformación wavelet discreta como indica la ecuación 2.46:

$$\begin{aligned} L_k(b_i, b_j) &= [H_x * (H_y * L_{k-1}) \downarrow_{2,1}] \downarrow_{1,2} (b_i, b_j) \\ D_{3k-2}(b_i, b_j) &= [H_x * (G_y * L_{k-1}) \downarrow_{2,1}] \downarrow_{1,2} (b_i, b_j] \\ D_{3k-1}(b_i, b_j) &= [G_x * (H_y * L_{k-1}) \downarrow_{2,1}] \downarrow_{1,2} (b_i, b_j] \\ D_{3k}(b_i, b_j) &= [G_x * (G_y * L_{k-1}) \downarrow_{2,1}] \downarrow_{1,2} (b_i, b_j] \end{aligned} \tag{2.46}$$

Donde $\downarrow$ indica un proceso de submuestreo, $*$ el operador convolución, H un filtro paso bajo, G un filtro paso banda y k el nivel de descomposición. Las imágenes de detalle están representadas por D y las aproximaciones por L. De esta forma, realizando la convolución de la imagen original con un filtro paso bajo y paso banda, obtenemos las imágenes detalle y aproximación. Este procedimiento puede realizarse de forma iterativa a lo largo de diferentes niveles.

En el análisis de la textura se hace uso de las matrices de co-ocurrencia del nivel de gris (GLCM) que obtienen información de las subimágenes obtenidas en la descomposición wavelet. Éstas capturan información de segundo orden sobre los niveles de gris de la imagen, lo que está relacionado con la percepción humana para la discriminación de texturas. Las texturas más gruesas obtienen valores elevados cerca de la diagonal de la matriz, siendo los valores dispersos en las texturas finas. Las matrices de co-ocurrencia cifran la dependencia espacial de los niveles de gris basándose en la función de densidad de probabilidad siguiente: $f(i, j, d, \Theta)$ donde d representa la distancia entre los píxeles y Θ la dirección. Las direcciones más usadas son $\{0, \pi/4, \pi/2, 3\pi/4\}$. A partir de las matrices de co-ocurrencia se calculan las características definidas por las ecuaciones 2.47, 2.48, 2.49 y 2.50. Éstas han sido aplicadas en diversas investigaciones, como por ejemplo [AWP+09] [MIKK03] y [KIM+03].

$$Segundo\ momento\ angular = \sum_{i}^{N_g}\sum_{j}^{N_g} p(i,j)^2 \tag{2.47}$$

$$Correlación = \frac{\sum_{i=1}^{N_g}\sum_{j=1}^{N_g}(i\cdot j)p(i,j) - \mu_{xx}\mu_{yy}}{\sigma_x \sigma y} \tag{2.48}$$

$$Momento\ de\ diferencia\ inversa = \sum_{i=1}^{N_g}\sum_{j=1}^{N_g}\frac{1}{1+(i-j)}p(i,j) \tag{2.49}$$

$$Entropía = -\sum_{i}^{N_g}\sum_{j}^{N_g} p(i,j)log(p(i,j)) \tag{2.50}$$

Donde $p(i,j)$ corresponde a la posición i,j de la matriz de co-ocurrencia normalizada, N_g es el número de niveles de gris, μ_x, μ_y, σ_x y σ_y son las medias y desviaciones estándar de la probabilidad marginal de $p_x(i)$ obtenidas de las sumas de las filas de la matriz $p(i,j)$.

Análisis de la textura basada en la covarianza de color wavelet (CWC)

El análisis de la textura basada en características de la CWC propuesta en [KIM+03] permite analizar la textura basándose en la covarianza de las características de la textura de segundo orden en el dominio wavelet de los canales de color.

Es necesario calcular la transformada wavelet discreta de K niveles en cada uno de los canales de color, para después calcular las matrices de co-ocurrencia de cada una de las imágenes de detalle $I_j(K)$ obtenidas. En ellas $j = 1,2,3..J$, $k = 1,2,3..K$, siendo $M_{C_i}^{I_j(k)}(\Theta)$ una matriz de co-ocurrencia de un canal de color C_i, donde $i = 1,2,3$ y las direcciones $\theta = 0^o, 45^o, 90^o, 135^o$. A partir de las matrices de co-ocurrencia se calculan las siguientes características: segundo momento angular (véase ecuación 2.47), correlación (véase ecuación 2.48), momento de diferencia inversa (véase ecuación 2.49) y entropía (véase ecuación 2.50), creando un conjunto de características $F_{C_i}^{I_j(k)}(\theta)$. El cálculo de la CWC se realiza a partir de la ecuación 2.51, donde $p \leq q$ y $p, q \epsilon i$.

$$CWC_{C_p,C_q}^{I_j(k)} = COV(F_{C_p}^{I_j(k)}, F_{C_q}^{I_j(k)}) \tag{2.51}$$

De esta forma se extraen las particularidades de las texturas de las imágenes ofreciendo una alternativa que consigue unos buenos resultados. Dada la alta eficacia mostrada por el análisis de la textura basada en CWC, investigaciones como [LM12] han hecho uso de ella obteniendo resultados satisfactorios.

Detección de pólipos mediante el uso de RIULBP

RIULBP [OPM02] es una variación de los LBP propuestos en [OPH96]. Se utilizan para describir la estructura espacial de la textura de una imagen local. Es un enfoque sencillo que trata de buscar los LBP fundamentales a los que denominan uniformes. Estos son de forma circular y tienen pocas transiciones de 0 a 1.

La definición de los patrones uniformes se basa en la medida de uniformidad U, que corresponde al número de transiciones espaciales bit a bit de 0 a 1 en el patrón. Por ejemplo, los patrones 00000000 y 11111111 tienen valores de uniformidad 0. Los patrones con valores de uniformidad mayores o iguales a 2 son etiquetados como uniformes. Basándose en esta definición de uniformidad se propuso un nuevo operador uniforme e invariante a la rotación. Éste viene determinado por la ecuación 2.52.

$$LBP^{riu2}_{P,R} = \begin{cases} \sum_{P=0}^{P-1} s(g_p - g_c) & si\ U(LBP_{P,R}) \leq 2 \\ P+1 & en\ otro\ caso \end{cases} \tag{2.52}$$

Donde,

$$U(LBP_{P,R}) = \left|s(g_{P-1} - g_c) - s(g_0 - g_c)\right| + \sum_{P=1}^{P=-1} \left|s(g_p - g_c) - s(g_{P-1} - g_C)\right| \tag{2.53}$$

$s(x)$ es una función escalón con $s(x) = 1$ si $x \geq 0$ y $s(x) = 0$ en cualquier otro caso. P determina el número de vecinos a tratar y R el radio del círculo.

Detección de pólipos mediante el uso de patrones locales binarios completos (CLBP)

Es una mejora de LBP propuesta en la investigación [GZZ10]. Los patrones de textura locales son representados por un signo y la magnitud de la diferencia local

de la imagen. La información que aporta el signo es equiparable a la aportada por el método LBP y es la más importante. En cuanto a la información aportada por la magnitud, se trata de una característica adicional. El conjunto de ambas proporciona la posibilidad de clasificar texturas. Los CLBP vienen determinados por la ecuación 2.54.

$$CLBP_M_{P,R} = \sum_{p=0}^{P-1} t(m_p - c)2^p, t(x,c) = \begin{cases} 1 & six > c \\ 0 & six < c \end{cases} \tag{2.54}$$

Donde m_p es la magnitud de la diferencia entre el píxel central de la región local y los píxeles vecinos y c es el umbral a elegir de forma adaptativa. El valor medio de m_p a lo largo de toda la imagen es determinante para realizar una clasificación de la textura de la imagen.

Detección de pólipos mediante el uso de la trasformada contourlet

Al igual que la transformada wavelet [DV05], la familia de bases curvelets se construyen mediante la transformación de una función curvelet madre. Usa tres dimensiones para generar la familia, el escalado diádico y la traslación tal como se hace para generar la familia wavelet, además de la rotación, que brinda una dimensión adicional en el análisis de las imágenes. Una de sus principales propiedades es que las curvas singulares pueden ser aproximadas de forma precisa con muy pocos coeficientes y en una manera no adaptable, por ello su nombre, curvelets. Comparada con la transformada wavelet, la transformada curvelet puede representar un contorno liso con múltiples direcciones usando muy pocos coeficientes consiguiendo la misma precisión. En la figura 2.34 se muestra el esquema de funcionamiento básico de la transformada contourlet para una mejor interpretación.

Investigaciones como [ZM11] y [LM09] hacen uso de esta transformada para el análisis de la textura de imágenes obtenidas de una cápsula endoscópica. Realizan una transformación de las imágenes originales mediante la transformada contourlet consiguiendo imágenes con diferentes orientaciones y escalas. Más tarde aplican LBP a partir de los cuales calculan una serie de características que permiten el análisis de la textura.

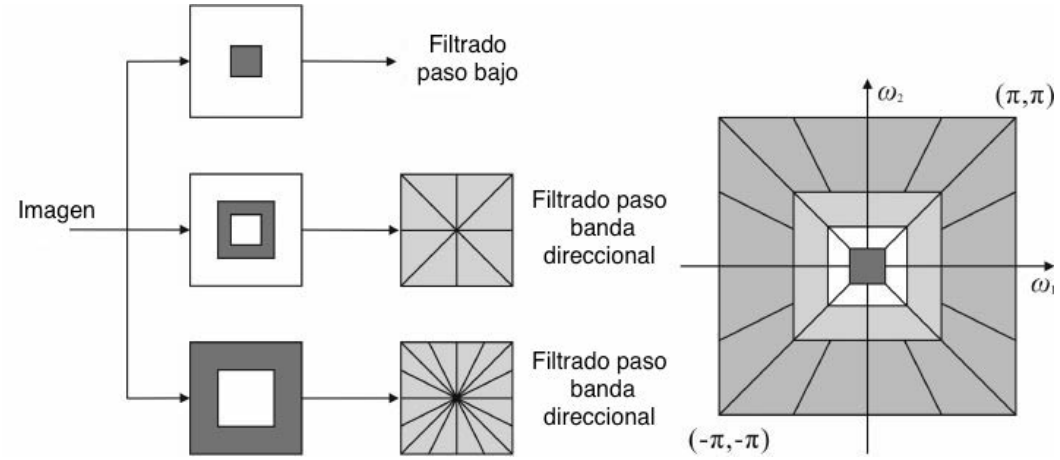


Figura 2.34: Transformada contourlet. Fuente: goo.gl/tSmhNa

Detección de pólipos mediante el análisis de la textura basada en unidades de textura

El análisis de la textura basado en unidades de textura es un enfoque novedoso introducido en [TKD02]. Las unidades de textura definen la textura local, es decir, la de un píxel concreto y su vecindad. De esta forma cada imagen se compone de N unidades de textura sobre las cuales extraen una serie de características de cada canal de los modelos de color RGB y HSI. Las características extraídas son: energía, media, desviación estándar, asimetría, curtosis y entropía, generando una caracterización de la textura local.

2.2.8.4 **Detección de pólipos mediante el uso de descriptores *moving picture experts group 7* (MPEG-7)**

Los seres humanos tienen la capacidad de seleccionar de forma intuitiva un conjunto de fotografías e identificarlas como similares. Esto es posible gracias a procesos cognitivos del aprendizaje que se centran en las características visuales de las imágenes. Este enfoque ha sido emulado en computadores calculando un conjunto de características de una imagen que hacen posible identificar atributos como la luminosidad, intensidad, color predominante y tonalidad entre otros.

En este principio se basa el estándar MPEG-7, que es una representación de imágenes y videos que define características llamadas descriptores visuales. Estos

pueden ser empleados para la aplicación de funciones de similitud entre imágenes, sin embargo, el coste computacional de obtener estos descriptores es elevado. Este enfoque ha sido utilizado para caracterizar la forma, textura y color de los pólipos, posibilitando el desarrollo de algoritmos para su detección automática. El estudio [CC06] tiene en cuenta los momentos de forma, la homogeneidad de las texturas, el histograma de los bordes locales y el color dominante para tal propósito obteniendo resultados satisfactorios.

2.2.9 Resumen de publicaciones y técnicas para la detección de pólipos

En la tabla 2.13 se realiza un resumen de las publicaciones más relevantes relacionadas con la detección automática de pólipos descritas en el presente capítulo.

2.2.10 Estadísticas sobre las publicaciones referenciadas

En este apartado se realiza una representación gráfica de las estadísticas de las publicaciones que se han referenciado en el presente capítulo. Se ha efectuado una clasificación de los trabajos en base a la temática y técnicas utilizadas. La organización realizada no es excluyente, pudiendo ser incluida una publicación en diversas categorías.

En primer lugar, se ha realizado una clasificación del total de las publicaciones referenciadas en base a la temática principal de las mismas. De un total de 98 publicaciones citadas, 42 han sido incluidas en el grupo “Detección de anomalías en el colon”, 17 en “Evaluación de la calidad de la colonoscopia” y 39 en “Información médica o técnica adicional”. En la figura 2.35 se muestra la representación gráfica de la clasificación realizada.

En segundo lugar, se han dividido las publicaciones que componen la categoría “Detección de anomalías” en diferentes grupos en base a las anomalías que tratan de detectar. De las 42 publicaciones que componen este grupo, se han incluido 31 en la categoría “Detección automática de pólipos”, 2 en “Clasificación automática de pólipos”, 5 en “Detección de anomalías”, es decir, no se realiza una detección de un tipo de anomalía específico, 3 en “Detección de tumores” y por último 1 en

Tabla 2.13: Resumen de las técnicas de detección de pólipos.

Publicación	Método	Año
[BY15]	Análisis de color y textura.	2015
[BSFE+15]	Acumulación DoV.	2015
[PLK15]	Análisis de textura y bordes.	2015
[TGL15]	Análisis de forma y contexto.	2015
[BNSV14]	Acumulación DoV.	2014
[TCGL14]	Análisis de bordes.	2014
[WTW+14]	Análisis de forma y textura.	2014
[ZBG+14]	Análisis de color mediante la varianza de canales RGB.	2014
[TGL13]	Análisis de curvatura y color.	2013
[BSV12a]	Acumulación DoV.	2012
[BSV12b]	Acumulación DoV.	2012
[LM12]	Análisis de textura.	2012
[ZM11]	Análisis de textura mediante la transformada contourlet.	2011
[BSV11a]	Acumulación DoV.	2011
[ZFL11]	Análisis de curvatura y forma.	2011
[GZZ10]	Análisis de textura mediante CLBP.	2010
[VWVRVVV10]	Análisis de forma.	2010
[AWP+09]	Análisis de textura mediante wavelets y GLCM.	2009
[LM09]	Análisis de textura mediante la transformada contourlet.	2009
[ACN07]	Análisis de color.	2007
[HOT+07]	Ajuste de elipses y análisis de curvatura.	2007
[CC06]	Descriptos MPEG-7.	2006
[JLC+06]	Análisis de curvaturas de bordes.	2006
[HSH05]	Análisis de curvaturas de superficies.	2005
[KD03]	Ajuste de elipses.	2003
[KIM+03]	Análisis de color y textura mediante wavelets y GLCM.	2003
[MIKK03]	Análisis de textura mediante wavelets y GLCM.	2003
[OPM02]	Análisis de textura mediante RIULBP.	2002
[TKD02]	Análisis de color y unidades de textura.	2002
[KYC+98]	Análisis de curvatura.	1998
[OPH96]	Análisis de textura mediante RIULBP.	1996

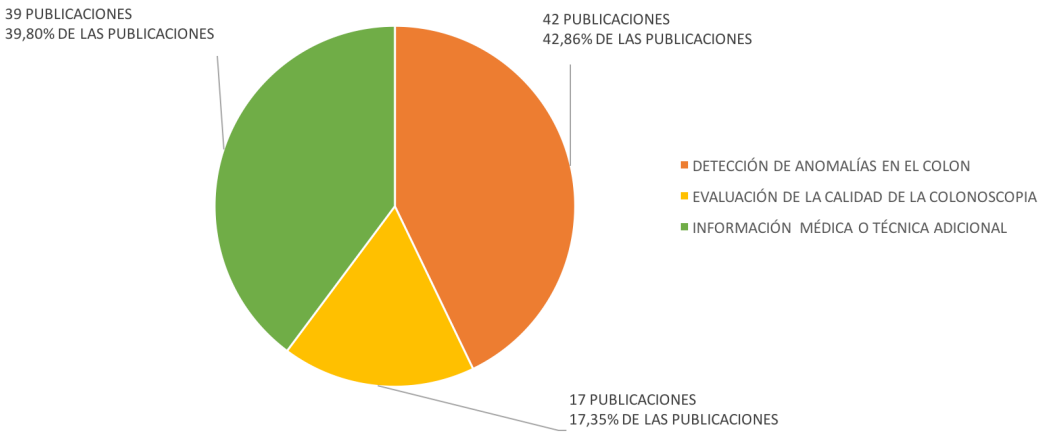


Figura 2.35: Clasificación de las publicaciones por su temática principal.

"Detección de úlceras". En la figura 2.36 se realiza una representación gráfica de esta clasificación.

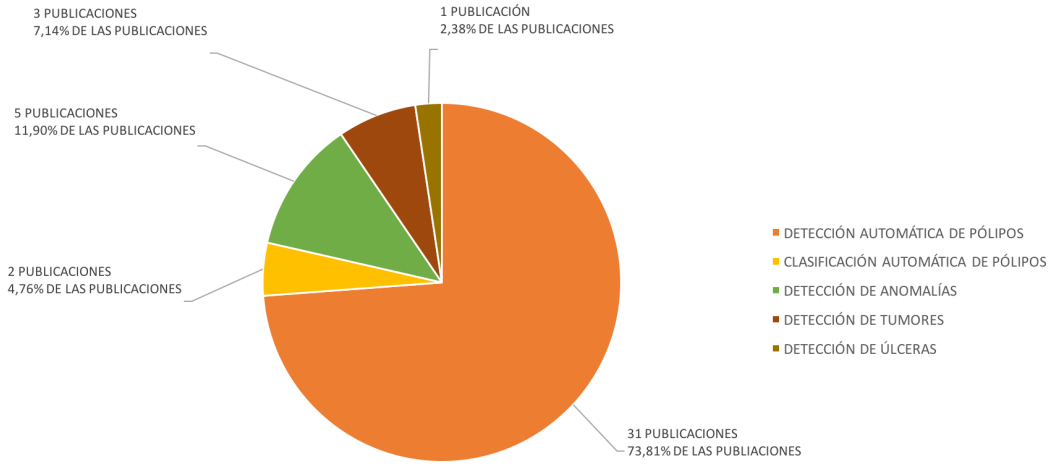


Figura 2.36: Clasificación de las publicaciones de la categoría "Detección de anomalías en el colon" en función del tipo de lesión.

En tercer lugar, se han organizado las publicaciones de la categoría "Evaluación de la calidad de la colonoscopia" en diferentes grupos según el objetivo que persiguen. Del total de las 17 publicaciones incluidas en esta categoría, 3 han sido clasificadas en el grupo "Mejora de la calidad de la colonoscopia", 7 en "Evaluación de la calidad de la colonoscopia" y 7 en "Información sobre indicadores de

calidad de la colonoscopia". En la figura 2.37 se muestra una representación gráfica de esta clasificación.

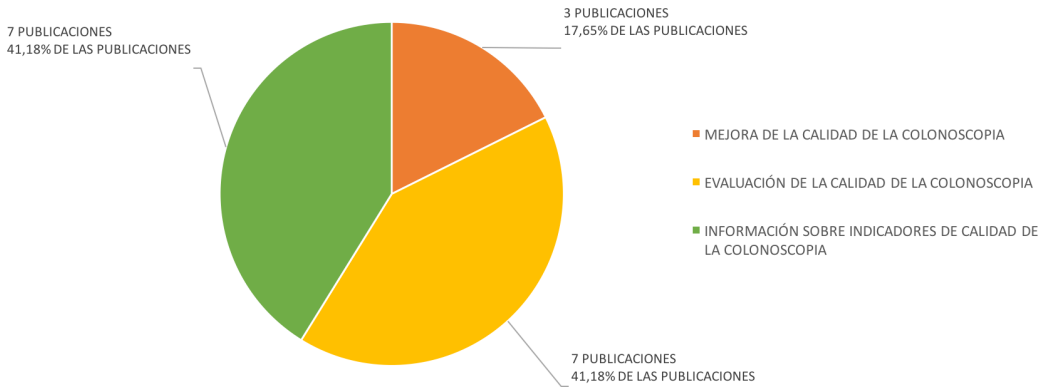


Figura 2.37: Clasificación de las publicaciones de la categoría "Evaluación de la calidad de la colonoscopia" en función de la temática principal.

En cuarto lugar, se han catalogado las publicaciones citadas de la categoría "Información médica o técnica adicional" en diferentes grupos dependiendo de la temática a la que pertenecen. Del total de 39 publicaciones, se incluyen 28 en la categoría "Publicaciones técnicas", 8 en "Publicaciones médicas y 3 en "Publicaciones de información general". En la figura 2.38 se puede ver la representación gráfica de esta clasificación.

En quinto lugar, teniendo en cuenta la gran importancia que tiene la selección de un modelo de color apropiado para el análisis de imágenes, se ha creído oportuno realizar una clasificación de las publicaciones en base a los modelos utilizados. Es necesario indicar que no todas las publicaciones especifican el modelo de color utilizado y que además, algunas de ellas utilizan más de uno. De las publicaciones citadas 5 se incluyen en el grupo "HSV", 16 en "RGB", 5 en "HSI", 4 en "L*a*b", 1 en "OC-RGB" (*opponent color red, green, blue*) , 1 en "S-RGB" (*standard red, green, blue*), 1 en "YUV" y por último 1 en "TSL". La figura 2.39 realiza una representación gráfica de la clasificación realizada.

En sexto lugar, debido a la variedad de pruebas diagnósticas existentes en la actualidad, se ha decidido realizar una organización de los trabajos referenciados en base a la procedencia de las imágenes utilizadas. Del total de publicaciones citadas

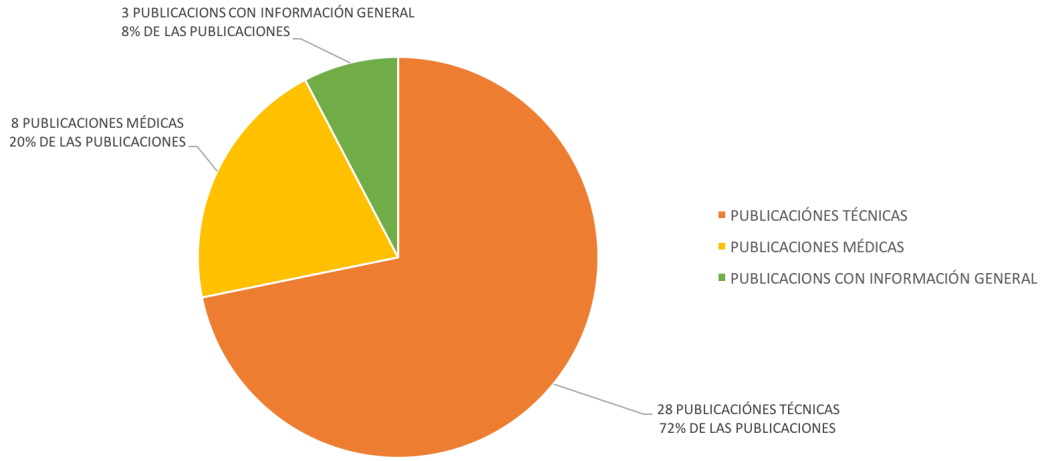


Figura 2.38: Clasificación de publicaciones de la categoría "Información médica o técnica adicional" en función de la temática principal.

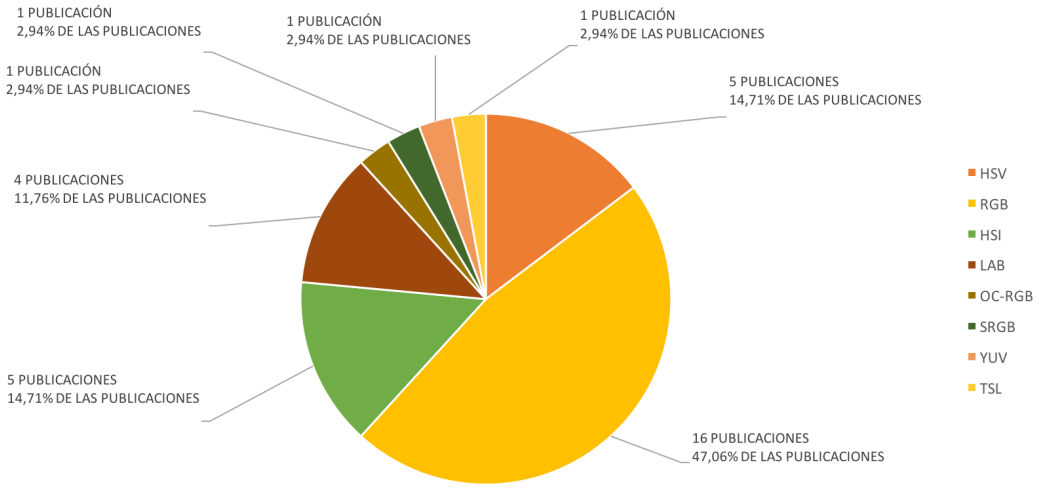


Figura 2.39: Clasificación de las publicaciones en base al modelo de color utilizado.

en el capítulo, 46 de ellas corresponden a la categoría "Imágenes de colonoscopia", 8 a "Imágenes de cápsula endoscópica", 5 a "Imágenes NBI" (*narrow band imaging*), 1 a "Imágenes de colonoscopia virtual" y por último, 1 a "Imágenes de tomografía computarizada". En la figura 2.40 se muestra la división realizada.

En séptimo lugar, teniendo en cuenta la gran variedad de enfoques existentes para afrontar la detección automática de anomalías, se cree necesaria la realización de una división de las publicaciones de la categoría "Detección de anomalías" en

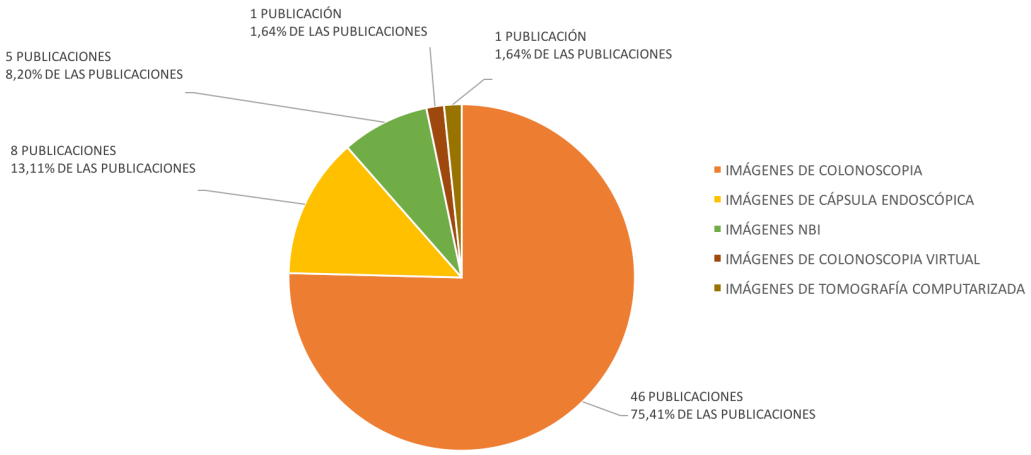


Figura 2.40: Clasificación de las publicaciones en base al tipo de imagen usado.

base al concepto utilizado. La clasificación realizada incluye a 3 publicaciones en la categoría de métodos de "Análisis de color", 10 en "Análisis de textura", 10 en "Análisis de forma", 1 en "Análisis de vasos sanguíneos", 9 en "Análisis de curvatura", 3 en "Análisis de color y textura", 3 en "Análisis de forma y textura", 2 en "Análisis de forma y color" y por último 1 en "Análisis de forma, color y textura". En la figura 2.41 se puede ver una representación gráfica de la clasificación llevada a cabo.

Por último y en octavo lugar, dada la importancia que tienen los métodos de extracción de características, tanto para la detección de anomalías, como para la implementación de métricas de evaluación de la calidad de ejecución de la colonoscopia, se ha hecho una clasificación de las publicaciones en base a los métodos de extracción de características que han utilizado. De las publicaciones que especifican el enfoque utilizado, 3 de ellas están en el grupo "LBP", 3 en "CLBP", 2 en "RIULBP", 1 en "mLBP", 1 en "OC-LBP" (*opponent color local binary patterns*), 2 en "GLCM" (*Gray Level Co-ocurrence Matrixes*), 1 en "shape-UCM" (*shape ultrametric contour map*), 5 en "Wavelets", 2 en "HOG" (*histogram of oriented gradients*), 1 en "SIFT" (*scale-invariant feature transform*) y por último 1 en "Descriptores MPEG-7". En la figura 2.42 se realiza una descripción gráfica de la clasificación realizada.

Gracias a la estructuración realizada de las publicaciones referenciadas en el presente capítulo se espera aportar claridad sobre la metodología seguida a la hora

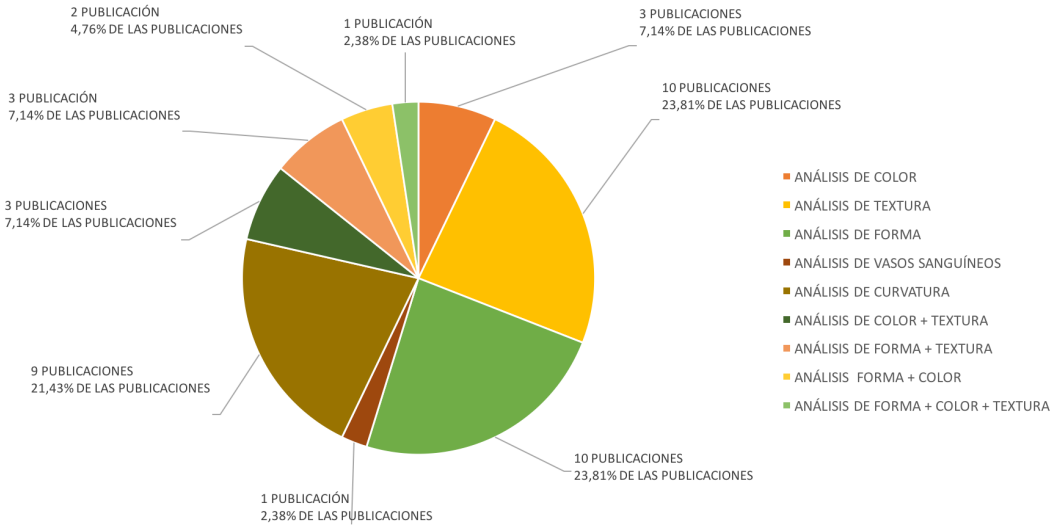


Figura 2.41: Clasificación de las publicaciones en base al enfoque de detección de anomalías utilizado.

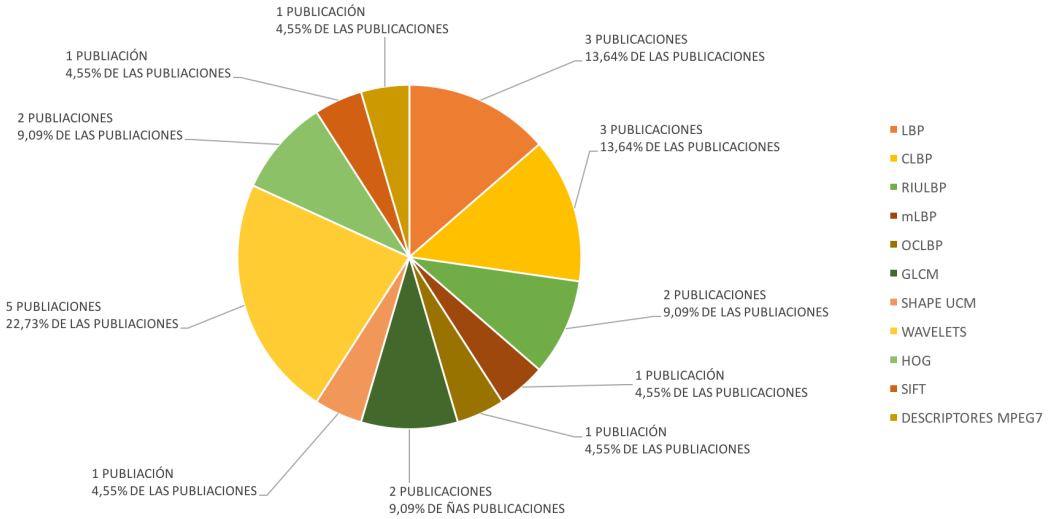


Figura 2.42: Clasificación de las publicaciones en base al enfoque de extracción de características utilizado.

de buscar los trabajos de referencia que han servido de guía en la presente investigación.

2.3 Sumario

En este capítulo, por un lado se han revisado los conceptos médicos más relevantes sobre el CCR. Se ha incluido una descripción del aparato digestivo describiendo sus componentes y funciones, haciendo especial énfasis en el colon. De este último se ha proporcionado su anatomía e histología, además de describirse una de las principales lesiones que se producen en él, los pólipos. En lo referente a los pólipos se han proporcionado diferentes metodologías para su clasificación, así como una revisión de las pruebas diagnósticas más relevantes para su exploración. Por otro lado, se ha llevado a cabo una revisión del ámbito técnico. En primer lugar, se ha incluido un análisis de las diferentes herramientas disponibles para el desarrollo de algoritmos de PDI. En segundo lugar, se han mostrado las principales características de los modelos de color más utilizados. En tercer lugar, se han explicado las técnicas y métodos de mejora de imagen más extendidos. En cuarto lugar, se han proporcionado las técnicas de detección de bordes y segmentación más utilizadas por la comunidad científica. Por último y en quinto lugar, se han mostrado los métodos existentes en la literatura para la detección automática de pólipos. Todo esto ha sido acompañado por un resumen de las publicaciones más relevantes en las diferentes áreas tratadas.

"The goal is to turn data into information, and information into insight."

Carly Fiorina

CAPÍTULO

3

Base de datos

En este capítulo se describirá la metodología seguida para realizar la selección de los centros de salud que han participado en las pruebas del sistema desarrollado *ad-hoc* para esta tesis, así como de los pacientes cuyas imágenes y vídeos colonoscópicos formarán la base de datos. Esto incluye los criterios de inclusión y exclusión aplicados para cada uno de los colectivos implicados.

3.1 Descripción de la base de datos

Para la realización de esta tesis se ha contado con 2 bases de datos diferentes de vídeos e imágenes colonoscópicas. La primera de ellas es la considerada **principal** que ha sido creada *ad-hoc* para la investigación, la segunda es una base de datos **secundaria** denominada *CVC Colon Database* [BSV12b] utilizada para comprobar la robustez de los algoritmos desarrollados.

Como ya se ha comentado, la base de datos está compuesta tanto por vídeos como por imágenes. Esto puede ser confuso, pero en realidad un vídeo no deja de ser una secuencia de imágenes encadenada, por lo tanto, para cumplir los objetivos de la investigación propuesta son válidos ambos tipos de datos. En la figura 3.1 se hace una representación gráfica de la descomposición de una secuencia de vídeo en diferentes fotogramas o imágenes para una mayor aclaración. En el caso de las

imágenes, su utilidad es inmediata, pudiéndose aplicar los algoritmos desarrollados de forma directa. En cambio, en el caso de los vídeos es necesario extraer el fotograma correspondiente para poder aplicar los métodos implementados.



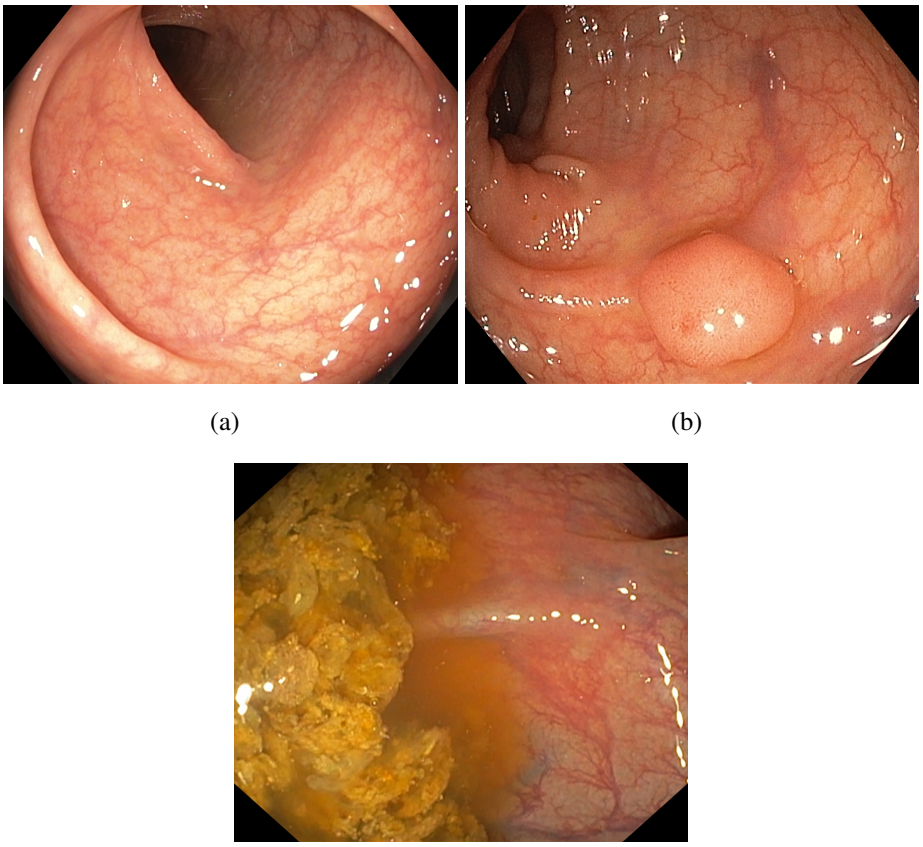
Figura 3.1: Descomposición de un vídeo en fotogramas. Fuente: goo.gl/zn7w9M

La base de datos principal se compone de vídeos e imágenes colonoscópicas. Por cada colonoscopia los especialistas obtienen el vídeo correspondiente a la prueba, imágenes de las lesiones detectadas y seis imágenes correspondientes a las zonas especificadas por la ELCB (ciego, ascendente, transverso, descendente, sigma y recto) para evaluar su calidad de preparación. Tanto los vídeos como las imágenes se pueden dividir en los siguientes grupos:

- Sin lesiones: se trata de vídeos e imágenes extraídas de colonoscopias en las que no se ha detectado ningún tipo de lesión en el paciente, siendo su calidad de preparación buena (véase figura 3.2 (a)).

- Con lesiones: son vídeos e imágenes extraídas de colonoscopias en las que se han detectado lesiones. En el caso particular de esta tesis, las lesiones detectadas son pólipos de diferente tipología según las clasificaciones de Kudo y París. La calidad de preparación del colon del paciente en estos vídeos e imágenes es buena (véase figura 3.2 (b)).

- Mal preparadas: lo componen vídeos e imágenes extraídas de colonoscopias en las que se ha observado una mala preparación del colon del paciente. Pueden contener lesiones pero en la gran mayoría de los casos éstas no pueden ser detectadas por la abundante cantidad de heces (véase figura 3.2 (c)).



(a) (b)

(c)

Figura 3.2: Clasificación de los tipos de vídeos e imágenes colonoscópicas de la base de datos principal. a) Imagen colonoscópica sin pólipo. b) Imagen colonoscópica con pólipo. c) Imagen colonoscópica con mala preparación.

Por cada una de las pruebas que componen la base de datos, los especialistas han realizado un informe que contiene la siguiente información:

- Tiempo de aparición de la lesión en el vídeo colonoscópico: en caso de detectarse alguna lesión, se indica el tiempo exacto de aparición en minutos y segundos para poder localizar los fotogramas correspondientes.

- Clasificación de la lesión: se aportan las clasificaciones de Kudo y París de las lesiones.
- Valoración observada en base a la ELCB: recordemos que se trata de una valoración subjetiva, por lo tanto dependiente de la interpretación del especialista. En el caso de la presente investigación 2 experimentados endoscopistas han realizado de forma independiente una valoración de los vídeos e imágenes.

La información presente en los informes endoscópicos es indispensable para el desarrollo y validación de los algoritmos desarrollados, ya que permite evaluar su eficacia.

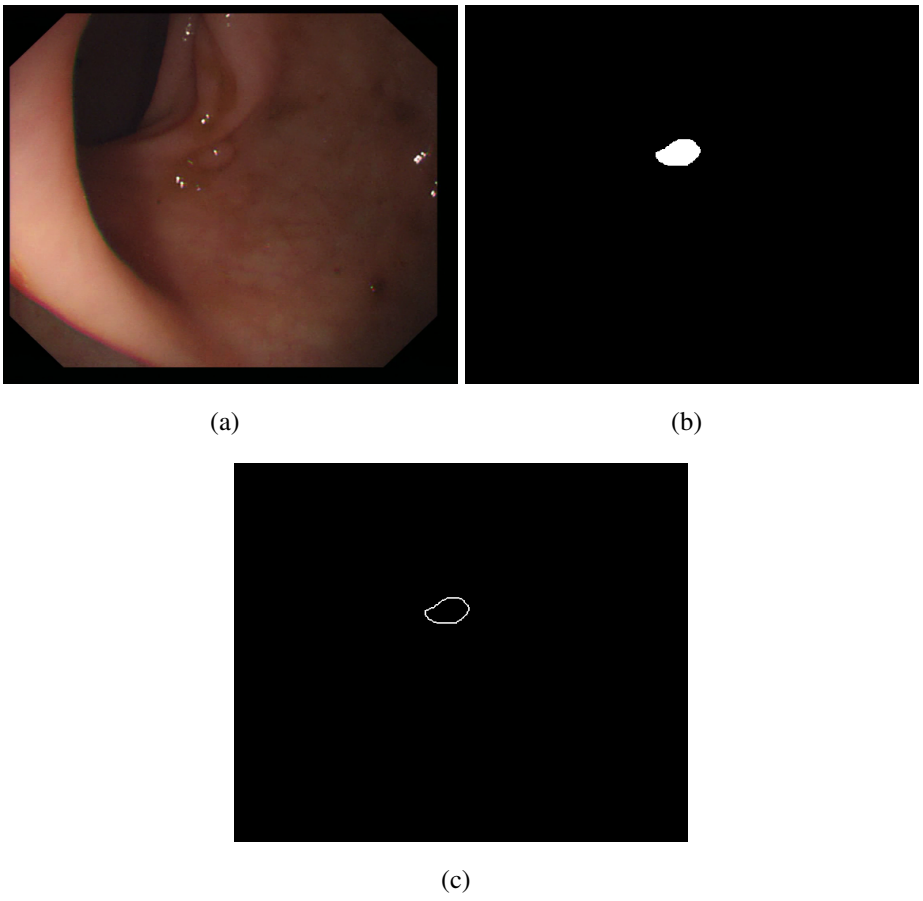
Los vídeos e imágenes adquiridas para formar la base de datos principal han sido registrados en diversos centros de salud del País Vásco por diferentes endoscopistas (véase Tabla 3.1), todos ellos en alta definición mediante endoscopios de los siguientes fabricantes: Pentax, Olympus y Fuji.

Tabla 3.1: Centros de salud y endoscopistas participantes en la creación de la base de datos principal.

Centros de Salud	**Endoscopistas**
Hospital de Basurto	Ángel Jose Calderón y Ana Belén Díaz Roca.
Hospital Universitario Donostia	Luís Bujanda e Inés Gil Lasa.
Hospital de San Eloy	Fidencio Bao e Iñigo García Kamiruaga.
Hospital Universitario Araba	Aitor Orive Calzada y Maite Escalante.
Hospital Universitario Cruces	Manuel Zaballa Iñiguez.
Hospital de Galdakao	Alain Huerta Madrigal e Ignacio Casado.

La segunda base de datos disponible es la denominada *CVC Colon Database*. Se compone de 380 imágenes colonoscópicas con pólipos, por lo que quedaría clasificada dentro del grupo de imágenes con lesiones. Además de las imágenes, proporciona las máscaras correspondientes a la detección de los pólipos, así como los contornos de estos (véase figura 3.3). Tanto las máscaras de detección de los pólipos como los contornos de estos han sido calculados por expertos endoscopistas, de forma que su fiabilidad está contrastada. Para la creación de esta base de

datos se han utilizado 15 vídeos colonoscópicos de los cuales se ha obtenido una secuencia de imágenes de cada una de las lesiones detectadas. Esta base de datos ha sido utilizada para contrastar la eficacia de los algoritmos de detección de pólipos desarrollados, ya que también ha sido utilizada en múltiples investigaciones.



(a) (b)

(c)

Figura 3.3: Imágenes disponibles en la base de datos *CVC Colon Database*. a) Imagen con pólipo. b) Máscara de detección del pólipo. c) Contorno del pólipo.

Se hace necesario indicar que todo el contenido de la base de datos está anonimizado, de forma que se garantiza el cumplimiento del artículo 3 de la Ley 14/2007 de investigación biomédica, en la que se hace referencia al proceso por el cual deja de ser posible establecer, por medios razonables, el nexo de unión entre un dato y el sujeto al que se refiere.

3.2 Población de referencia

Una población está determinada por sus características definitorias. Por lo tanto, el conjunto de elementos que posea esta característica se denomina población o universo. Población es la totalidad del fenómeno a estudiar, donde las unidades de población poseen una característica común, la que se estudia y da origen a los datos de la investigación.

La población es un conjunto de individuos de la misma clase limitada por el estudio. Según Tamayo [T$^+$04], la población es la totalidad de un fenómeno de estudio, incluyendo la totalidad de unidades de análisis que integran dicho fenómeno y que debe cuantificarse para un determinado estudio integrando un conjunto N de entidades que participan de una determinada forma. Así se le denomina a la población por constituir la totalidad del fenómeno adscrito a una investigación.

Cuando se seleccionan algunos elementos con la intención de averiguar algo sobre una población determinada, nos estamos refiriendo a este grupo de elementos como muestra. Por supuesto, se espera que lo averiguado en la muestra sea cierto para la población en su conjunto. La exactitud de la información recolectada depende en gran medida de la forma en que fue seleccionada la muestra. Cuando no es posible medir cada uno de los individuos de una población, se toma una muestra representativa de la misma.

La muestra descansa en el principio de que las partes representan al todo y, por tal, refleja las características que definen a la población de la que fue extraída, lo cual nos indica que es representativa. Por lo tanto, la validez de la generalización depende de la validez y del tamaño de la muestra (véase figura 3.4).

A la población de estudio se le conoce como población diana o población blanco y viene delimitada por características demográficas, sociales, hábitos de vida, problemas de salud, etc. De esta manera, nuestra población de estudio son pacientes que se han sometido a programas de cribado de CCR, quienes de forma previa no han sido diagnosticados de ninguna enfermedad intestinal. En toda investigación la población diana es el universo al que queremos generalizar nuestros resultados.

Dentro de esta población diana se encuentra la población accesible, que consta del conjunto de casos que satisfacen los criterios predeterminados y que al mismo

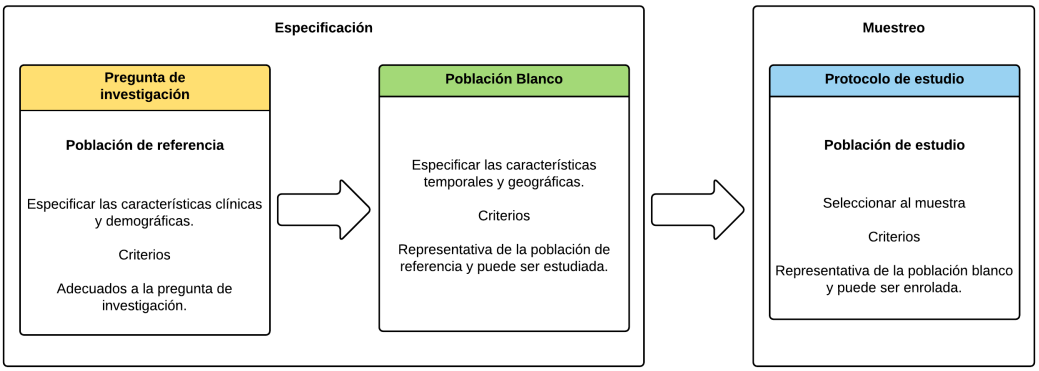


Figura 3.4: Diagrama de selección de la muestra.

tiempo, son accesibles para el investigador, por lo que la población accesible viene determinada por consideraciones prácticas en función de la accesibilidad que tengamos a los sujetos (existencia de registros, circunstancias que faciliten la colaboración, etc.). En esta investigación, la población accesible es aquella que acude a uno de los centros de salud colaboradores y de la cual se realiza una grabación de vídeo de la prueba, fotografiándose las lesiones detectadas así como las zonas especificadas por la ELCB a fin de evaluar la calidad de preparación del colon.

Al identificar una población se debe especificar los criterios que definen quienes deben incluirse. Estos criterios deben estar bien especificados, ya que mediante ellos se decidirá si un individuo se incluirá o no en la población de interés. Estos criterios de selección delimitan a la población elegible. Los criterios que especifican las características que la población debe tener se denominan criterios de elegibilidad o criterios de inclusión.

En el caso particular de la tesis que se presenta, la población de referencia está formada por pacientes que han tomado parte en programas de cribado de CCR en los siguientes centros de salud del País Vasco:

- Hospital Universitario Donostia.
- Hospital de San Eloy.
- Hospital de Basurto.
- Hospital Universitario Araba.

- Hospital Universitario Cruces.
- Hospital de Galdakao.

3.3 Criterios de selección

Cada estudio tiene reglas sobre quién puede, o no, participar en él. Estas reglas, llamadas requisitos de elegibilidad, describen las características que todos los participantes deben compartir. Los requisitos de elegibilidad son distintos entre un estudio y otro. Pueden incluir la edad, el sexo, el historial médico y la condición de salud actual. Los requisitos de elegibilidad para los estudios de tratamiento en ocasiones tienen como regla que las personas tengan una edad similar, que las características de la enfermedad sean similares o que tengan cierto tipo de mutación genética.

Los requisitos de elegibilidad incluyen los criterios de inclusión y exclusión. La meta de los criterios de inclusión y exclusión es inscribir al grupo de participantes que tenga la mayor probabilidad de ayudar a responder la pregunta de la investigación. Para las pruebas clínicas que están estudiando una nueva intervención, las pruebas están diseñadas para tratar de obtener una respuesta de la manera más rápida y eficiente posible.

- El criterio de inclusión comprende las reglas sobre las características específicas que una persona debe tener para poder estar incluida en el estudio. Éstas pueden incluir características personales como la edad y el sexo, características de la enfermedad como una mutación específica, síntomas que una persona exhibe o características del tratamiento como tratamientos anteriores. El criterio de inclusión ayuda a seleccionar participantes con características similares que con seguridad afecten su reacción a un tratamiento específico de un modo que pueda medirse, o cuyo curso de la enfermedad es similar. Las personas que cumplen con el criterio de inclusión no serán las mismas en otras áreas de su vida personal o médica. Las personas que no cumplan con todos los requisitos de inclusión no podrán inscribirse en el estudio. Los distintos estudios tienen criterios de inclusión diferentes, lo que

significa que no ser elegible para un estudio no quiere decir que no pueda participar en otro.

- El criterio de exclusión comprende reglas que impedirían que las personas participaran en un estudio, incluso si cumplen con todos los criterios de inclusión. El criterio de exclusión identifica características específicas como otras condiciones médicas o características personales, que podrían afectar la condición de la persona de tal forma que podrían hacer su participación más peligrosa o que podrían hacer que la persona tenga menos posibilidades de completar la prueba con éxito.

Los criterios de inclusión fijados para la investigación que se presenta son los siguientes:

- Paciente participante en programas de cribado colorrectal en los centros de salud colaboradores.
- Paciente mayor de 18 años.
- Hombres y mujeres.
- Haber sido firmado el consentimiento informado y avalado con anterioridad por el comité de ética de la Universidad de Deusto.

En cuanto a los criterios de exclusión, los fijados para la investigación son los siguientes:

- Cualquier circunstancia contraria a los criterios de inclusión.
- Baja calidad en los vídeos o imágenes debida a problemas de adquisición.

Gracias a estas premisas se han definido los criterios para la creación de la base de datos principal de la investigación.

3.4 Tamaño muestral

Se ha mencionado de forma previa que para la realización de esta tesis doctoral se han utilizado dos bases de datos, una principal creada *ad-hoc* para la investigación y otra secundaria utilizada para la validación de los algoritmos. A continuación se realiza una descripción de la cantidad de vídeos e imágenes que componen ambas bases de datos.

En cuanto a la base de datos principal, la tabla 3.2 muestra información acerca de la cantidad total de vídeos e imágenes que la componen, así como de la cantidad disponible para cada uno de los grupos que componen la base de datos (sin lesiones, con lesiones y mal preparadas).

Tabla 3.2: Tamaño muestral de la base de datos principal.

	Cantidad total	**Sin lesiones**	**Con lesiones**	**Mal preparadas**
Vídeos	145	35	85	25
Imágenes	700	100	200	400

En lo referente a la base de datos secundaria, la denominada *CVC Colon Database*, la cantidad de imágenes, máscaras y contornos que proporciona viene descrita en la tabla 3.3

Tabla 3.3: Tamaño muestral de la base de datos secundaria *CVC Colon Database*.

	Imágenes	**Máscaras**	**Contornos**
Cantidad	380	380	380

3.5 Método utilizado para la clasificación de la base de datos

La clasificación de los vídeos e imágenes tanto de la base de datos principal, como de la secundaria ha sido realizada por endoscopistas pertenecientes a los centros de salud participantes en la investigación.

En el caso del grupo de imágenes y vídeos sin lesiones, los especialistas indican en el informe endoscópico de la prueba correspondiente no haber detectado lesión alguna.

Para el grupo de vídeos e imágenes con lesiones, los especialistas indican en el informe endoscópico la catalogación del pólipo basada en las clasificaciones de Kudo y París.

Por último, en el caso de los vídeos e imágenes con mala preparación, a sabiendas que la calidad de preparación es evaluada mediante la ELCB y que ésta es dependiente de la interpretación del especialista, se ha decidido que dos endoscopistas evalúen todos los vídeos e imágenes de la base de datos. A todos y cada uno de ellos se les asigna una valoración de la ELCB. En el caso de los vídeos, todos aquellos que obtienen una puntuación menor o igual a 4 puntos se les considera mal preparados, por contrario los que han obtenido una puntuación mayor a 4 puntos son incluidos en el grupo "sin lesiones" o "con lesiones", en función de la presencia de éstas. En el caso de las imágenes, los especialistas evalúan todas y cada una de las imágenes otorgando una puntuación de 0 a 3 puntos basada en la ELCB. A continuación, la tabla 3.4 realiza un resumen de la clasificación de las imágenes y vídeos llevada a cabo.

Tabla 3.4: Clasificación de los vídeos e imágenes de la base de datos.

Puntuación ELCB	**Grupo**	**Posible subgrupo**
≤ 4	Mal preparada	-
>4	Bien preparada	Con lesiones / sin lesiones

3.6 Sumario

En este capítulo se han descrito las bases de datos utilizadas para la realización de la presente tesis doctoral. Además, se ha definido la población de referencia, criterios de selección, tamaño muestral y el método utilizado para la clasificación de la base de datos. Asimismo, se ha demostrado el cumplimiento del primer subobjetivo definido para la presente investigación (véase apartado 1.3 ≪Objetivos≫). Éste decía: "Crear una base de datos de vídeos e imágenes colonoscópicas".

"Good design is obvious. Great design is transparent."

Joe Sparano

CAPÍTULO

4

Diseño

Este es el capítulo central y más importante del presente trabajo, ya que presenta al lector todo lo relacionado con el sistema diseñado con el que se ha llevado acabo el experimento. Así, se explicarán en detalle las cuatro partes de las que consta: en primer lugar, el módulo de **preprocesado de imágenes colonoscópicas (A)**, en segundo lugar el módulo de **evaluación de la calidad de preparación del colon mediante la ELCB (B)**, en tercer lugar, el módulo de **detección automática de pólipos (C)** y en cuarto lugar, el módulo de **generación de informes (D)**.

El texto está a su vez dividido en **diseño de alto nivel** y **diseño de bajo nivel** para cada una de las partes de las que consta. De esta forma, el lector se hará una idea aproximada del sistema en su totalidad para posteriormente, poder profundizar en el mismo de la mejor manera posible, facilitando una correcta comprensión.

Finalmente, esto permitirá al lector afrontar los sucesivos capítulos de esta tesis con una perspectiva más adecuada.

4.1 Diseño de alto nivel

El diseño de esta tesis se divide en cuatro grandes bloques (véase figura 4.1) que sustentan la totalidad de la investigación. Estos son: preprocesado de imágenes

colonoscópicas (A), evaluación de la calidad de preparación del colon mediante la ELCB (B), detección automática de pólipos (C) y generación de informes (D).

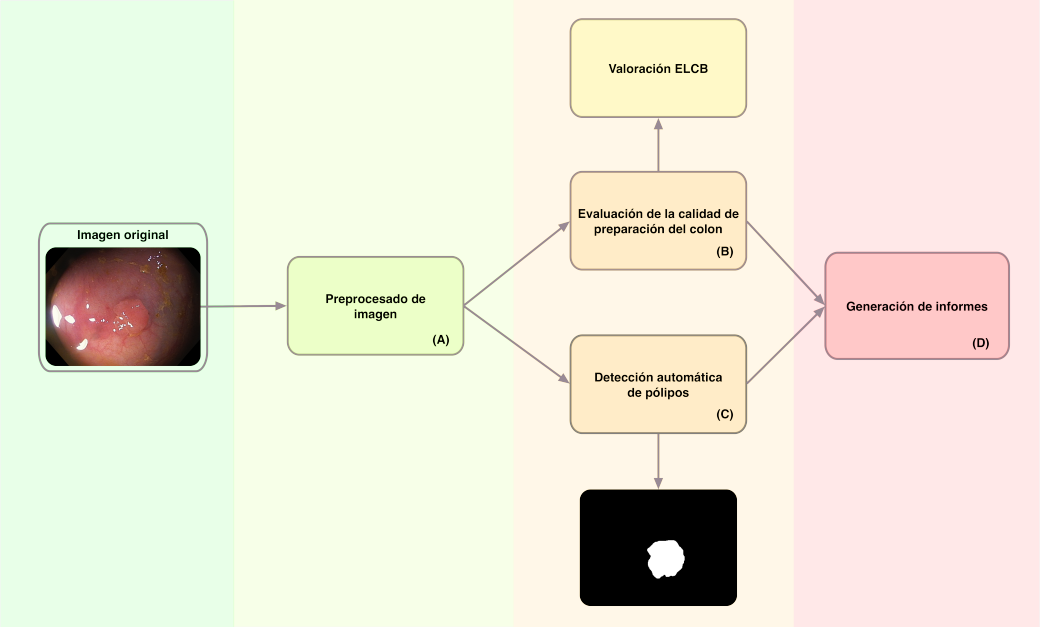


Figura 4.1: Diseño de alto nivel.

A continuación se describe cada uno de los bloques que forman el diagrama de alto nivel, indicando su funcionamiento y la descripción de entradas y salidas para cada uno de ellos.

4.1.1 Preprocesado de imágenes colonoscópicas (A)

El módulo de A es el encargado de realizar el preprocesado de las imágenes colonoscópicas obtenidas de los programas de cribado colorrectal. El objetivo perseguido con este proceso es el de conseguir algoritmos que mejoren la calidad o apariencia de las imágenes originales, las cuales en la mayoría de las ocasiones se ven afectadas por diversos efectos adversos. Con esto se pretende resaltar ciertas características de las mismas, así como también eliminar otras. En el caso que nos ocupa, las imágenes colonoscópicas, éstas suelen estar afectadas de forma general por los siguientes efectos adversos: bordes negros, reflejos especulares e iluminación no homogénea. Con el objetivo de mejorar la calidad de las imágenes colo-

noscópicas se ha diseñado y desarrollado el sistema de preprocesado de imágenes mostrado en la figura 4.2.

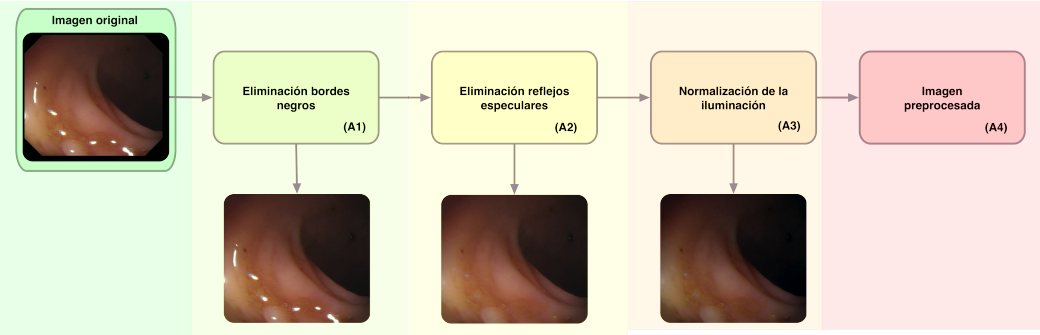


Figura 4.2: Preprocesado de imágenes colonoscópicas.

Como puede observarse, el sistema de preprocesado de imágenes consta de cuatro módulos: eliminación de bordes negros (A1), eliminación de reflejos especulares (A2), normalización de la iluminación (A3) e imagen preprocesada (A4). La entrada del sistema es una imagen colonoscópica directamente extraída de la prueba médica pertinente, siendo la salida del sistema el bloque A4 a partir del cual se dispone de una imagen preprocesada.

A continuación se realiza una breve descripción de cada uno de los bloques del sistema de preprocesado de imagen, indicando el motivo de su creación:

- Eliminación de bordes negros (A1): debido a las lentes del sistema de captura de imágenes colonoscópicas, éstas están rodeadas por un borde negro. En muchos casos es utilizado para mostrar información, bien del paciente, o de la prueba que se está realizando. Este marco dificulta las labores de desarrollo de algoritmos de PDI, ya que genera falsos bordes, además de suponer una mayor área a analizar que no aporta información útil. Por estos motivos se hace necesario aplicar diferentes técnicas para eliminar sus efectos.

- Eliminación de reflejos especulares (A2): los reflejos especulares son puntos brillantes de luz en la imagen debidos a la iluminación de objetos brillantes. Cuando una fuente de luz incide de forma directa sobre un objeto, ésta es reflejada y capturada de forma directa por la cámara. Este proceso genera zonas muy saturadas en la imagen que pueden generar bordes no deseados,

dificultando el posterior procesamiento de la imagen. Este efecto es de gran importancia en la investigación que se propone, ya que por un lado, eliminan información útil de la imagen que es necesaria reconstruir y por otro lado, generan bordes de forma circular que pueden ser confundidos como bordes de pólipos. Por todo esto es imprescindible eliminar sus efectos.

- Normalización de la iluminación (A3): las variaciones de intensidad y dirección de la iluminación son determinantes en la apariencia de los objetos en las imágenes digitales. La iluminación del colon mediante el sistema de colonoscopia es variante, lo que unido a la forma tridimensional del colon, hace que se generen sombras que acentúan o disminuyen ciertos aspectos de la imagen. Distintas condiciones de iluminación sobre un mismo objeto provocan representaciones desiguales del mismo, por lo que dicha variación de iluminación no es deseada y debe ser mitigada.

- Imagen preprocesada (A4): como salida del sistema de preprocesado se obtiene una imagen sin bordes negros, reflejos especulares y con la iluminación normalizada. De esta forma se dispone de una imagen lista para ser procesada por los algoritmos, tanto para la evaluación de la calidad de preparación del colon mediante la ELCB (B) como para la detección automática de pólipos (C).

Una vez las imágenes colonoscópicas son sometidas a las técnicas de preprocesado diseñadas, éstas cumplen con los requisitos de calidad suficientes para poder ser suministradas a los módulos de evaluación de la calidad de preparación del colon mediante la ELCB (B) y la detección automática de pólipos (C). De esta forma nos aseguramos que estos cumplan su cometido de una forma eficiente y eficaz.

4.1.2 Evaluación de la calidad de preparación del colon mediante la ELCB (B)

Tras realizar el preprocesado de las imágenes colonoscópicas, éstas son sometidas a la evaluación de su calidad de preparación mediante la ELCB. La eficacia de la colonoscopia se ve afectada de forma principal por dos aspectos: la destreza

del endoscopista y la calidad de preparación del colon. El conjunto de estos dos aspectos determinará la efectividad de la detección de pólipos. Una buena calidad de preparación del colon permitirá la visualización de todas las lesiones presentes, lo que evita la posibilidad de desarrollar un cáncer de intervalo. La investigación que se ha llevado a cabo se centra en la evaluación de la calidad de preparación del colon, haciendo uso para ello de la ELCB, habiéndose diseñado el sistema mostrado en la figura 4.3 para tal propósito.

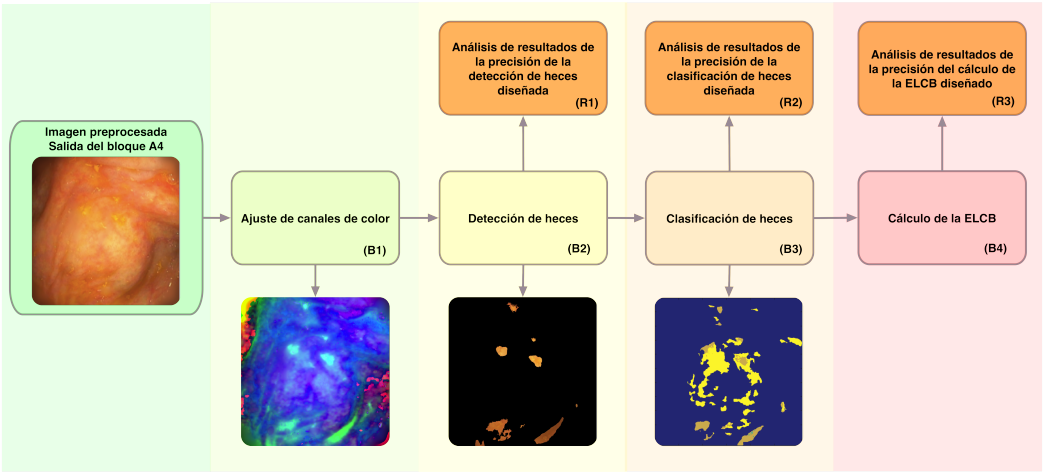


Figura 4.3: Evaluación de la calidad de preparación del colon haciendo uso de la ELCB.

El sistema de evaluación de la calidad de preparación del colon propuesto se compone de los siguientes bloques: ajuste de los canales de color (B1), detección de heces (B2), clasificación de heces (B3) y cálculo de la ELCB (B4). A continuación se realiza una descripción de cada uno de estos módulos:

- Ajuste de los canales de color (B1): las imágenes colonoscópicas tienen un rango de valores de color muy ajustado. Esto hace que los rangos de valores de intensidad del color entre las heces y el resto de elementos del colon aparezcan muy comprimidos solapándose sus valores. Por este motivo se hace necesario llevar a cabo un ajuste en los canales de color que expanda el rango de valores y así poder segmentar las heces de una forma más precisa.

- Detección de heces (B2): tras el ajuste de los canales de color se procede con la detección automática de las heces. Para ello se realiza un umbralizado en los canales H, S y V del modelo de color HSV. Asimismo, para evaluar el buen desempeño de este módulo, se ha diseñado un sistema de evaluación de la precisión de la detección de heces diseñada (bloque R1), cuyos resultados se tratarán en el apartado 5.2.1.1 ≪Análisis de resultados de la precisión de la detección de heces diseñada (R1)≫ del capítulo 5 ≪Resultados≫.

- Clasificación de las heces (B3): tal y como especifica la ELCB, no afectan de igual forma a la evaluación de la calidad de preparación los diferentes tipos de heces existentes. La propia escala hace una distinción entre heces líquidas, sólidas y tintadas, por lo que para poder realizar un cálculo preciso de la misma es necesario abordar una clasificación de ellas. Para evaluar el buen funcionamiento de este módulo se ha diseñado un sistema de evaluación de la precisión de la clasificación de heces (bloque R2), cuyos resultados se tratarán en el apartado 5.2.1.2 ≪Análisis de resultados de la precisión de la clasificación de heces diseñada (R2)≫ del capítulo 5 ≪Resultados≫.

- Cálculo de la ELCB (B4): una vez realizada la detección automática de las heces junto con su clasificación, se acomete el cálculo de la escala. Con este objetivo se ha diseñado una metodología que realiza el cálculo automatizado de la ELCB, basándose en el porcentaje de heces de cada tipo presente en las imágenes y el peso específico (importancia) otorgado a cada una de ellas. Para evaluar el buen desempeño de este módulo se ha diseñado un sistema de evaluación de la precisión del cálculo de la ELCB diseñado (bloque R3) que se llevará a cabo en el apartado 5.2.1.3 ≪Análisis de resultados de la precisión del cálculo de la ELCB diseñado (R3)≫ del capítulo 5 ≪Resultados≫.

La evaluación de la calidad de preparación del colon diseñada establece una estandarización de la ELCB que hasta la fecha dependía del criterio subjetivo del especialista restándole eficacia, ya que la valoración de una misma colonoscopia variaba en función del evaluador. De esta forma, se realizará un calculo preciso de la ELCB basado en criterios objetivos aportándole una mayor validez.

4.1.3 Detección automática de pólipos (C)

Una vez finalizado el preprocesado de las imágenes colonoscópicas, éstas son analizadas por el módulo de detección automática de pólipos diseñado. Se ha comentado con anterioridad que una de las principales problemáticas de las colonoscopias son las lesiones perdidas. El colon es un órgano con multitud de recovecos y pliegues, esto sumado a la posible presencia de heces y una iluminación lejos de ser óptima, hace de la detección de pólipos una ardua tarea. Por este motivo, se ha decidido desarrollar el sistema de detección automática de pólipos disponible en la figura 4.4, el cual se pretende que sirva de ayuda al diagnóstico.

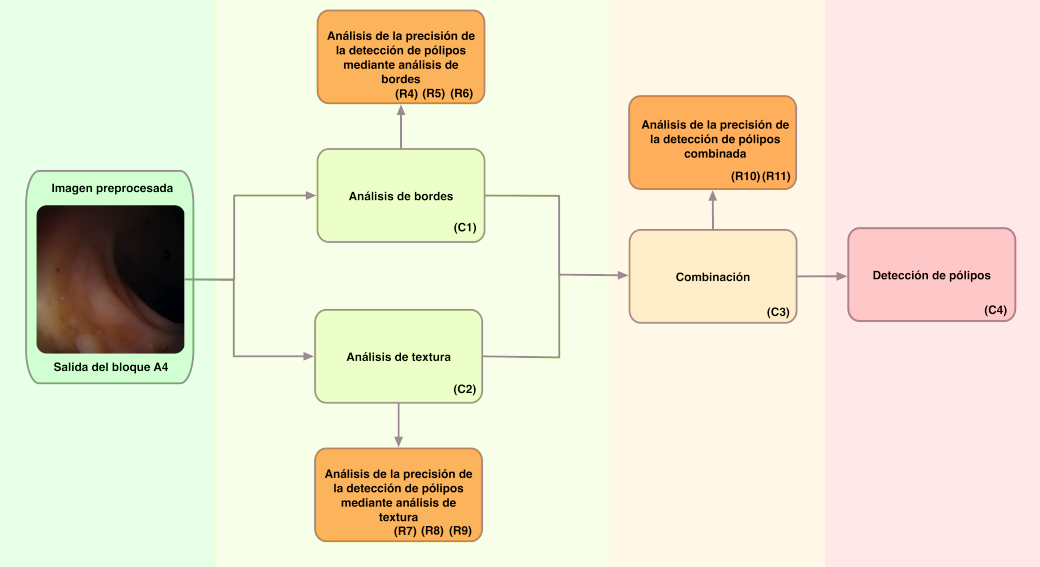


Figura 4.4: Detección automática de pólipos.

Los pólipos colorrectales son muy variantes en cuanto a su tamaño, forma, color y posicionamiento. Por estos motivos el diseño de un sistema de detección automática de pólipos tiene una alta dificultad. Para tratar de lidiar con ello se ha diseñado un sistema combinado que utiliza el análisis de los bordes y de la textura de las imágenes. El sistema de detección automática de pólipos diseñado está compuesto de los siguientes bloques: análisis de bordes (C1), análisis de textura (C2) y combinación (C3). A continuación se realiza una descripción de cada uno de estos módulos:

- Análisis de bordes (C1): los bordes generados por los pólipos en las imágenes colonoscópicas tienen unas propiedades diferentes a los bordes generados por otros elementos del colon. Por este motivo se ha decidido analizar los bordes detectados en los canales R, G y B de las imágenes colonoscópicas. Mediante la extracción de diferentes propiedades de la curvatura, intensidad y forma se permite distinguir aquellos bordes candidatos a ser pólipos de los que no. Todo esto, mediante un sistema de clasificación automático posibilita una detección automática de pólipos. Con el objetivo de evaluar la eficacia de este sistema, se ha diseñado un módulo para la evaluación de la precisión del sistema de detección de pólipos mediante el análisis de bordes propuesto, el cual se llevará a cabo en los apartados 5.2.2.1 ≪Análisis de la precisión de la clasificación mediante características de los bordes (R4)≫, 5.2.2.2 ≪Análisis de la precisión del área del pólipo detectada mediante el análisis de bordes (R5)≫ y 5.2.2.3 ≪Análisis de la precisión de la detección de pólipos mediante el análisis de bordes (R6)≫ del capítulo 5 ≪Resultados≫.

- Análisis de textura (C2): los pólipos presentes en las imágenes colonoscópicas presentan una textura particular que se diferencia de las paredes del colon y las heces. Por este motivo, es de sentido común que una de las alternativas existentes para la detección automática de pólipos esté basada en este principio. El proceso de análisis de la textura de las imágenes se realiza mediante diferentes operadores que extraen características de la imagen y que mediante un sistema de clasificación permite la detección automática de pólipos. Con el objetivo de evaluar la eficacia de este sistema se ha diseñado un módulo para la evaluación de la precisión del sistema de detección de pólipos mediante el análisis de la textura propuesto, el cual se llevará a cabo en los apartados 5.2.2.4 ≪Análisis de la precisión de la clasificación de las características de la textura (R7)≫, 5.2.2.5 ≪Análisis de la precisión del área del pólipo detectada mediante el análisis de la textura (R8)≫ y 5.2.2.6 ≪Análisis de la precisión de la detección de pólipos mediante el análisis de la textura (R9)≫ del capítulo 5 ≪Resultados≫.

- Combinación de los análisis de bordes y textura (C3): una vez realizado el análisis de los bordes y de la textura, es necesario efectuar una combinación

de ellos para obtener el resultado final. Por un lado, el análisis de los bordes obtiene su mayor eficacia cuando los pólipos están a media y larga distancia de la cámara. Esta situación permite capturar todo su contorno, pero no visualizar correctamente los patrones de textura con la definición deseada. Por otro lado, el análisis de la textura obtiene mejores resultados a corta distancia, es decir, cuando el pólipo está cerca de la cámara. En esta situación se observa de una forma muy definida la textura no pudiéndose detectar el contorno completo del pólipo. Por estos motivos, se ha creído que ambos enfoques son complementarios y pueden obtener unas altas tasas de detección de pólipos. Con el objetivo de evaluar la eficacia de este sistema se ha diseñado un módulo para la evaluación de la precisión del sistema de detección de pólipos combinado propuesto, el cual se llevará a cabo en los apartados 5.2.2.7 ≪Análisis de la precisión del área del pólipo detectada mediante el análisis combinado (R10)≫ y 5.2.2.8 ≪Análisis de la precisión de la detección de pólipos mediante el análisis combinado (R11)≫ del capítulo 5 ≪Resultados≫.

- Detección de pólipos (C4): efectuada la combinación del análisis de los bordes y de la textura se finaliza la detección automática de pólipos, obteniéndose una segmentación de la lesión en caso de haber sido localizada.

La detección automática de pólipos diseñada permitirá reducir la tasa de lesiones perdidas, haciendo de la colonoscopia una prueba diagnóstica más segura. De esta forma se incidirá de forma positiva en la salud de los pacientes que se someten a esta prueba diagnóstica, ya que se reducirá la posibilidad de desarrollar un cáncer de intervalo.

4.1.4 Generación de informes (D)

El módulo final de la tesis desarrollada es el referente a la generación de informes (D). Éste recoge la información de los sistemas de evaluación de la calidad de preparación del colon mediante la ELCB (B) y de detección automática de pólipos (C), ejecutados previamente para la generación de un informe de ayuda al diagnóstico que será utilizado por el especialista. La figura 4.5 muestra el diseño realizado para esta funcionalidad.

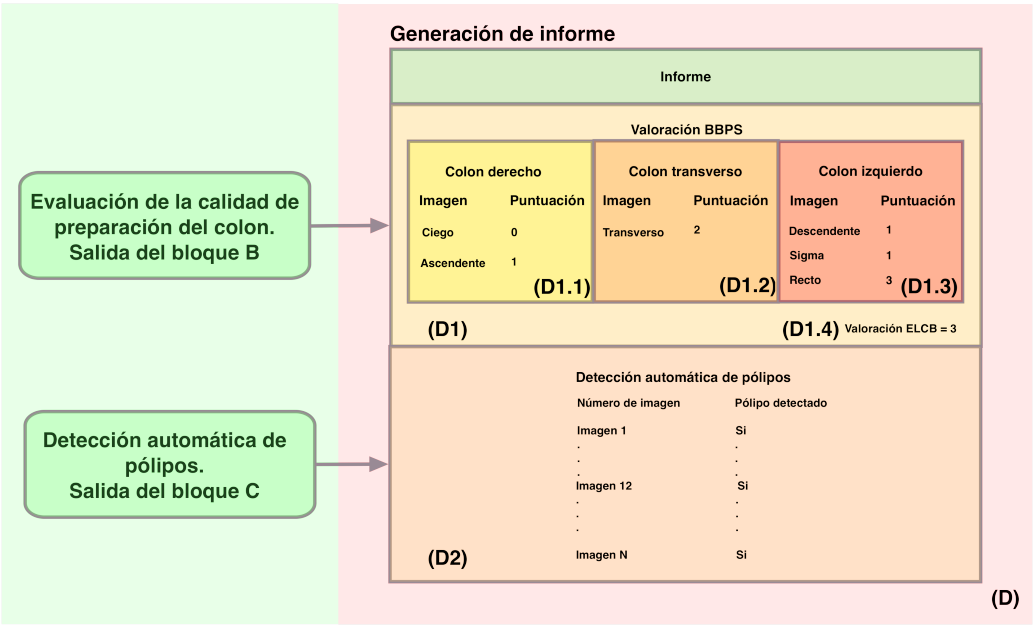


Figura 4.5: Generación de informes.

Como puede apreciarse tiene dos entradas, la evaluación de la calidad de preparación del colon (salida de módulo B) y la detección automática de pólipos (salida de módulo C). El informe generado se compone de dos partes, la valoración de la ELCB (D1) y la detección automática de pólipos (D2). A continuación se hace una descripción de cada una de ellas.

- Valoración de la ELCB (D1): la ELCB evalúa la calidad de preparación del colon dividiendo a éste en tres zonas: colon derecho, colon transverso y colon izquierdo. En el informe generado, estas zonas se corresponden con la información presentada en D1.1, D1.2 y D1.3. Para el cálculo de la valoración general de la ELCB mostrada en D1.4 se realiza la suma de la peor puntuación obtenida para cada una de las zonas (D1.1, D1.2 y D1.3). La evaluación de la calidad de preparación de cada una de las zonas ha sido consensuada con diferentes especialistas quedando definida de la siguiente forma:

  – Evaluación de la calidad de preparación del colon derecho (D1.1): para evaluar la calidad de preparación de esta zona del colon se analizan las imágenes del ciego y ascendente proporcionadas por el especialista. La

puntuación más baja de ambas imágenes será la utilizada para el cálculo de la valoración de la ELCB general.

  - Evaluación de la calidad de preparación del colon transverso (D1.2): para la evaluación de la calidad de preparación de esta zona del colon se analiza la imagen del colon transverso proporcionada por el especialista. La valoración de esta imagen será la utilizada para el cálculo de la valoración de la ELCB general.
  - Evaluación de la calidad de preparación del colon izquierdo (D1.3): para evaluar la calidad de preparación de esta zona del colon se analizan las imágenes del colon descendente, sigma y recto, proporcionadas por el especialista. La puntuación más baja de las tres imágenes será la utilizada para el cálculo de la valoración de la ELCB general.

- Detección automática de pólipos (D2): este apartado incluye los identificativos de las imágenes en las que se ha detectado algún pólipo. Para tratar de reducir al mínimo la extensión del informe sólo se incluyen los identificativos de las imágenes en las que se han detectado pólipos.

Gracias al informe generado se aúna la información obtenida de los diferentes módulos que componen la tesis doctoral llevada a cabo. De esta manera se facilita la interpretación de los resultados por parte de los especialistas, proporcionándoles una ayuda al diagnóstico y haciéndoles ahorrar un valioso tiempo.

4.2 Diseño de bajo nivel

En este apartado se va a especificar cada uno de los bloques que componen el diseño de alto nivel visto de forma previa. Para cada uno de ellos se detalla exhaustivamente el proceso que se realiza, las entradas que recibe cada bloque y sus salidas. Además de esta descripción se presentarán diagramas para una mejor comprensión.

4.2.1 Preprocesado de imágenes colonoscópicas (A)

El primer módulo de la presente tesis doctoral es el de preprocesado de imágenes colonoscópicas (véase figura 4.6). La adecuación de las imágenes a un estándar de

calidad mínimo es requisito indispensable para cualquier sistema de PDI. No es una excepción el caso que nos ocupa, en el que se requiere de un proceso de mejora de la calidad y resaltado de ciertas características de las imágenes. Éstas suelen verse afectadas por diversos artefactos que distorsionan su calidad, esto es debido en gran medida al difícil entorno en el que son obtenidas.

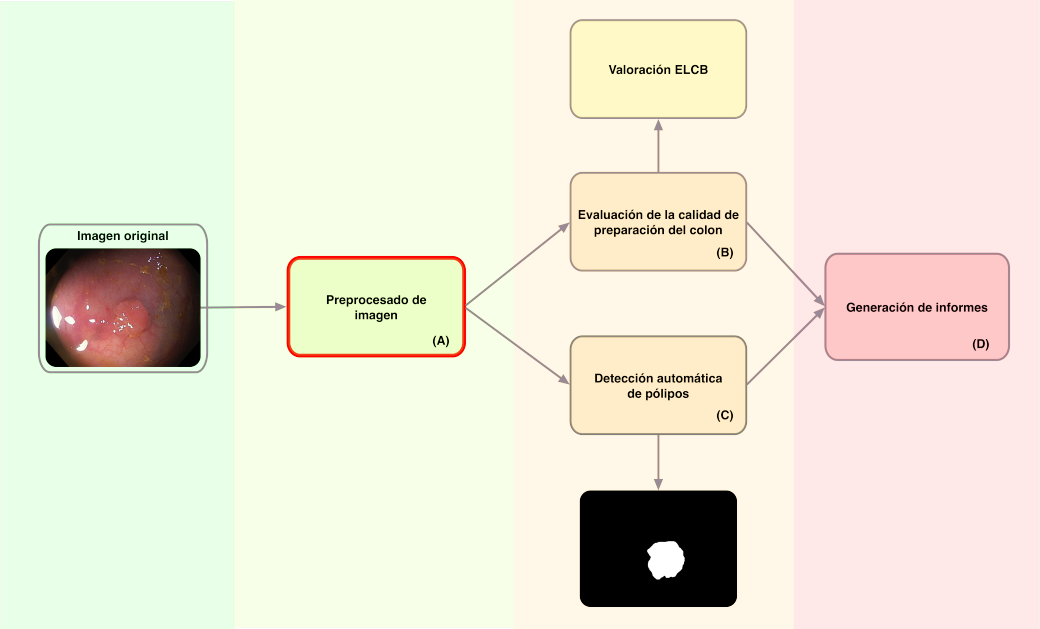


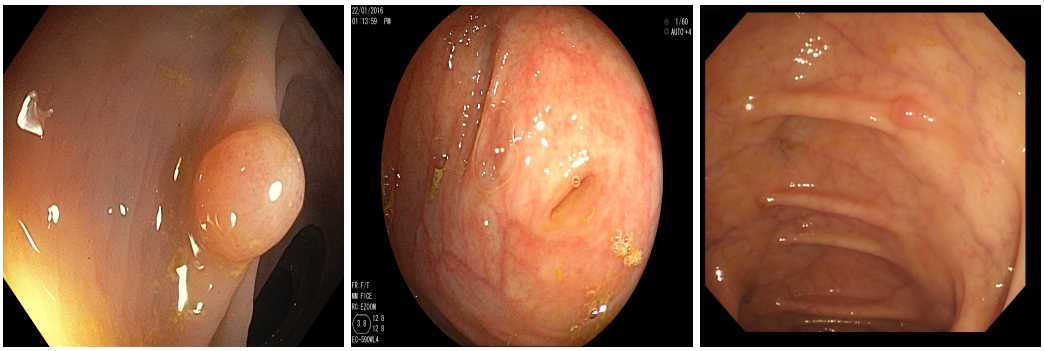
Figura 4.6: Módulo A. Preprocesado de imágenes colonoscópicas.

El proceso de captura de imágenes en el interior del colon tiene que lidiar con diversos factores que dificultan una toma de calidad. Algunas de estas complicaciones son: liquido, iluminación no homogénea o reflejos especulares. Para tratar de solucionar todos estos inconvenientes se ha diseñado un módulo de preprocesado de imágenes colonoscópicas compuesto por los siguientes bloques: eliminación de bordes negros (A1), eliminación de reflejos especulares (A2) y normalización de la iluminación (A3). Este sistema tiene como entrada una imagen colonoscópica recién capturada por el colonoscopio que se ve afectada por diversas alteraciones. Tras ser procesada por el presente sistema se obtiene una imagen sin bordes negros ni reflejos especulares, además de tener una iluminación más homogénea (resultado del bloque A4). De esta forma se consigue una imagen lista para ser tratada por los módulos diseñados para la presente tesis, es decir, el módulo B de evaluación de la

calidad de preparación del colon mediante la ELCB y el C referente a la detección automática de pólipos. A continuación se realizará una descripción pormenorizada de cada uno de los bloques que constituyen este módulo.

4.2.1.1 **Eliminación de bordes negros (A1)**

El primer paso para conseguir una imagen colonoscópica preprocesada es la eliminación de los bordes negros que se encuentran rodeando a la imagen. Estos son debidos a las lentes del sistema de captura de imágenes colonoscópicas. Dependiendo del modelo de colonoscopio utilizado, los bordes negros generados varían (véase figura 4.7), lo que dificulta las labores de preprocesado. En muchos casos los bordes se utilizan para mostrar información, bien del paciente o de la prueba que se está realizando (véase imagen 4.7(b)). Este marco dificulta las labores de desarrollo de algoritmos de PDI, ya que genera falsos bordes, además de suponer una mayor área a analizar que no aporta información útil. Por estos motivos se hace necesario aplicar diferentes técnicas para eliminar sus efectos.



(a) (b) (c)

Figura 4.7: Máscaras negras con diferentes características: a) Máscara negra en las esquinas. b) Máscara negra circular y con información. c) Máscara negra bordeando a la imagen.

En la literatura existen diferentes enfoques para tratar esta problemática, estos son: reconstrucción de los bordes mediante una restauración de los mismos [BSV13], la utilización de umbrales para su detección [WCLS12] y el recorte de

la máscara negra. En el sistema de preprocesado diseñado se ha optado por un enfoque combinado de las soluciones existentes. En él se realiza una detección de la máscara negra mediante la utilización de umbrales, además de hacer un recorte y reconstrucción de la máscara. La figura 4.8 muestra el proceso mediante el cual se realiza esta tarea.

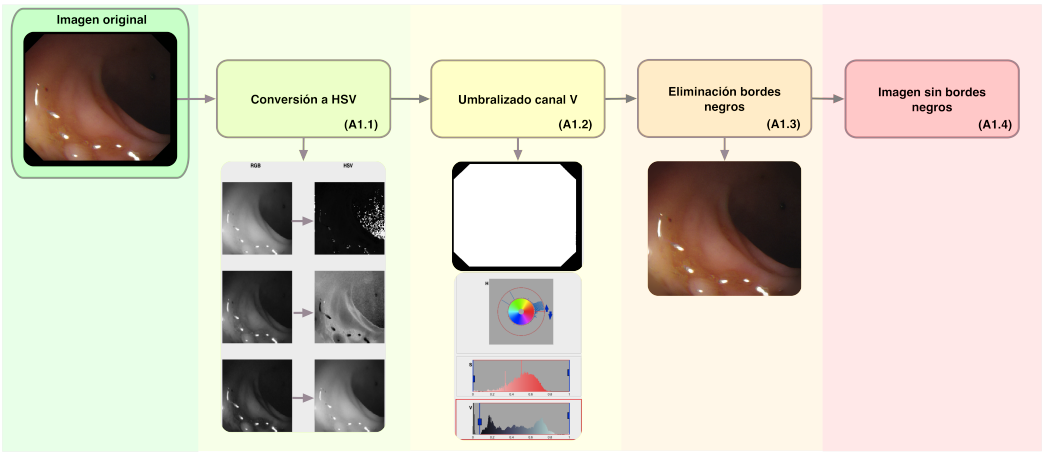


Figura 4.8: Eliminación de bordes negros.

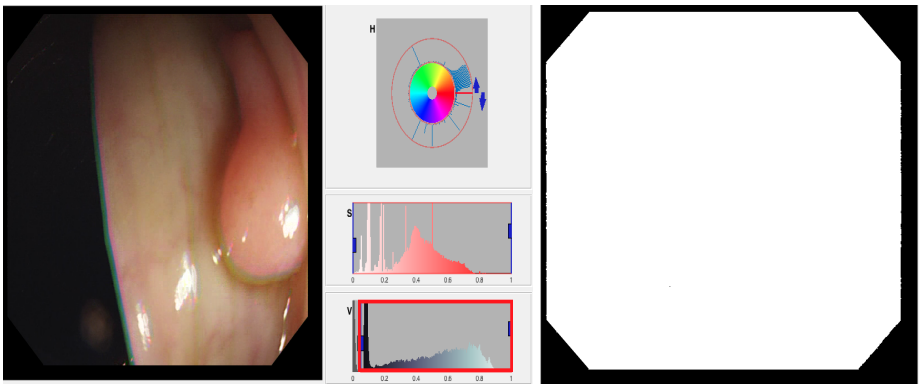
En los siguientes apartados se realiza una completa descripción de los bloques que componen la figura 4.8, es decir: conversión a HSV (A1.1), umbralizado del canal V (A1.2), eliminación de bordes negros (A1.3) e imagen sin bordes negros (A1.4).

Conversión a HSV (A1.1)

Para poder abordar la detección automática de la máscara negra en las imágenes colonoscópicas es necesaria su conversión desde el modelo de color RGB, modelo de color original de las imágenes colonoscópicas, al modelo de color HSV. Esto es debido a que el modelo RGB hace más difícil la especificación de colores concretos, en cambio este es uno de los puntos fuertes del modelo de color HSV. Gracias a ello se hace mucho más sencilla la labor de umbralizado que se explica en el siguiente apartado.

Umbralizado del canal V (A1.2)

Una vez realizada la conversión desde el modelo de color RGB al HSV la imagen se encuentra preparada para su umbralización. La umbralización permite seleccionar diversos rangos de valores de intensidad, de forma que los objetos que queramos detectar automáticamente queden definidos dentro de ellos. En el presente trabajo se propone una umbralización del canal V, en el que los valores que sean menores a 0.03 pertenecen a la mascara negra. De esta forma se permite separar el contenido útil de la imagen colonoscópica de los bordes negros. Este proceso puede verse en la figura 4.9, en el que la imagen 4.9(a) muestra el proceso de umbralización del canal V y la imagen 4.9(b) presenta el resultado generado.

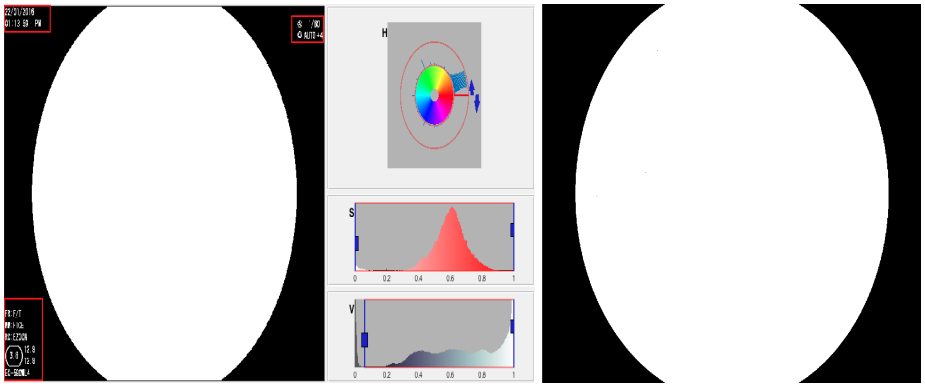


(a) (b)

Figura 4.9: Umbralizado para la detección de bordes negros: a) Umbralización del canal V resaltado en rojo. b) Resultado de la umbralización.

Al comienzo de este apartado se ha comentado que en función del modelo de colonoscopio utilizado para la captura de las imágenes, los bordes negros serán diferentes. El ejemplo más extremo es el mostrado por la imagen 4.7(b), la cual contiene información sobre la prueba realizada. Esto es un problema, ya que al realizar el umbralizado para la detección de los bordes negros, se mantendrá en la imagen la información mostrada en ella. Para abordar su eliminación es necesario un paso adicional que consiste en la realización de una apertura morfológica mediante una estructura de disco de tamaño 5 sobre la máscara detectada. De esta forma se elimina toda la información que se mostraba en la máscara, quedando

ésta limpia. Este proceso se puede observar en la figura 4.10, en la que la imagen 4.10(a) muestra la máscara negra detectada con los restos de información y la imagen 4.10(b) presenta el resultado de la apertura morfológica para la eliminación de ésta.



(a) (b)

Figura 4.10: Umbralizado para la detección de bordes negros: a) Bordes negros con información resaltada en rojo. b) Resultado de la apertura morfológica.

Una vez finalizada la umbralización de la imagen se procede a realizar la eliminación de los bordes negros.

Eliminación de bordes negros (A1.3)

El proceso de eliminación de los bordes negros consta de dos pasos: recorte y reconstrucción. En las siguientes líneas se realiza una descripción en detalle de cada uno de ellos.

Recorte de bordes negros: la decisión de recortar los bordes negros se debe a motivos de eficiencia computacional. Al realizar esta operación, la imagen a tratar tiene unas dimensiones más reducidas pero con la misma cantidad de información, es decir, sólo se eliminan de la imagen los bordes negros que no aportan información válida. El proceso de recorte de los bordes consta de los siguientes pasos:

1. Detección del punto central superior no perteneciente a la máscara negra: se comienza desde el píxel de la posición $(max(X)/2, 1)$ buscando en dirección Sur el primer píxel no perteneciente al borde negro.

2. Detección del punto central inferior no perteneciente a la máscara negra: se comienza desde el píxel de la posición $(max(X)/2, max(Y))$ buscando en dirección Norte el primer píxel no perteneciente al borde negro.

3. Detección del punto central izquierdo no perteneciente a la máscara negra: se comienza desde el píxel de la posición $(1, max(Y)/2)$ buscando en dirección Este el primer píxel no perteneciente al borde negro.

4. Detección del punto central derecho no perteneciente a la máscara negra: se comienza desde el píxel de la posición $(max(X), max(Y)/2)$ buscando en dirección Oeste el primer píxel no perteneciente al borde negro.

Una vez obtenidas las 4 posiciones de los píxeles buscados se genera el rectángulo que los contiene y que será quien determinará las dimensiones de la imagen con los bordes negros recortados. La figura 4.11 muestra un ejemplo visual de este proceso. El siguiente paso a la hora de eliminar los bordes negros es la reconstrucción de los restos de los bordes negros. Este proceso se aborda en el siguiente apartado.

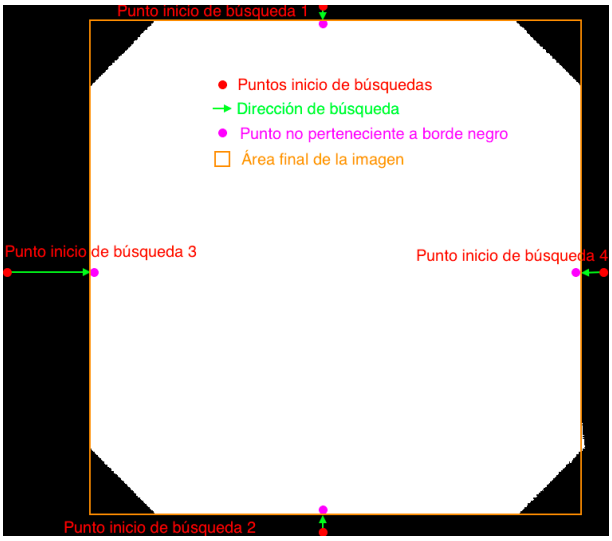
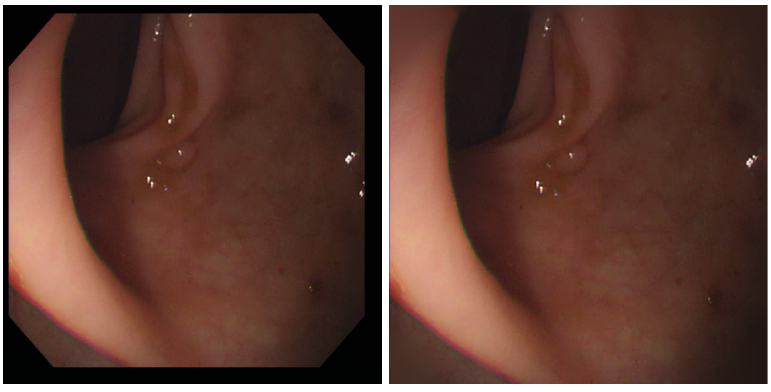


Figura 4.11: Proceso de recorte de los bordes negros.

Reconstrucción de los restos de la máscara negra: puede observarse en la figura 4.11 que en el área final de la imagen delimitada en color naranja siguen apareciendo restos de los bordes negros de la imagen. La última tarea para su eliminación es la reconstrucción de estos. Para ello se aplica una restauración que trata de reemplazar los píxeles de la máscara negra por la media de los valores de los píxeles de una vecindad determinada. Esta operación se realiza de forma repetitiva hasta que la diferencia de los valores medios de los píxeles reconstruidos y la de la media de los valores de los píxeles vecinos utilizados para la reconstrucción sea menor a un valor prefijado. Una vez realizada la reconstrucción de los bordes negros, es necesario un proceso de suavizado para evitar cambios abruptos entre las zonas reconstruidas y las no pertenecientes a los bordes negros. Este proceso de suavizado se explica más en profundidad en el apartado 4.2.1.2 ≪Eliminación de reflejos especulares (A2)≫.

Imagen sin bordes negros (A1.4)

Tras la realización de todos los procesos diseñados para la eliminación de los bordes negros se obtiene una imagen con las dimensiones reducidas y los bordes negros reconstruidos. El resultado obtenido se puede ver en la figura 4.12, en la que la imagen 4.12(a) muestra la imagen original sin tratar y la imagen 4.12(b) proporciona el resultado obtenido por este proceso.



(a) (b)

Figura 4.12: Resultado de la eliminación de los bordes negros: a) Imagen original con bordes negros. b) Resultado de la eliminación de los bordes negros.

Para continuar con el preprocesado de las imágenes colonoscópicas, en el siguiente apartado se tratará la eliminación de los reflejos especulares.

4.2.1.2 Eliminación de reflejos especulares (A2)

Los reflejos especulares se deben a la reflexión de la luz emitida por la linterna del colonoscopio sobre la propia cámara del dispositivo. Como consecuencia se generan zonas en la imagen con una alta intensidad que hacen que se pierda información de la misma. La aparición de reflejos especulares en la investigación genera dos principales efectos adversos:

- Efectos en la evaluación de la calidad de preparación del colon mediante la ELCB: debido a la pérdida de información provocada por los reflejos especulares no es posible calcular con la precisión deseada el porcentaje de heces presente en la imagen, así como tampoco la clasificación de las mismas.

- Efectos en la detección automática de pólipos: dado que los reflejos especulares en muchos casos tienen forma circular, a la hora de realizar una detección de bordes, los contornos debidos a los reflejos especulares y pólipos pueden presentar similitudes que generen un mal funcionamiento de los algoritmos diseñados para la detección automática.

Por estos motivos se hace necesario el diseño de un sistema para la eliminación de los reflejos especulares en las imágenes colonoscópicas. En la figura 4.13 se muestra el diseño propuesto para la eliminación de los mismos.

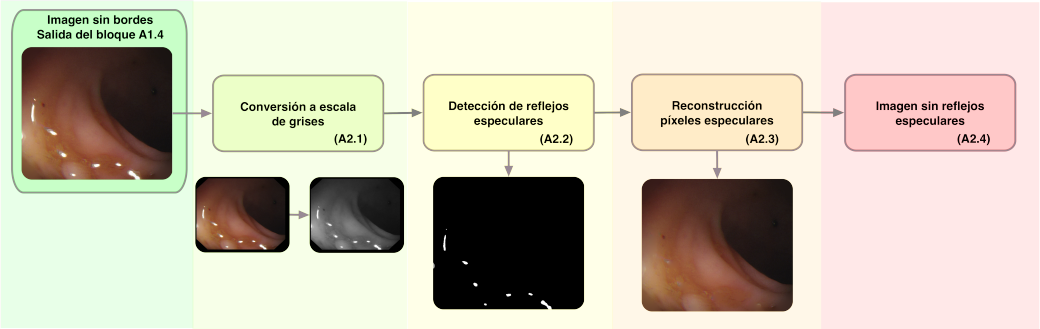


Figura 4.13: Eliminación de los reflejos especulares.

En los siguientes apartados se realiza una completa descripción de los bloques que componen la figura 4.13, es decir: conversión a escala de grises (A2.1), detección de reflejos especulares (A2.2), reconstrucción de píxeles especulares (A2.3) e imagen sin reflejos especulares (A2.4).

Conversión a escala de grises (A2.1)

Para comenzar con el proceso de eliminación de los reflejos especulares, es necesario convertir la imagen sin bordes negros obtenida del módulo A1.4 desde el modelo de color original (RGB) a escala de grises. Esta operación es necesaria para la posterior detección de los reflejos especulares que se describe en el próximo apartado.

Detección de reflejos especulares (A2.2)

La metodología utilizada para la detección de los reflejos especulares ha sido la propuesta por los autores del trabajo de investigación [BSV13]. Para ello se ha diseñado un sistema compuesto por cuatro bloques, el cual se muestra en la figura 4.14. En los siguientes apartados se hace una descripción detallada del proceso de eliminación de los reflejos especulares propuesto para esta investigación.

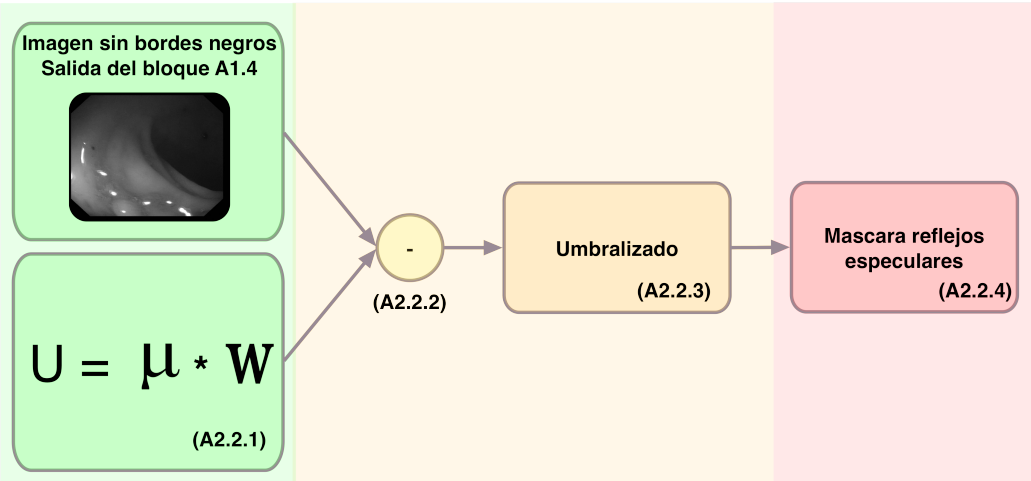


Figura 4.14: Detección de los reflejos especulares. μ representa el valor medio de la imagen sin bordes negros y W el factor multiplicador (0.3 por defecto).

Cálculo del valor umbral (U) (A2.2.1): para detectar de forma automática los reflejos especulares es imprescindible fijar un valor umbral (U) que discrimine entre valores normales en la imagen y reflejos especulares. Para ello se calcula el valor medio de la imagen original (μ) en escala de grises, siendo este valor multiplicado por un peso (W) que por defecto tiene un valor de 0.3. De esta forma se calcula el valor necesario para afrontar el siguiente paso en la detección de los reflejos especulares.

Resta de la imagen original en escala de grises y el valor umbral (A2.2.2): una vez el valor umbral (U) haya sido calculado se realiza la resta de la imagen original en escala de grises con el valor umbral (U). De esta forma se obtiene una matriz de iguales dimensiones que la imagen en escala de grises, en la que los valores que sean mayores a 0.75 pertenecen a los reflejos especulares.

Umbralizado (A2.2.3): habiéndose calculado la matriz con los valores pertenecientes a la resta entre la imagen original en escala de grises y el valor umbral (U), se generará una máscara binaria en la que los valores que han superado el umbral (U) pasan a tener valor 1 y el resto valor 0, de forma que se obtiene una imagen que sólo muestra las posiciones de los reflejos especulares detectados.

Máscara con reflejos especulares (A2.2.4): como resultado de este proceso se obtiene una máscara que será utilizada en el siguiente paso, quien será el encargado de la reconstrucción de los reflejos.

Reconstrucción de píxeles especulares (A2.3)

Una vez obtenida la máscara que calcula las posiciones de los reflejos especulares se puede realizar el proceso de reconstrucción de los mismos. Este es un complejo procedimiento que ha ido evolucionando a lo largo de los años. Al principio se basaba en técnicas aplicadas en el dominio de la frecuencia, pero ha ido derivando a lo que es en la actualidad, un método algebraico basado en la manipulación de grandes sistemas de ecuaciones. La metodología de la reconstrucción se resume en cuatro pasos que se describen a continuación:

1. La sección dañada se rellena utilizando información del resto de la imagen.
2. La estructura de la zona circundante a la parte deteriorada es rellenada hacia su interior, prolongando las líneas que llegan al borde.
3. Las diversas regiones que se generan dentro de la zona dañada a partir de la prolongación de las líneas de contorno, son rellenadas con el color de la correspondiente región de la frontera.
4. Finalmente, se pintan los pequeños detalles para mantener la uniformidad.

El algoritmo realiza repetidamente los pasos 2 y 3 hasta conseguir la calidad deseada. Para ejecutar el algoritmo se necesita traducir los conceptos de la restauración expresados anteriormente a lenguaje matemático. Teniendo una imagen bidimensional en tonos de grises definida por la ecuación 4.1.

$$I_O\left(i,j\right):\left[0,M\right]\times\left[0,N\right]\rightarrow\mathbb{R}\; con\left[0,M\right]\times\left[0,N\right]\;\subset\;\mathbb{N}\times\mathbb{N} \tag{4.1}$$

Se realiza la reconstrucción de un conjunto de imágenes a partir de la ecuación 4.2.

$$I\left(i,j,n\right):\left[0,M\right]\times\left[0,N\right]\times\mathbb{N}\rightarrow\mathbb{R} \tag{4.2}$$

De manera que se obtiene la ecuación 4.3.

$$I\left(i,j,0\right)=I_0\left(i,j\right),\lim_{n\rightarrow\infty}I\left(i,j,n\right)=I_R\left(i,j\right) \tag{4.3}$$

Pudiendo ser definido el método de forma general como la ecuación 4.4.

$$I^{n+1}\left(i,j\right)=I^n\left(i,j\right)+\Delta tI_t^n\left(i,j\right),\;\forall\left(i,j\right)\epsilon\,\Omega \tag{4.4}$$

I_R representa la imagen reconstruida, n determina el tiempo de restauración, i,j son las coordenadas del píxel, Δt es la tasa de mejora, $I_t^n(i,j)$ es la actualización de la imagen $I^n(i,j)$ y Ω es la región a ser restaurada.

La figura 4.15 proporciona el sistema diseñado para la eliminación de los reflejos especulares. El proceso se compone de tres bloques, dilatación de la máscara de reflejos especulares (A2.3.1), reconstrucción de la imagen (A2.3.2) y suavizado de la reconstrucción (A2.3.3). Para ello se requiere como entrada la imagen original con reflejos especulares (salida de módulo A1.4), además de la máscara que indica las posiciones de los reflejos especulares detectados (salida de módulo A2.2.4). A continuación se realiza una descripción en detalle de cada uno de estos bloques.

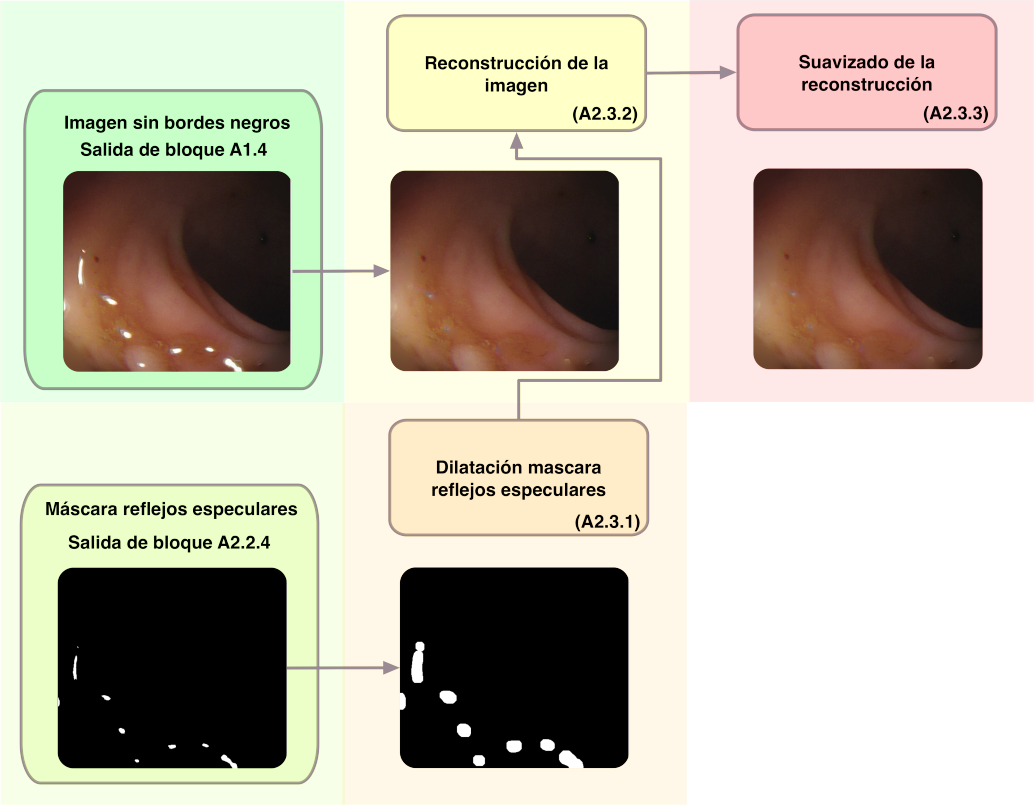


Figura 4.15: Sistema de eliminación de los reflejos especulares.

Dilatación de la máscara de reflejos especulares (A2.3.1)

El primer paso a realizar es la dilatación de la máscara de los reflejos especulares. Esto se debe a que a la hora de hacer la reconstrucción se escogen los píxeles no especulares vecinos a los reflejos. De esta forma nos aseguramos no utilizar píxeles especulares en la reconstrucción. La dilatación se realiza mediante una estructura de disco de tamaño 5.

Reconstrucción de la imagen (2.3.2)

Una vez que se ha realizado la dilatación de la máscara de los reflejos especulares, se puede comenzar a reconstruir las regiones de la imagen indicadas por la máscara, siguiendo el proceso definido al comienzo del apartado ≪Reconstrucción de píxeles especulares (A2.3)≫. Una vez reconstruidos los reflejos especulares es necesario

realizar un suavizado de los mismos. Este paso se describe en el próximo apartado.

Suavizado de la reconstrucción (A2.3.3)

Es sabido que no es válida la realización de la reconstrucción sin un suavizado posterior. Esto es debido a que a pesar de haber sido reconstruidas las zonas deterioradas con los valores medios de los píxeles vecinos, aún se percibe un cambio abrupto en los límites de la reconstrucción. Para superar esta adversidad se ha diseñado el módulo de suavizado descrito por la figura 4.16.

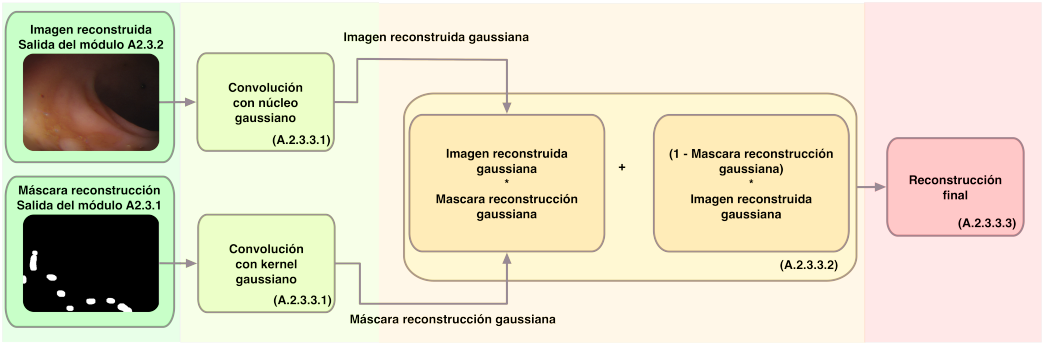
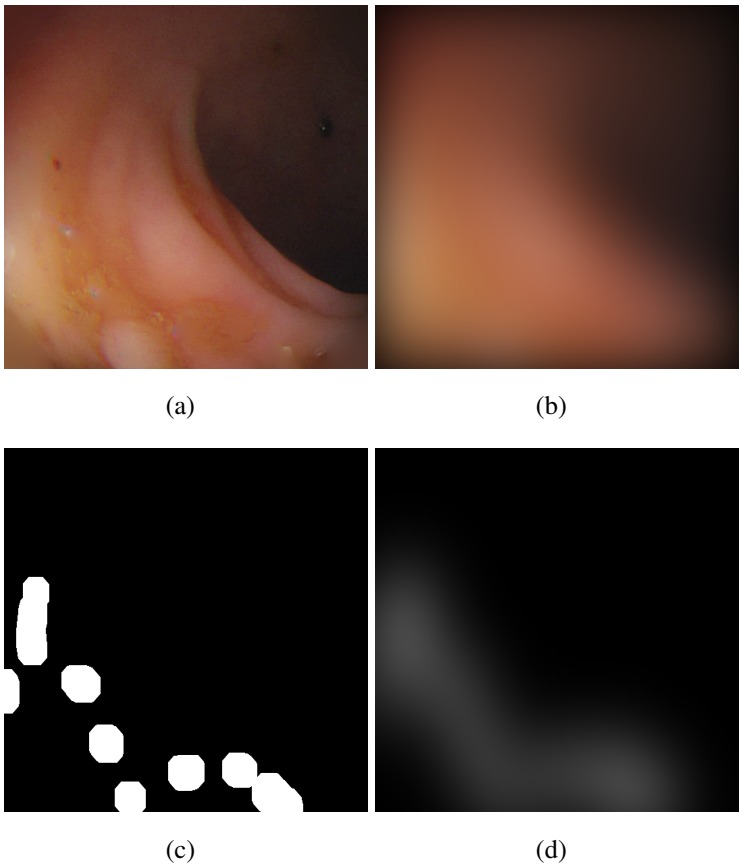


Figura 4.16: Mezcla de la reconstrucción de los reflejos especulares.

Este módulo tiene como entradas la imagen reconstruida (salida del bloque A2.3.2) y la máscara de los reflejos especulares dilatada (salida de bloque A2.3.1) y se compone de tres pasos: convolución de las imágenes con núcleos gaussianos (A2.3.3.1), mezcla de las imágenes (A2.3.3.2) y por último, la reconstrucción final (A2.3.3.3) que es la salida del módulo. A continuación se describe este proceso en mayor detalle.

Convolución de las imágenes con núcleos gaussianos (A2.3.3.1): la mezcla de la reconstrucción de los reflejos especulares comienza con la convolución de la imagen reconstruida y la máscara dilatada de los reflejos especulares con un núcleo gaussiano. De esta forma se consigue un difuminado de ambas imágenes que permitirá su posterior mezclado. El resultado de las convoluciones puede verse en la figura 4.17, en la que la imagen 4.17(a) muestra la imagen sin reflejos especulares

previa al mezclado, la imagen 4.17(b) muestra su convolución por un núcleo gaussiano, la imagen 4.17(c) muestra la máscara dilatada de los reflejos especulares y por último, la imagen 4.17(d) su convolución por un núcleo gaussiano.



(a) (b)

(c) (d)

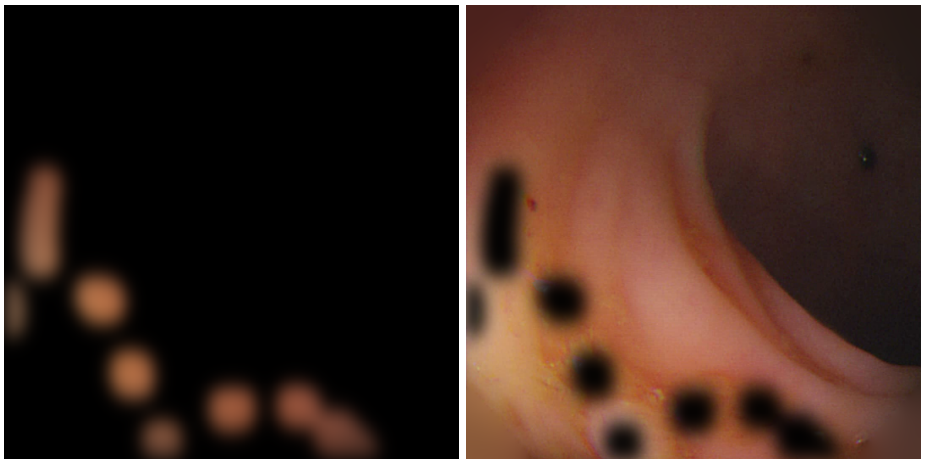
Figura 4.17: Convolución de las imágenes con núcleos gaussianos. a) Imagen sin reflejos especulares. b) Imagen sin reflejos especulares convolucionada con un núcleo gaussiano. c) Máscara de los reflejos especulares dilatada. d) Máscara de los reflejos especulares dilatada y convolucionada con un núcleo gaussiano.

Una vez finalizado este proceso se pasará a la mezcla de las imágenes haciendo uso de las imágenes difuminadas conseguidas.

Mezcla de las imágenes (A2.3.3.2): este es el paso más importante de la reconstrucción, ya que de él dependerá la calidad de la misma. En primer lugar se realiza la multiplicación de cada uno de los canales (R, G y B) de la imagen

reconstruida gaussiana por la máscara de los reflejos especulares dilatada gaussiana (véase imagen 4.18(a) de la figura 4.18).

Con ello se consigue obtener los píxeles de la imagen reconstruida gaussiana que vienen definidos en la máscara de los reflejos especulares gaussiana, con la particularidad de que los píxeles centrales de la máscara tienen una mayor definición que los exteriores. Esto nos permite la mezcla suavizada de la reconstrucción. Con este paso se consigue el contenido de la imagen reconstruida mezclada de los reflejos especulares, pero aún sigue faltando el contenido del resto de la imagen, es decir, las zonas no especulares. Esto se realiza multiplicando $1 - M_{reconstruccion\ gaussiana} \times \ I_{reconstruida\ gaussiana}$ (véase imagen 4.18(b) de la figura 4.18). De esta forma se finaliza el módulo de mezclado de la reconstrucción de los reflejos especulares, siendo este el último paso a realizar.

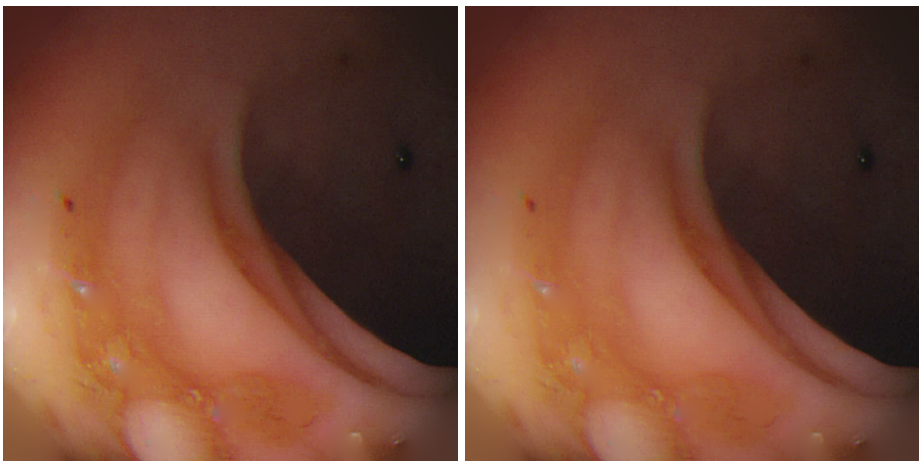


(a) (b)

Figura 4.18: Mezcla de las imágenes. a) Máscara de los reflejos especulares dilatada gaussiana multiplicada por la imagen reconstruida. b) Inversa de la máscara de los reflejos especulares dilatada gaussiana multiplicada por la imagen reconstruida.

Reconstrucción final (A2.3.3.3): como salida de este módulo se consigue una imagen sin reflejos especulares en la que se ha realizado un suavizado de la reconstrucción. Estas operaciones son muy sutiles (véase figura 4.19), aunque en

muchos casos no son apreciables a simple vista son imprescindibles para el correcto funcionamiento de los algoritmos a aplicar en las imágenes.



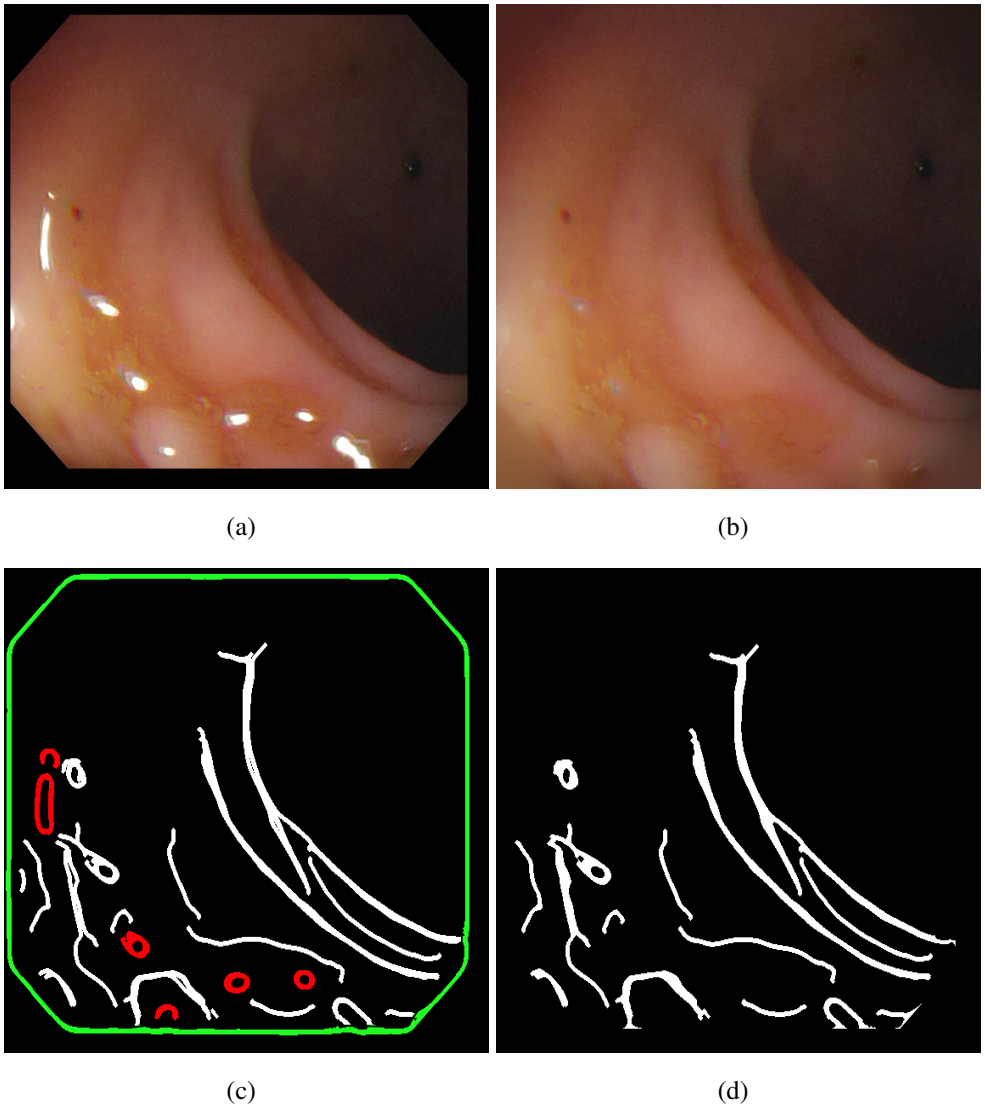
(a) (b)

Figura 4.19: Resultado final de la eliminación de los reflejos especulares. a) Imagen con reflejos especulares reconstruidos sin suavizado. b) Imagen con reflejos especulares reconstruidos con suavizado.

Imagen sin reflejos especulares (A2.4)

Como salida de este módulo se obtiene una imagen libre de los efectos adversos provocados por los reflejos especulares. De esta forma se puede afrontar la evaluación de la calidad de preparación del colon mediante la ELCB y la detección automática de pólipos con mayores garantías, aunque no sin antes realizar una normalización de la iluminación, último bloque del preprocesado de imágenes planteado. En la figura 4.20 se hace una representación gráfica del resultado de la reconstrucción de los reflejos especulares. La imagen 4.20(a) muestra una imagen colonoscópica sin ningún tipo de preprocesado en la que se observan tanto reflejos especulares como bordes negros. Como consecuencia de ellos se observa en la imagen 4.20(c) como aparecen bordes de forma circular debidos a los reflejos especulares (bordes coloreados en rojo) y un borde debido a la máscara negra (borde verde). Una vez eliminados los bordes negros y reflejos especulares se puede ver

en la imagen 4.20(b) el aumento de calidad experimentado, además de desaparecer multitud de bordes no deseados (véase figura 4.20(d)).



(a) (b)

(c) (d)

Figura 4.20: Resultado de la eliminación de los reflejos especulares. a) Imagen original. b) Imagen sin bordes negros ni reflejos especulares. c) Bordes de la imagen original (bordes especulares en rojo). d) Bordes de la imagen sin máscara negra ni reflejos especulares.

Siguiendo con el preprocesado de las imágenes colonoscópicas, en el siguiente apartado se describe el módulo de normalización de la iluminación diseñado.

4.2.1.3 Normalización de la iluminación (A3)

El último paso para conseguir una imagen colonoscópica preprocesada lista para ser analizada por los algoritmos diseñados en este trabajo es la normalización de la iluminación. Debido al difícil entorno en el que se adquieren las imágenes se obtiene una iluminación no uniforme que hace que el color de un mismo elemento en la imagen tenga cambios en las intensidades no deseadas. Para tratar de lidiar con esta problemática se ha diseñado el módulo para la normalización de la iluminación. En la figura 4.21 se muestra el diseño planteado, realizándose una completa descripción de los bloques que lo componen, es decir: obtención del valor de sustracción (A3.1), resta de la imagen con el valor de sustracción (A3.2) e imagen con iluminación normalizada (A3.3).

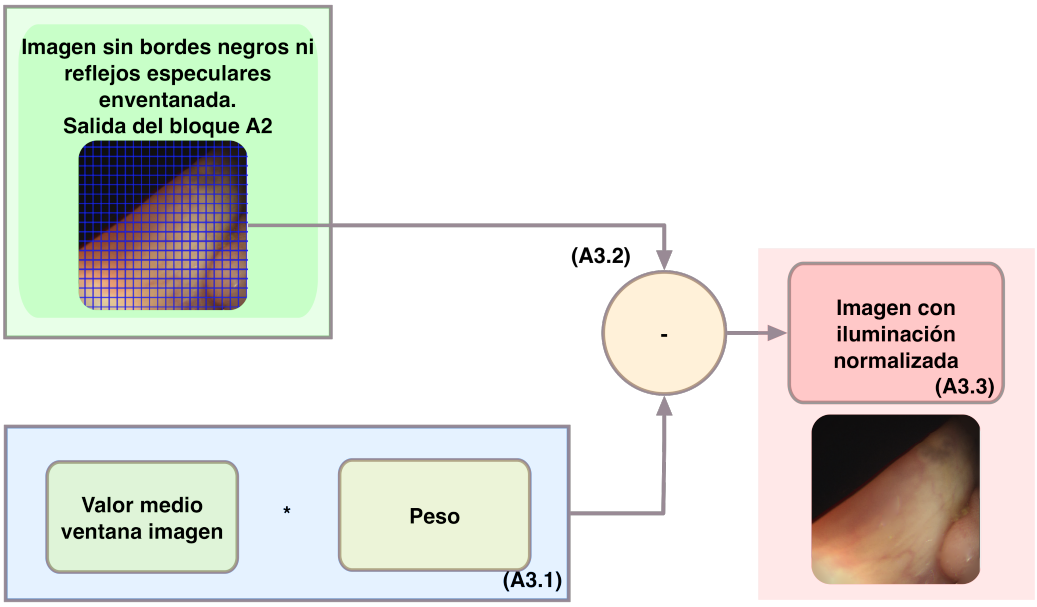


Figura 4.21: Normalización de la iluminación.

Obtención del valor de sustracción (A3.1)

Para poder conseguir una iluminación más uniforme en las imágenes, es requisito fundamental el cálculo de un valor de sustracción para cada una de las ventanas en las que se ha dividido la imagen (20x20 píxeles). Éste es obtenido calculando el

valor medio de cada canal dentro de dicha ventana y multiplicándolo por un peso (0.3 por defecto).

Resta de la ventana con el valor de sustracción (A3.2)

Una vez calculados los valores de sustracción de los diferentes canales, estos son restados al canal correspondiente de la ventana. De esta forma se mitigan los efectos de los picos de intensidad que provocan la no uniformidad de la iluminación.

Imagen con iluminación normalizada (A3.3)

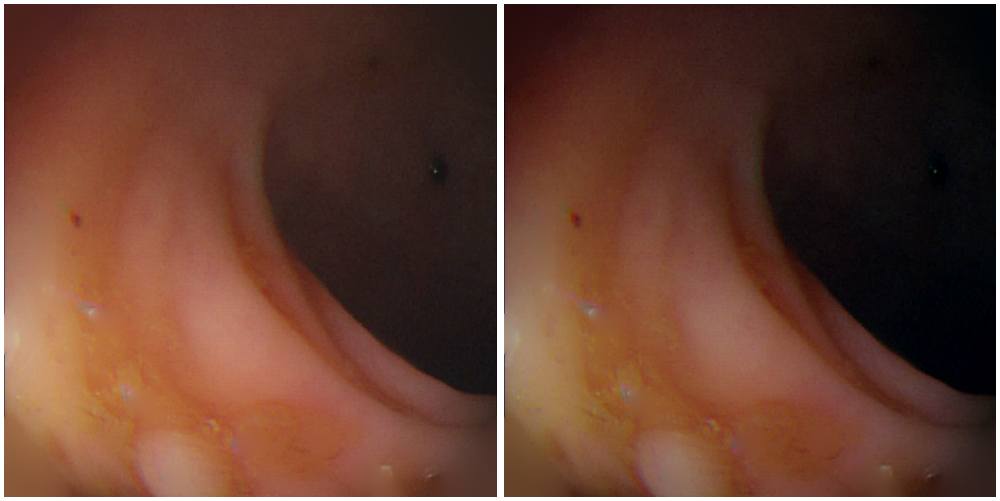
Como salida del módulo de normalización de la iluminación se consigue una imagen con un rango de intensidades de color mucho más uniforme, que favorece el posterior análisis de la misma. Tras la realización de este último paso, las imágenes colonoscópicas están listas para ser utilizadas por los algoritmos de evaluación de la calidad de preparación del colon mediante la ELCB y de detección automática de pólipos. En la figura 4.22 puede verse el resultado conseguido mediante la normalización de la iluminación y en consecuencia, de todo el sistema de preprocesado diseñado. La imagen 4.22(a) muestra una imagen con un preprocesado previo a la normalización de la iluminación y la imagen 4.22(b) muestra el resultado obtenido mediante este proceso.

4.2.1.4 Imagen preprocesada (A4)

Como salida del sistema de preprocesado se obtiene una imagen sin efectos adversos lista para ser administrada a los algoritmos de evaluación de la calidad de preparación del colon y de detección automática de pólipos, los cuales se describen en los siguientes apartados.

4.2.2 Evaluación de la calidad de preparación del colon mediante la ELCB. (B)

El segundo módulo del presente trabajo es el de la evaluación de la calidad de preparación del colon mediante la ELCB (véase figura 4.23). El dotar de herramientas que realicen una valoración objetiva de la limpieza del colon basándose



(a) (b)

Figura 4.22: Resultado de la normalización de la iluminación. a) Imagen sin bordes negros ni reflejos especulares. b) Resultado de la normalización de la iluminación.

para ello en escalas validadas y parámetros objetivos es una necesidad. Esto es debido a que en la actualidad las valoraciones se realizan siguiendo escalas validadas, pero dependientes del criterio subjetivo de los especialistas, lo que resta validez a los informes de endoscopia realizados tras la colonoscopia, además de impedir la correcta comparación entre diferentes centros de salud para tratar de mejorar la calidad de ejecución.

El sistema de evaluación de la calidad de preparación del colon mediante la ELCB diseñado se compone de diferentes bloques, estos son los siguientes: ajuste de canales de color (B1), detección de heces (B2), clasificación de heces (B3) y cálculo de la ELCB (B4). A continuación se realizará una descripción en detalle de cada uno de ellos.

4.2.2.1 **Ajuste de los canales de color (B1)**

El primer bloque de este sistema es el ajuste de los canales de color. Las heces presentes en el colon presentan un amplio rango de valores de color, además de presentar diferentes patrones de textura. Es por esto que existen diversos tipos de heces (líquidas, tintadas y sólidas) y que para mayor complejidad del sistema, al-

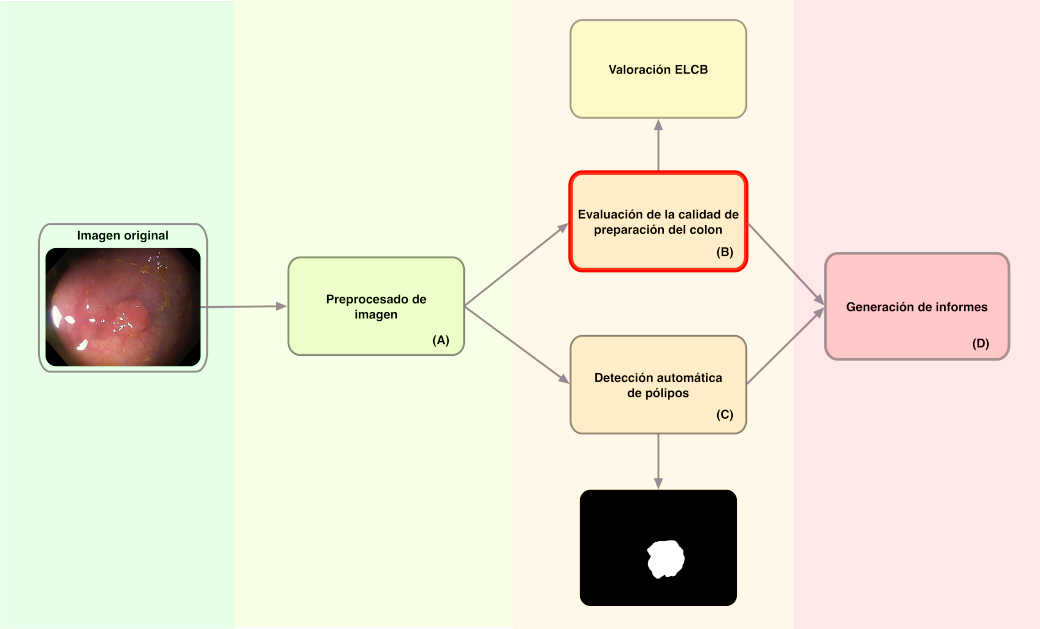


Figura 4.23: Módulo B. Evaluación de la calidad de preparación del colon mediante la ELCB.

gunas de ellas comparten rangos de colores similares entre sí y con las paredes del colon, haciendo que la detección de las heces se complique. Para dar solución a esta problemática se ha propuesto realizar una redistribución del canal de color H del modelo de color HSV como se muestra en la figura 4.24. De esta forma se expanden los rangos de colores de las imágenes permitiendo la segmentación y clasificación de las heces de una forma más precisa.

Como se observa, este bloque se compone de dos pasos: conversión a HSV (B1.1) y redistribución del canal H (B1.2). En los siguientes apartados se explica cada uno de ellos.

Conversión a HSV (B1.1)

La entrada a este sistema es una imagen colonoscópica preprocesada (salida del bloque A4) que viene representada por el modelo de color RGB. Uno de los principales inconvenientes de éste es la dificultad que acarrea la definición de rangos de colores para la realización de segmentaciones. Por este motivo se ha creído necesaria la conversión de la imagen colonoscópica preprocesada al modelo de color

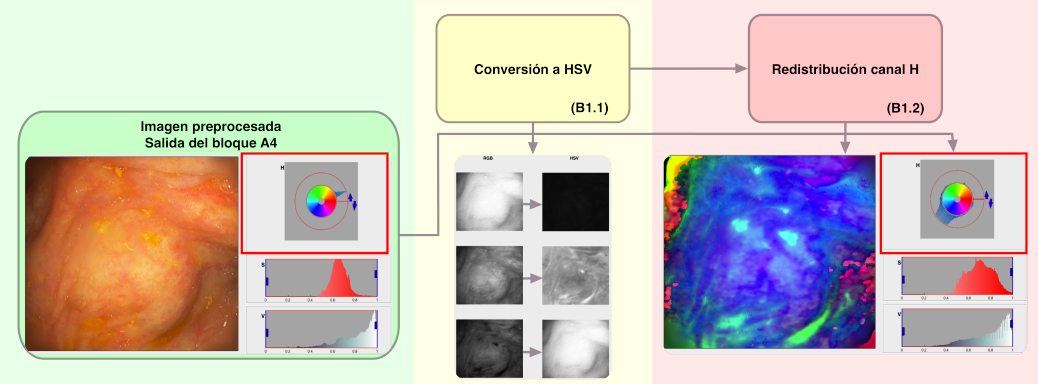


Figura 4.24: Ajuste de los canales de color.

HSV, que tiene como una de sus principales ventajas la facilidad para definir rangos de color para futuras segmentaciones.

Redistribución del canal H (B1.2)

Una vez se ha realizado la conversión de la imagen al modelo de color HSV se procede a redistribuir el canal de H. Este canal es el que contiene la información propia del color, por este motivo es sobre el que se ha decidido actuar. Las heces aparecen en los rangos de valores de entre 40 y 90º (véase figura 4.25), siendo los valores de entre 0 y 45º los de las paredes del colon. Como puede verse comparten ciertos rangos, de forma que al realizar una segmentación automática la eficacia se ve afectada. La solución desarrollada se compone de dos pasos, en primer lugar una redistribución de los valores comprendidos en el rango de entre 40 y 90º, seguida de otra redistribución del rango completo de la imagen.

De esta forma se separan más los rangos de color de las heces y el colon, solucionando en gran medida el solapamiento existente. La figura 4.26 muestra el resultado obtenido mediante este proceso. La imagen 4.26(a) carece de la redistribución del canal H y es muy difícil la detección de las heces dada su similitud con la pared del colon, en cambio la imagen 4.26(b) ya dispone de la redistribución y se observa la mayor facilidad con la que se detectan las heces.

Es necesario indicar que la imagen 4.26(b) sólo se utiliza para la segmentación de las heces, ya que los colores quedan desvirtuados para posteriores procesamientos sobre la imagen.

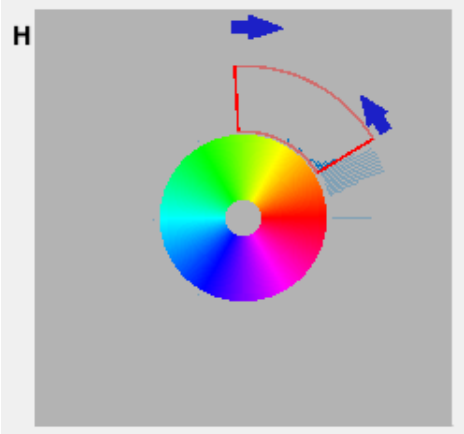
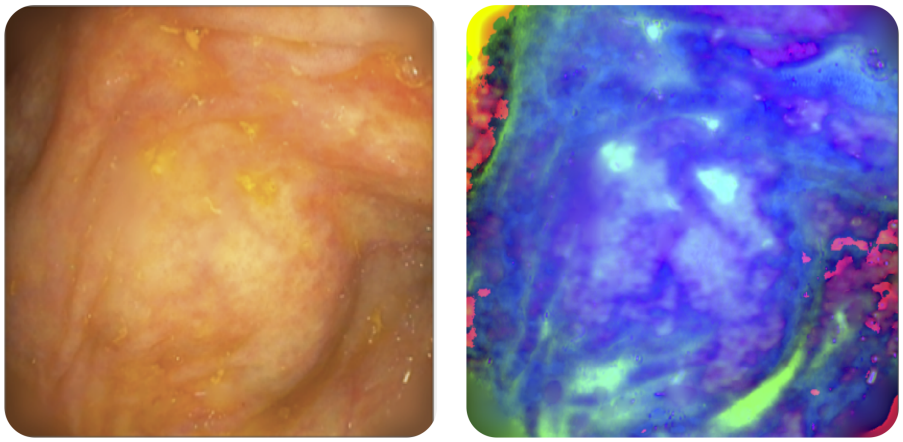


Figura 4.25: Rangos de colores de las heces en el canal H.



(a) (b)

Figura 4.26: Resultado de la redistribución del canal H. a) Imagen sin la redistribución del canal H. b) Imagen con la redistribución del canal H.

4.2.2.2 **Detección de heces (B2)**

La detección automática de las heces se realiza sobre la imagen con el canal H redistribuido obtenida en el punto anterior. Este proceso consta de tres pasos (véase figura 4.27): umbralización de los canales H, S y V (B2.1), eliminación de píxeles espurios (B2.2) y relleno de áreas huecas (B2.3). El paso B2.1 es la detección automática, siendo los pasos B2.2 y B2.3 un postprocesado para mejorar su calidad. En los siguientes apartados se realiza una descripción de ellos.

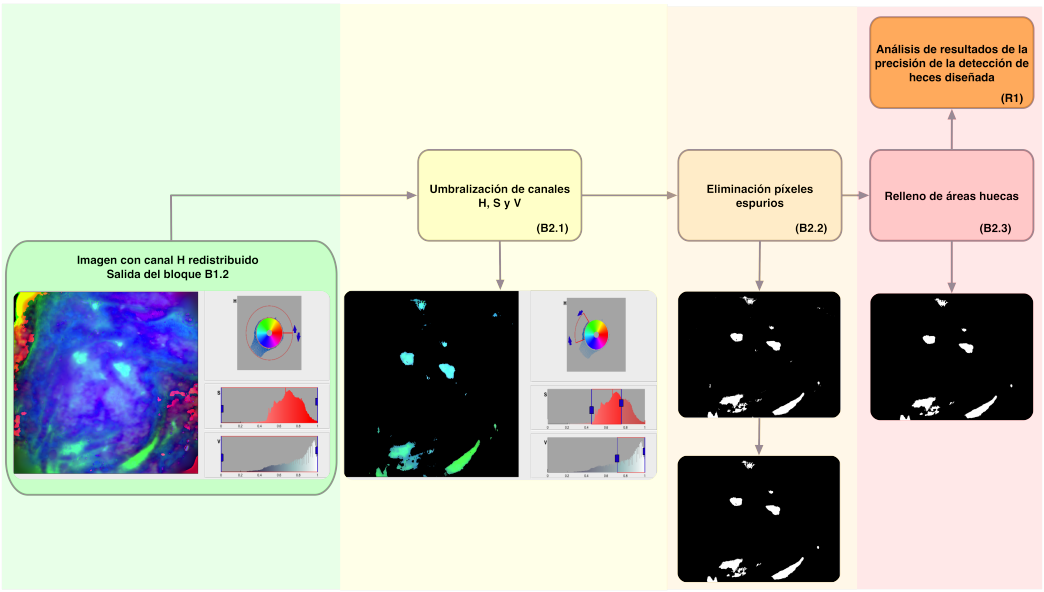


Figura 4.27: Detección de las heces mediante el umbralizado del color.

Umbralización de los canales H, S y V (B2.1)

Mediante la especificación de un umbral en cada canal (H, S y V) se realiza la detección de las heces. El umbral definido para el canal V está fijado en el rango de valores comprendido entre 115 y 190º. En el caso del canal S el rango de valores está comprendido entre 0.45 y 0.77. Por último, el rango fijado para el canal V está comprendido entre 0.72 y 1. Mediante esta umbralización se consigue una precisa detección de las heces en las imágenes colonoscópicas, no obstante se requiere de un refinamiento que se lleva a cabo en los bloques B2.2 y B2.3.

Eliminación de píxeles espurios (B2.2)

La detección de heces realizada mediante la umbralización de los canales H, S y V obtiene una gran precisión, pero es necesaria la eliminación de píxeles o grupos de píxeles espurios y aislados de pequeño tamaño. Para ello se ha realizado una operación de apertura morfológica mediante una estructura de disco de tamaño 5. Con ello se consigue una detección de heces mucho más limpia y precisa. Tras este sencillo proceso también es necesario el relleno de áreas huecas, el cual se aborda en el siguiente apartado.

Relleno de áreas huecas (B2.3)

El último paso del postprocesado de la detección automática de las heces es el relleno de áreas huecas. En muchas ocasiones en el interior de las heces detectadas se generan huecos vacíos. En la mayoría de los casos estos se deben a efectos de los reflejos especulares, que a pesar de haber sido tratados en el sistema de preprocesado de imágenes, hay ocasiones en las que todos sus efectos no han podido ser mitigados. No tratar esta problemática generaría unos resultados menos precisos, ya que se tomarían como píxeles del colon aquellos que en realidad pertenecen a las heces. Para que un hueco vacío en las heces sea rellenado, éste debe tener un tamaño menor a una estructura de disco de tamaño 5. Esta condición es necesaria porque es posible que en el centro de las heces exista un hueco debido a la presencia de colon, de esta manera se soluciona esta hipotética situación.

Sistema de análisis de resultados de la precisión de la detección de heces diseñada (R1)

Se ha creído necesaria la inclusión de un sistema de evaluación de la precisión de la detección de heces propuesta. Con ello se pretende validar su eficacia, ya que es la base de la futura valoración de la ELCB que se realizará. En caso de que los resultados obtenidos no fuesen precisos, no tendría sentido continuar con la evaluación de la calidad de preparación del colon, ya que estaría asentada sobre algoritmos que arrojan una baja precisión, por lo que los resultados no serían válidos.

Para tratar de validar la detección automática de las heces realizada se ha procedido a segmentar manualmente las heces de 200 imágenes colonoscópicas pertenecientes a la base de datos principal. Esta segmentación manual es la más precisa que se puede conseguir, ya que se detectan absolutamente todas las heces presentes en la imagen. Esta segmentación manual ha sido validada por los especialistas participantes en la investigación, de forma que su validez está demostrada. Una vez realizado esto se calcula el porcentaje de heces real en cada imagen. Tras obtener los porcentajes de heces reales de las imágenes, se ejecutan los algoritmos de detección automática desarrollados sobre el mismo conjunto de 200 imágenes, calculándose los porcentajes de heces detectados. Por último, el mismo conjunto de imágenes utilizado es presentado a dos experimentados endoscopistas, quienes

indican el porcentaje de heces que estiman que existe (subjetivamente) en cada una de las imágenes, comparándose los resultados con los obtenidos por el método propuesto. Por lo tanto se dispone de los siguientes datos:

- Porcentajes de heces totales para cada una de las 200 imágenes utilizadas proporcionados por el especialista 1.
- Porcentajes de heces totales para cada una de las 200 imágenes utilizadas proporcionados por el especialista 2.
- Porcentajes de heces totales para cada una de las 200 imágenes utilizadas proporcionados por el sistema de detección diseñado.
- Porcentajes de heces totales para cada una de las 200 imágenes utilizadas segmentadas de forma manual (se considera la real).

Para comenzar, se lleva a cabo un test de normalidad de los datos. Con ello se pretende ver si estos siguen una distribución normal, condición que determinará el uso de métodos paramétricos o no paramétricos. Para este propósito se utilizará el test de Kolmogorov-Smirnov [Lil67] que se describe a continuación:

La prueba de Kolmogorov-Smirnov para una muestra se considera un procedimiento que permite medir el grado de concordancia existente entre la distribución de un conjunto de datos y una distribución teórica específica. Su objetivo es señalar si los datos provienen de una población que tiene la distribución teórica especificada.

Mediante la prueba se compara si la distribución acumulada de las frecuencias teóricas y la distribución acumulada de las frecuencias observadas se encuentran en el punto de divergencia máxima. De esta forma se determina qué probabilidad existe de que una diferencia de esa magnitud se deba al azar.

En las tareas de investigación se puede obtener un conjunto de observaciones, las cuales se supone que tienen una distribución normal, binomial, de Poisson, etc. Para el caso, las frecuencias de las distribuciones teóricas deben contrastar con las frecuencias observadas, a fin de conocer que distribución se adecua mejor al modelo. Para poder determinar el tipo de distribución de los datos han de realizarse los siguientes pasos:

1. Calcular las frecuencias esperadas de la distribución teórica específica a considerar para un determinado número de clases. Esto es realizado en un vector de rangos ordenados de menor a mayor.

2. Arreglar estos valores teóricos en frecuencias acumuladas.

3. Arreglar de modo acumulativo las frecuencias observadas.

4. Aplicar la ecuación $D = FT - FOBS$, donde D es la máxima discrepancia de ambas.

5. Comparar el valor estadístico D de Kolmogorov-Smirnov en la tabla de valores críticos de D.

6. Decidir si se acepta o rechaza la hipótesis.

El planteamiento de las hipótesis de este test es el siguiente:

- Hipótesis alternativa (HA): los valores observados de las frecuencias para cada clase son diferentes a las frecuencias teóricas de una distribución normal.

- Hipótesis nula (H0): las diferencias entre los valores observados y los teóricos de la distribución normal se deben al azar.

Una vez calculado el test de Kolmogorov-Smirnov, para todo valor de significancia $p <= 0.05$ se acepta HA y se rechaza H0.

Determinado el tipo de distribución de los datos, se continuará comprobando si existen diferencias significativas entre los porcentajes de heces determinados por los dos especialistas, el método propuesto y el porcentaje real. Es deseable que la significancia entre los especialistas y el método propuesto respecto a la realidad sea $p > 0.05$, ya que esto sería un indicativo de una alta precisión al no detectarse diferencias significativas. Esta tarea se aborda haciendo uso del test de la suma de rangos de Wilcoxon para muestras emparejadas, el cual se describe a continuación.

Cuando se trata de variables medibles en por lo menos una escala ordinal y pueden suponerse poblaciones continuas, la prueba no paramétrica más potente es la de Wilcoxon [Wil45]. La H0 del contraste postula que las muestras proceden de

poblaciones con la misma distribución de probabilidad; la HA establece que hay diferencias respecto a la tendencia central de las poblaciones y puede ser direccional o no.

El contraste se basa en el comportamiento de las diferencias entre las puntuaciones de los elementos de cada par asociado, teniendo en cuenta no sólo el signo, sino también la magnitud de la diferencia. Sea $d_i = x_i - y_i$ la diferencia entre las puntuaciones de la pareja i-ésima, si alguna de estas diferencias es nula la pareja correspondiente se elimina del análisis, de forma que el tamaño de la muestra es n, el número de diferencias no nulas. A continuación se asignan rangos desde 1 hasta n atendiendo únicamente al valor absoluto de las d_i y se suman los rangos correspondientes a las diferencias positivas y a las diferencias negativas por separado. Si la H0 es cierta, X e Y tienen el mismo valor central y es de esperar que los rangos se distribuyan de forma aleatoria entre las diferencias positivas y negativas y, por tanto, que ambas sumas de rangos sean aproximadamente iguales. El estadístico de la prueba, T, es el menor de las dos sumas de rangos. Cuando $n > 15$ la distribución muestral de T bajo el supuesto de que H0 es cierta se aproxima a una normal de parámetros (véase ecuación 4.5):

$$\mu_T = \frac{n(n+1)}{4} \sigma_T^2 = \frac{n(n+1)(2n+1)}{24} \tag{4.5}$$

El cálculo del estadístico de la prueba se realiza mediante la ecuación 4.6 que se distribuye según una normal tipificada.

$$Z = \frac{T - \mu_T}{\sigma_T} \tag{4.6}$$

Para el nivel de significación deseado se rechazará la H0 si Z pertenece a la región crítica localizada en las dos colas o en una cola de la normal tipificada, según la naturaleza de la hipótesis alternativa.

Siguiendo con el análisis de resultados, se calcularán las correlaciones por parejas de los resultados de los porcentajes de heces aportados por el especialista 1, el especialista 2, el método propuesto y los resultados reales obtenidos manualmente. De esta forma se podrá evaluar qué concordancia tienen entre ellos. Esta tarea se abordará haciendo uso del coeficiente de correlación intraclase (CCI) [PLC98]. Es deseable que el CCI de los especialistas y el método propuesto con la realidad

sea lo más alto posible como indicativo de una fuerte analogía. A continuación se realiza una descripción del CCI.

En el caso de variables cuantitativas, es frecuente que el análisis de la concordancia se aborde mediante técnicas estadísticas inapropiadas. Con frecuencia ha sido utilizado el cálculo del coeficiente de correlación de lineal (r) de Pearson como índice de concordancia. Sin embargo, ésta no resulta una medida adecuada del grado de acuerdo entre dos mediciones, ya que si dos instrumentos miden sistemáticamente cantidades diferentes uno del otro, la correlación puede ser perfecta (r=1), a pesar de que la concordancia sea nula. No se debe olvidar que el coeficiente de correlación de Pearson no proporciona información sobre el acuerdo observado y solamente mide la asociación lineal entre dos variables. De esta forma, al calcularse a partir de los pares ordenados de mediciones, si varía el orden también cambia el valor del coeficiente, mientras que un cambio en las escalas de medida no afecta a la correlación pero sí afecta a la concordancia. A su vez, hay que mencionar que la idea de que si el coeficiente de correlación entre dos medidas es significativamente diferente de cero la fiabilidad es buena, es incorrecto. El coeficiente de correlación lineal puede ser muy pequeño y resultar significativo si el tamaño muestral es suficientemente grande. Por último, tampoco la comparación de medias mediante un test *t-Student* con datos apareados es una técnica adecuada para este tipo de análisis. Desde el punto de vista matemático, el índice más apropiado para cuantificar la concordancia entre diferentes mediciones de una variable numérica es el llamado CCI.

Dicho coeficiente estima el promedio de las correlaciones entre todas las posibles ordenaciones de los pares de observaciones disponibles y, por lo tanto, evita el problema de la dependencia del orden del coeficiente de correlación. Asimismo, extiende su uso al caso en el que se disponga de más de dos observaciones por sujeto. Sin embargo, una de las principales limitaciones del CCI es la dificultad de su cálculo, ya que debe ser estimado de distintas formas dependiendo del diseño del estudio. La forma de cálculo más habitual se basa en un modelo de análisis de la varianza (ANOVA) con medidas repetidas. La idea es que la variabilidad total de las mediciones se pueda descomponer en dos componentes: la variabilidad debida a las diferencias entre los distintos sujetos y la debida a las diferencias entre las medidas para cada sujeto. Esta última, a su vez, depende de la variabilidad entre

observaciones y una variabilidad residual o aleatoria asociada al error que conlleva toda medición. El CCI se define entonces como la proporción de la variabilidad total que se debe a la variabilidad de los sujetos.

Cuando utilizamos la desviación típica intra-sujetos como una estimación del error de medida, lo que estamos haciendo es considerar el siguiente modelo matemático para cada medida $X = \pi + \epsilon$, donde π representa el valor verdadero de la variable que se mide (desconocido) y ϵ el error de la medida. A partir de ese modelo se puede calcular CCI mediante la ecuación 4.7.

$$\rho = \frac{Var(\pi)}{Var(\pi) + Var(\epsilon)} \tag{4.7}$$

Se trata del cociente entre la varianza correspondiente a los valores verdaderos (variabilidad biológica) y la suma de la varianza de los valores verdaderos y la varianza debida al error de medida (variabilidad total). Así el CCI es un indicador de la fiabilidad de una sola medida.

Para facilitar la interpretación de los resultados del CCI se proporciona la tabla 4.1 que relaciona los valores del CCI con su fuerza de concordancia.

Tabla 4.1: Valoración de la concordancia según los valores del CCI.

Valor del CCI	**Fuerza de la concordancia**
CCI>0.9	Muy Alta
0.71<=CCI<=0.9	Alta
0.51<=CCI<=0.7	Media
0.31<=CCI<=0.5	Baja
CCI <0.3	Muy baja

Para finalizar se calculará el error existente en los porcentajes de las heces detectados por el especialista 1, el especialista 2 y el método propuesto respecto al porcentaje real para cada una de las 200 imágenes utilizadas. Se calculará el error absoluto medio (EAM), mediana y desviación típica de los errores para determinar quien es más preciso. El cálculo del error se realiza mediante la ecuación 4.8.

$$error = |D - R| \tag{4.8}$$

Donde D representa el porcentaje de heces determinado por los especialistas y el método propuesto, R el porcentaje de heces real y $||$ denota el valor absoluto.

Con todo esto se pretende validar la eficacia de los algoritmos diseñados, de forma que los métodos desarrollados queden validados. De esta manera se considera que la eficacia de la detección automática de heces propuesta queda demostrada. Los resultados obtenidos por este sistema se muestran en el aparatado 5.2.1.1 ≪Análisis de resultados de la precisión de la detección de heces diseñada (R1)≫ del capítulo 5 ≪Resultados≫.

4.2.2.3 **Clasificación de heces. (B3)**

El proceso más complejo en la evaluación de la calidad de preparación del colon mediante la ELCB es la clasificación de las heces. Según especifica la escala existen tres tipos de heces: líquidas, tintadas y sólidas. Cada una de ellas tiene diferente efecto a la hora de evaluar la calidad de preparación del colon. Las heces líquidas son las menos problemáticas porque permiten en un mínimo grado, la visualización del colon que se encuentra tras ellas. En el caso de las tintadas, se considera que tienen un efecto intermedio. Esto es debido a que no permiten la visualización del colon que se encuentra bajo ellas, pero si permiten ver en la mayoría de los casos el posible contorno o forma de pólipos bajo las mismas. En último lugar, las heces sólidas son las más peligrosas porque no permiten ver el colon a través de ellas ni tampoco observar el contorno o forma de posibles pólipos bajo ellas. Para abordar la clasificación de las heces se ha diseñado el sistema mostrado en la figura 4.28.

Como puede apreciarse, el sistema de clasificación tiene como entrada la imagen con las heces detectadas obtenida como salida del módulo B2 detección de heces, componiéndose de los siguientes bloques: imagen umbralizada mediante color (B3.1), enventanado de la imagen (B3.2), rotación y escalado de las ventanas (B3.3), extracción de características de textura (B3.4), reducción de características (B3.5), clasificación (B3.6) y cálculo del porcentaje de heces por tipo (B3.7). A continuación se realiza una descripción detallada de cada uno de ellos.

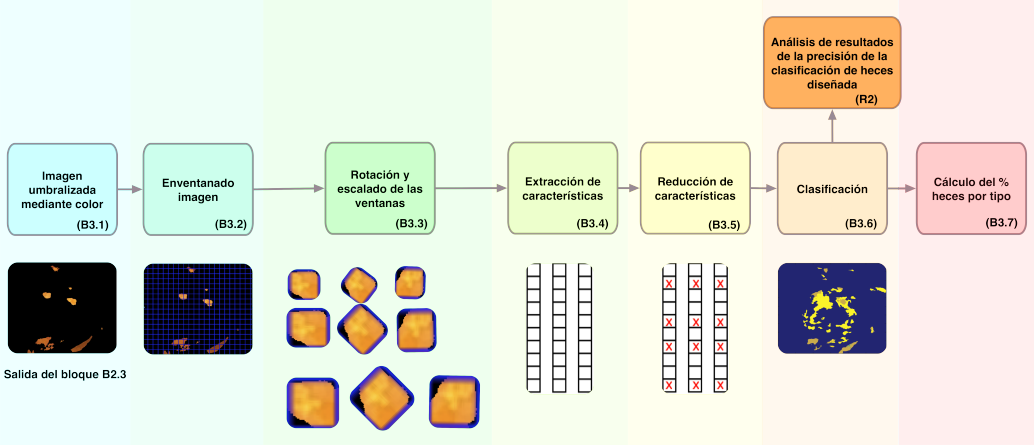


Figura 4.28: Clasificación de las heces.

Imagen umbralizada mediante color (B3.1)

El sistema de clasificación tiene como entrada una imagen umbralizada mediante el color obtenida como salida del bloque B2.3. Sobre ella se aplicarán el resto de los algoritmos diseñados para el presente propósito.

Enventanado de la imagen (B3.2)

Todo proceso de extracción de características y clasificación de imágenes debe ser realizado mediante un enventanado. El enventanado es la división de la imagen en fragmentos rectangulares a modo de cuadrícula (véase el paso 1 de la figura 4.30). Cada una de las cuadrículas en las que se divide la imagen se denomina ventana y permite un análisis local, siendo este enfoque mucho más preciso que un análisis global de toda la imagen. En función de la clasificación a realizar se definirá un tamaño de ventana mayor (más rápido y menos preciso) o menor (más lento y más preciso). En el caso que nos ocupa, se ha optado por un tamaño de ventana de 20x20 píxeles. Por otro lado, el enventanado puede realizarse con o sin solapamiento, es decir, las ventanas adyacentes comparten posiciones. Se ha decidido optar por un enventanado sin solapamiento, ya que los resultados obtenidos son buenos y de esta forma se consigue una mayor velocidad de ejecución. Como resultado del enventanado se obtiene la descomposición de la imagen en diferentes mini-imágenes de 20x20 píxeles.

Rotación y escalado de las ventanas (B3.3)

Una vez realizado el enventanado de la imagen es necesario rotar y escalar cada una de las ventanas generadas. El principal motivo para la realización de estas operaciones es que muchos de los operadores de análisis de textura son variantes a la rotación y al cambio de escala. Un ejemplo de la varianza a la rotación puede verse en la figura 4.29, en la que en función de la rotación puede verse a una persona joven o mayor. Para abordar esta problemática se realiza la rotación de cada una de las ventanas por los siguientes ángulos 45º, 90º, 135º, 180º, 235º, 270º y 315º (véase el paso 3 de la figura 4.30).

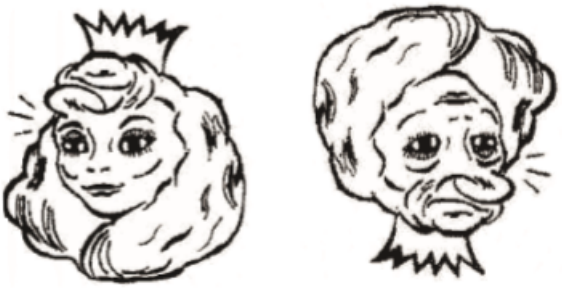


Figura 4.29: Varianza a la rotación. La imagen de la izquierda muestra una mujer joven y la de la derecha una mujer mayor. Ambas son la misma imagen variando la rotación de la misma. Fuente: goo.gl/9xBQQU

Lo mismo ocurre con los cambios de escala (véase el paso 2 de la figura 4.30), imaginemos que queremos buscar una moneda en una imagen. Esa misma moneda aparece en 2 imágenes, en la primera de ellas con un área de 200 píxeles y en la segunda de ellas con un área de 100 píxeles. Siendo la misma moneda, el área varía en función de la distancia entre la cámara y la moneda. Para tratar de solventar esta problemática cada una de las ventanas es escalada por los factores 0.5 (mitad de tamaño) y 1.5 (1.5 de tamaño). Para una mayor aclaración, la figura 4.30 muestra de forma gráfica la rotación y el escalado de las ventanas.

El cálculo de las rotaciones y escalados se ha llevado a cabo mediante funciones pertenecientes al API de Matlab. Se ha elegido esta alternativa dada la alta eficiencia en el manejo de matrices del propio entorno, ofreciendo una velocidad de cálculo superior a la mostrada por otros operadores, como por ejemplo la transformada contourlet.

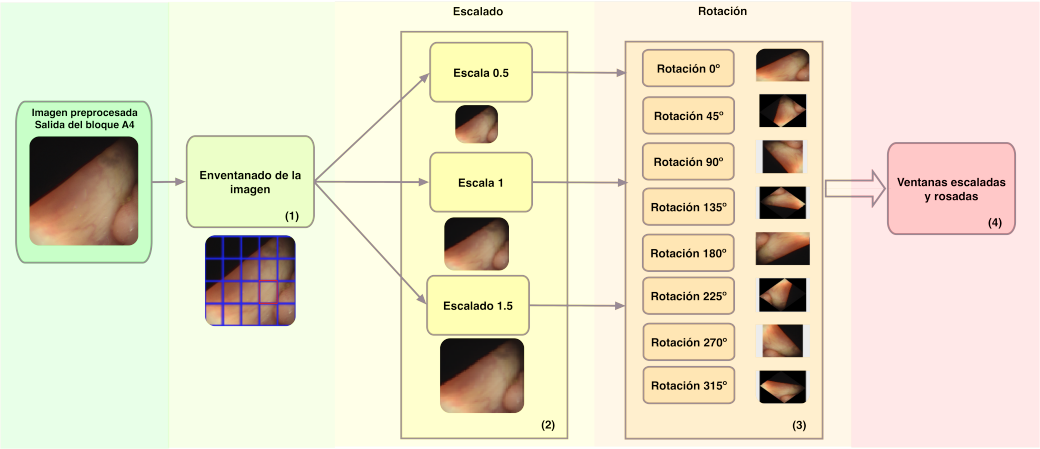


Figura 4.30: Ejemplo gráfico de la rotación y escalado de las ventanas.

De forma adicional, es necesario aclarar que el descriptor SIFT realiza internamente la rotación y el escalado de las ventanas pertenecientes a la imagen. Para no realizar cómputos innecesarios se ha configurado el cálculo de dicho operador para no realizar internamente rotaciones y escalados. Por otra parte, en el caso de los momentos de color, estos no se ven afectados por los cambios de rotación y escalado, por lo que no es necesario realizar el presente paso para su cálculo.

Extracción de características de textura y color (B3.4)

Tras la rotación y el escalado de las ventanas se procede con la extracción de características de la textura y del color. Se ha optado por una solución combinada, ya que en muchas ocasiones diferentes tipos de heces tienen una apariencia similar, imposibilitando su correcta clasificación mediante un análisis único.

La textura hace referencia a los rasgos visuales representados en la superficie de un objeto que da carácter e identidad al mismo. Suelen ser pequeños rasgos visuales que describen si el aspecto es liso, rugoso, granulado, homogéneo o heterogéneo. Así, la textura de una imagen o un fragmento de imagen, suele diferenciar el objeto representado. Además de ésta, han sido utilizados los momentos de color como descriptores. El color es uno de los elementos esenciales de la configuración de una forma, de como la interpretamos y apreciamos en el espacio, siendo en el caso de la visión humana el descriptor que ofrece mayor información.

Para realizar la extracción de características se ha diseñado el sistema disponible en la figura 4.31, quien tiene como entrada las ventanas rotadas y escaladas, siendo la salida un conjunto de características. El sistema consta de dos pasos, extracción de características (1) y concatenación y normalización de las características (2). Estos son descritos a continuación.

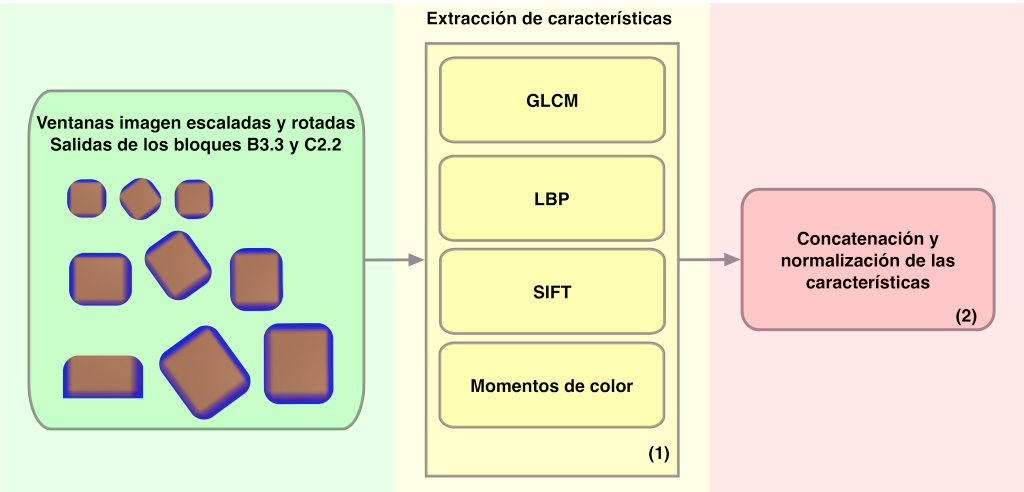


Figura 4.31: Extracción de las características de la textura. Para el caso de los descriptores GLCM, LBP y SIFT es necesaria la rotación y escalado de las ventanas, en cambio los momentos de color no se ven afectados por tal aspecto.

Extracción de características (1): se han utilizado diversos descriptores de textura (GLCM, LBP y SIFT), así como un descriptor de color (momentos de color). El uso de diferentes características hace posible una mayor especificación de las propiedades de la imagen consiguiendo una completa generalización y por tanto mejores resultados. Con ellos se pretende describir objetivamente todas las características visuales que hacen a los humanos distinguir diferentes tipos de heces. En las siguientes líneas se hace una explicación de cada una de las técnicas aplicadas.

- GLCM: este descriptor representa la frecuencia con la que un píxel con un nivel de gris i aparece en una relación de espacio específica con otro píxel de nivel de gris j. Son medidas de segundo orden porque consideran parejas de píxeles vecinos, separados por una distancia d y en un determinado ángulo.

Por tanto, las matrices de co-ocurrencia pueden revelar ciertas propiedades sobre la distribución espacial de los grises en la textura de la figura 4.32.

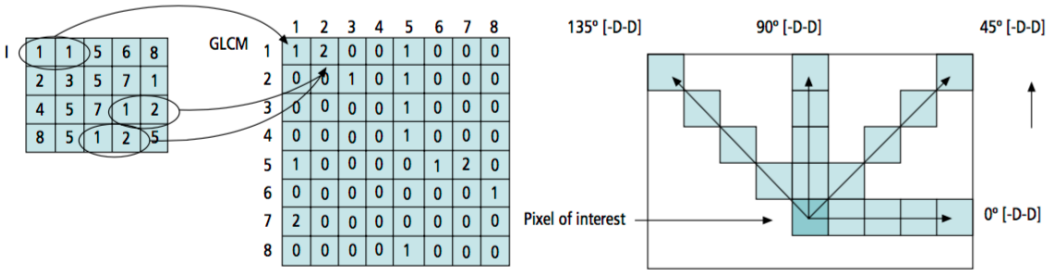


Figura 4.32: Proceso de construcción de una matriz de co-ocurrencia de nivel de gris (GLCM). Fuente: goo.gl/XY2HV0

A partir de ellas se han calculado el contraste, correlación, energía y homogeneidad para ocho orientaciones (0º, 45º, 90º, 135º, 180º, 235º, 270º y 315º) y tres distancias (d = 1, 5 y 10 píxeles). Estas propiedades se describen a continuación.

- Contraste: el contraste de una textura proporciona información acerca de las variaciones bruscas de color en la imagen. La extracción de este descriptor está definida por la expresión mostrada en la ecuación 4.9.
- Correlación: la correlación de la textura es una medida de probabilidad que mide la relación entre las diferentes intensidades presentes en el entorno definido por la matriz de co-ocurrencia. Matemáticamente la correlación se describe mediante la ecuación 4.10.
- Energía: la propiedad de energía da una idea de la suavidad de la textura. Esto se refleja en la ubicación de sus probabilidades en la matriz de co-ocurrencia, de modo que si una mayor cantidad de píxeles de colores iguales cumplen con la condición de ocurrencia, será posible observar un pico de intensidad en la diagonal principal de la matriz. Su representación matemática se muestra en la ecuación 4.11.
- Homogeneidad local: ésta proporciona información sobre la regularidad local de la textura. Indica que mientras los elementos de la matriz de co-ocurrencia estén más próximos a la diagonal principal, mayor

será el valor de la homogeneidad local. El cálculo de esta propiedad se muestra en la ecuación 4.12.

$$Contraste = \sum_{i=1}^{n}\sum_{j=1}^{n} \mid i-j \mid^2 C_{i,j} \tag{4.9}$$

$$Correlación = \frac{1}{\sigma_i \sigma_j}\sum_{i=1}^{n}\sum_{j=1}^{n}(i-\mu_i)(j-\mu_j)C_{i,j} \tag{4.10}$$

$$Energía = \sum_{i=1}^{n}\sum_{j=1}^{n} C_{i,j}^2 \tag{4.11}$$

$$Homogeneidad = \sum_{i=1}^{n}\sum_{j=1}^{n} \frac{C_{i,j}}{1- \mid i-j \mid} \tag{4.12}$$

- LBP: son descriptores locales que tratan de describir la textura existente en una zona concreta de la imagen considerando imágenes en escala de grises. La aplicación básica del algoritmo LBP es seleccionar una vecindad de 8 píxeles alrededor del punto de trabajo. Si el valor de uno de esos 8 píxeles es mayor que un umbral, entonces se indica con un 1 y si es menor se marca con un 0. Esta operación de umbralizado se ilustra en la figura 4.33. El siguiente paso es transformar la firma de 8 bits en un número entero (entre 0 y 255). Todos estos valores se agregan en un histograma para obtener un descriptor de dicha región basado en LBP.

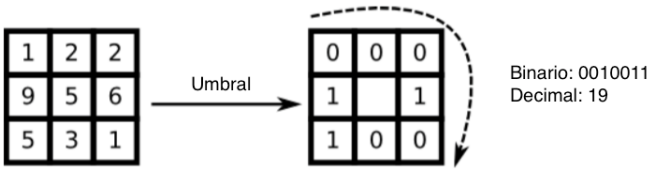


Figura 4.33: Operación de umbralizado en LBP. Fuente: goo.gl/VWPVnI

- SIFT: se trata de un descriptor global basado en una serie de pasos para lograr una representación de los puntos locales característicos de una imagen de forma invariante a los cambios de escala, rotación y traslación. Dichos pasos son los siguientes:

1. Como los elementos presentes en una imagen pueden contener diferentes tamaños, el primer paso es generar un espacio de escalas (véase figura 4.34), asegurándose ser invariante a cambios de escala.



Figura 4.34: Diferentes escalas de una imagen. Fuente: goo.gl/BZtq8Z

2. El siguiente paso es la computación de los potenciales puntos de interés en la imagen. Para ello, se utiliza la operación LoG, donde a partir de una imagen se calculan las derivadas de segundo orden de la misma en una escala inferior. A pesar de que esta operación es computacionalmente costosa al tenerse que aplicar a todas las escalas, en SIFT se propone una solución basada en restar imágenes de escalas consecutivas para simular el operador LoG.

3. A partir de este último cálculo, es necesario detectar los puntos de interés que se encontrarán en los máximos y mínimos de la resta de las escalas. En SIFT se busca mucho más detalle, detectando la posición exacta de ellos con una precisión a nivel de subpíxel mediante la expansión de Taylor de la imagen en ese punto. En la figura 4.35 se ve un ejemplo de este tipo de detección subpíxel: los puntos rojos marcan los píxeles de una imagen y la curva indica el nivel de gris. Se comprueba que el máximo del nivel de gris (punto verde) puede encontrarse fuera de un píxel de la imagen (puntos rojos).

4. El paso anterior genera un gran número de puntos característicos, por lo que hay que realizar una limpieza de ellos, eliminando aquellos que

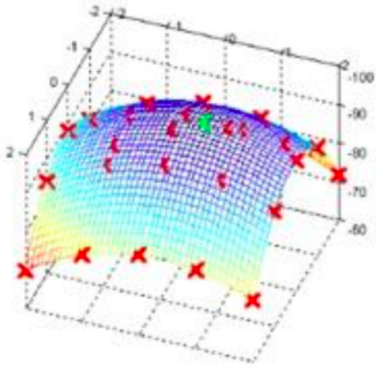


Figura 4.35: Detección a nivel de subpíxel. Fuente: goo.gl/UT7Mjr

se detecten en los bordes de la imagen (computando el gradiente de la imagen en el punto) y aquellos puntos en regiones con poco contraste (en base a un umbral).

5. Mediante los pasos anteriores se han conseguido puntos característicos estables e invariantes a la escala. Para conseguir ser invariantes a la rotación, se computa la magnitud y la orientación del gradiente de la imagen en base a las ecuaciones 4.13 y 4.14.

$$m(x,y) = \sqrt{(L(x+1,y) - L(x-1,y))^2 + (L(x,y+1) - L(x,y-1))^2} \tag{4.13}$$

$$\theta(x,y) = \tan^{-1} \frac{(L(x,y+1) - L(x,y-1)}{L(x+1,y) - L(x-1,y)} \tag{4.14}$$

Calculando estos valores para diferentes puntos de una región limitada de la imagen se computa un histograma de orientaciones, añadiendo en cada nivel la magnitud computada. Gracias a este histograma de orientaciones, todos los cálculos posteriores serán descritos en función de la orientación principal y por tanto, serán invariantes a la rotación. Una vez computados los puntos se extrae el propio descriptor SIFT, que busca ser una firma de la región alrededor de cada punto. Para ello, la región se divide en 4x4 bloques, y estos a su vez en 4x4 subbloques (véase figura 4.36). Dentro de cada bloque se computa

la magnitud y la orientación del gradiente, agregando todo en un histograma de 8 niveles de orientaciones. A cada orientación se le suma la magnitud del gradiente ponderado por una distancia al centro del punto, de esta manera los gradientes más alejados tendrán menos influencia. Concatenando los 4x4x8 valores se genera el vector de características final de 128 dimensiones.

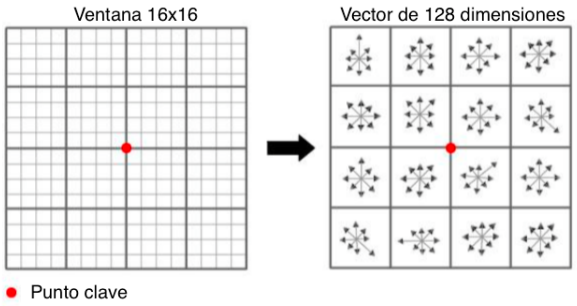


Figura 4.36: Regiones para el cálculo del descriptor SIFT alrededor de un punto. Fuente: goo.gl/eyaUzg

- Momentos de color: se trata de un descriptor utilizado para el análisis de color de las imágenes. Esta técnica ya ha sido previamente descrita en el apartado 2.2.8.2 ≪Análisis de color≫. Con ello se consigue una mayor robustez, ya que se añaden propiedades de color a las ya calculadas de la textura.

Concatenación y normalización de las características (2): finalizada la extracción de características es necesaria su concatenación y normalización. En los sistemas de análisis de imagen lo importante es tener una idea de la imagen en su conjunto y por tanto, integrar toda la información posible en un único vector que describa el contenido de la misma.

Los descriptores que se han mostrado con anterioridad se centran en la descripción de una componente de la imagen, ya sea información del color o de la textura. Como se intuye, la combinación de características posee un resultado potencial mucho mayor que el uso de características individuales. La forma más sencilla de utilizar varios descriptores es la concatenación de los mismos. Así, por ejemplo, ante un histograma de color y otro descriptor de textura, como por ejemplo GLCM, la concatenación de ambos dará como resultado un vector único que combine textura y color. Esta concatenación no puede ser realizada de forma directa, ya que los

rangos de valores de cada uno de los vectores individuales son diferentes, pudiendo ser que los algoritmos de inteligencia artificial (IA) que utilicen ese vector concatenado tiendan a hacer más caso a unas características que a otras. Para evitar este fenómeno existen las técnicas de normalización. En el caso que nos ocupa, se ha optado por acotar los valores en el rango [0-1]. Esto permite ser más robustos frente a pequeñas desviaciones estándar de las características, así como mantener aquellas que son cero. Esta transformación es sencilla y se realiza mediante la ecuación 4.15.

$$X_{Normalizada} = \frac{X - X_{MÍN}}{X_{MÁX} - X_{MÍN}} \tag{4.15}$$

Donde $X_{MÍN}$ corresponde a la característica con menor valor del vector de características y $X_{MÁX}$ la de mayor valor. Una vez realizada la concatenación y normalización se procede con la reducción de características que se describe en el siguiente apartado.

Reducción de características (B3.5)

Finalizada la concatenación y normalización de las características, se procede a realizar una reducción de las mismas. La reducción de características, también denominada selección de atributos, permite automatizar la búsqueda de subconjuntos de descriptores más apropiados para caracterizar un objetivo. En un sentido de clasificación supervisada permite explorar qué subconjuntos de atributos son los que mejor pueden determinar la clase de la instancia. El manejo de conjuntos de características de gran tamaño genera dos problemas principales: baja eficiencia del entrenamiento por la alta dimensionalidad y baja calidad del modelo creado debido a la utilización de atributos dependientes y con una baja ganancia de información. Llevándose a cabo una reducción de características se obtiene una mayor calidad de los datos, evitándose problemas de información irrelevante y datos ruidosos, lo que deriva en un mayor desempeño predictivo, reducción del tiempo de proceso y una mayor eficacia en la clasificación.

Se puede considerar que el objetivo de la reducción de características es seleccionar un subconjunto más pequeño de atributos. Éste no debe afectar significativa-

mente al porcentaje de clasificación y además, la distribución resultante tiene que ser lo más parecida posible a la original. Este proceso consta de cuatro pasos que se describen en la figura 4.37.

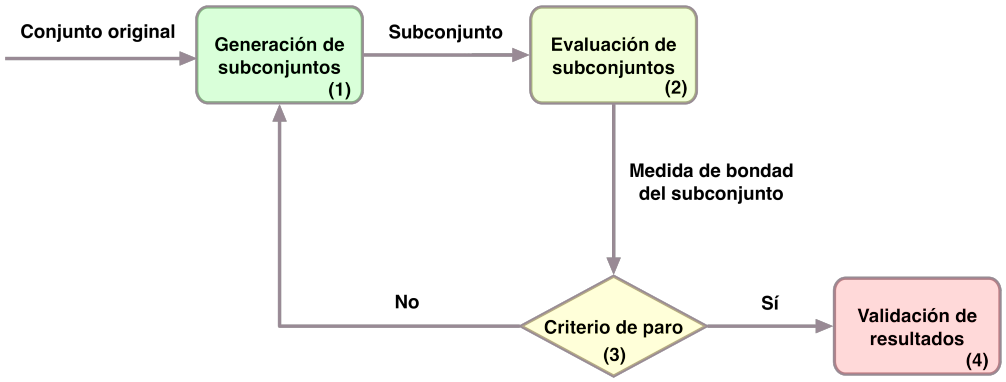


Figura 4.37: Proceso de reducción de características.

Se tiene como entrada el conjunto original de características a partir del cual se genera una agrupación de subconjuntos (1). Estos subconjuntos son evaluados mediante técnicas que evalúan su bondad (2). En función de cumplirse el objetivo de bondad fijado (3) se obtienen unos resultados validados (4) o bien se vuelve a iniciar el proceso (vuelta al paso 1).

La solución planteada en esta investigación para acometer la reducción de características tiene como entrada el conjunto de características original y consta de tres pasos: selección del conjunto de técnicas de reducción, aplicación de las técnicas seleccionadas y combinación de las técnicas mediante voto mayoritario. Mediante este sistema se consigue como salida un conjunto de características reducido. El sistema propuesto se muestra en la figura 4.38 y se describe a continuación.

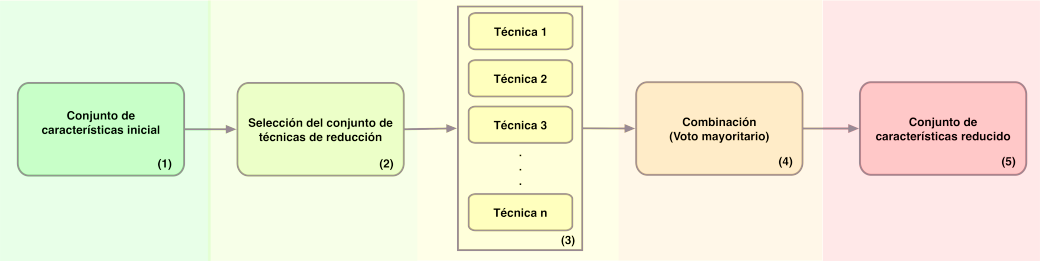


Figura 4.38: Reducción de características.

Conjunto inicial de características (1): el proceso de reducción de características comienza con el conjunto bruto de descriptores extraídos. Sobre este conjunto se aplicarán una serie de técnicas de reducción de dimensionalidad para tratar de obtener el subconjunto más reducido y discriminante posible.

Selección del conjunto de técnicas de reducción (2): el primer paso a realizar en la reducción del conjunto de características es la selección del conjunto de técnicas de reducción a aplicar. Para llevar a cabo su objetivo, estos métodos realizan una búsqueda supervisada sobre el espacio de características, aplicando una función criterio que evalúa la calidad del subconjunto seleccionado. Dicha búsqueda suele ser heurística, ya que una búsqueda exhaustiva supone un problema combinatorio, resultando muy costosa. Según el criterio evaluador utilizado las técnicas pueden ser consideradas como:

- Envoltorios (*wrappers*): la función criterio utilizada es el propio conjunto de reglas generadas por el algoritmo de aprendizaje que posteriormente se usará en la clasificación. Se generan subconjuntos de características y se evalúan en función de la eficacia obtenida en la clasificación.

- Filtros: su función criterio es independiente de algoritmos de aprendizaje, usando medidas de distancia, información o dependencia.

En el sistema de reducción de características implementado se hace uso de envoltorios y filtros. La decisión de combinar ambos ha sido tomada para conseguir una reducción más efectiva. En el caso de los métodos envoltorio se consigue el mejor subconjunto para un clasificador en concreto, no siendo el mejor subconjunto real, cosa que se pretende conseguir mediante su combinación con los filtros, que evalúan las características sin tener en cuenta clasificador alguno. A continuación se describe el proceso seguido para su elección.

La técnica envoltorio elegida ha sido la evaluación de subconjuntos mediante envoltorios (ESME) propuesta en la investigación [KJ97]. Ésta evalúa los subconjuntos de atributos utilizando un clasificador y validación cruzada para estimar la bondad de cada subconjunto. Para seleccionar el algoritmo de aprendizaje a utilizar, se clasifica el conjunto de características inicial (mediante validación cruzada)

utilizando diversos clasificadores. La evaluación de la eficacia de la clasificación se mide mediante los siguientes indicadores: porcentaje de instancias clasificadas correctamente, el estadístico Kappa, EAM, precisión, sensibilidad, valor-F y área característica operativa del receptor (ROC).

En el caso de la selección de técnicas de tipo filtro se han seleccionado la evaluación de subconjuntos mediante el análisis de la correlación (ESAC) [HS99] y el análisis de componentes principales (PCA). ESAC evalúa la capacidad de cada atributo individualmente para determinar la clase y la redundancia entre los distintos atributos, seleccionando aquellos que están altamente correlados con la clase, pero tienen baja intercorrelación entre sí.

PCA por su parte es una técnica estadística de síntesis de información o reducción de dimensionalidad. Es decir, ante un conjunto de datos con muchas variables, el objetivo será reducirlas a un menor número perdiendo la menor cantidad de información posible. Los nuevos componentes principales o factores serán una combinación lineal de las variables originales y además, serán independientes entre sí. Un aspecto clave de PCA es la interpretación de los factores, ya que ésta no viene dada a priori, sino que es deducida tras observar la relación de los factores con las variables iniciales.

En ambos casos se ha utilizado el método de búsqueda primero el mejor (PM) [Pea84] que busca en el espacio de los subconjuntos de atributos utilizando el algoritmo ascenso de colinas (AC) [RNC$^+$03] con retroceso. Este algoritmo comienza con un conjunto vacío de atributos buscando hacia adelante y generando todas las posibles expansiones de los atributos individuales. Se elige el subconjunto que maximiza el resultado de la evaluación y se expande de la misma manera añadiendo atributos individuales. Si al expandir el subconjunto no mejora, se prueba con el siguiente subconjunto mejor. Con suficiente tiempo este algoritmo evalúa todo el espacio de atributos, pero se ha limitado la búsqueda con un criterio de parada: cinco expansiones completas sin mejorar los resultados.

Aplicación de las técnicas seleccionadas (3): una vez han sido seleccionadas las técnicas de reducción de características a utilizar, el conjunto de características original es procesado por ellas. De esta forma, cada método proporciona aquellas características o subconjunto de ellas que es más eficaz para realizar una futura

clasificación. Como se aplica más de una técnica de reducción, se hace necesaria la combinación de ellas, temática que se aborda en el siguiente apartado.

Combinación de las técnicas mediante voto mayoritario (4): el último proceso a realizar para obtener un conjunto de características reducido es la combinación de las diferentes técnicas empleadas, para ello se ha diseñado la metodología plasmada en la figura 4.39.

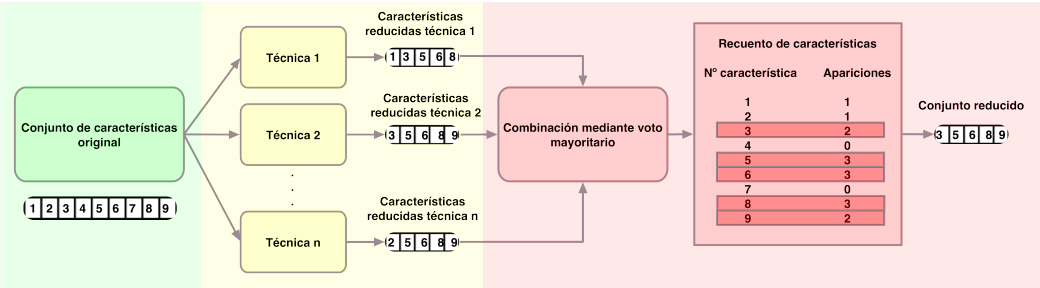


Figura 4.39: Descripción de la realización de la combinación mediante voto mayoritario.

Conjunto de características reducido (5): finalizado el proceso de reducción de características diseñado se obtiene como salida un subconjunto del original con un mayor potencial discriminante que proporcionará una mayor eficacia de clasificación.

El conjunto de características inicial es procesado por las diferentes técnicas, consiguiéndose subconjuntos u ordenaciones de ellas en función de la relevancia otorgada por el método. La combinación mediante voto mayoritario se realiza contando el número de veces que una característica ha sido elegida por los métodos de reducción utilizados. De esta forma conseguimos que aquellas elegidas por más métodos sean las más importantes, siendo las menos elegidas consideradas como irrelevantes.

En la realización de una reducción de características hay que tener en cuenta diversos factores, como por ejemplo las dimensionalidades del conjunto original de características y del conjunto reducido obtenido, numero de iteraciones realizadas en las clasificaciones para seleccionar el clasificador del método envoltorio

etc. Todos estos factores y los resultados obtenidos serán tratados en el capítulo 5 «Resultados».

Clasificación (B3.6)

El paso más importante a la hora de calcular correctamente la valoración de la ELCB es la clasificación. Para ello es necesario disponer de un conjunto de características reducido que mejore su eficacia y así poder afrontar con garantías este proceso. Se ha diseñado un sistema de clasificación (véase figura 4.40) basado en un clasificador no supervisado de tipo *K-Means*. La decisión de utilizar un clasificador de este tipo es debida a la dificultad de obtener una suficiente cantidad de regiones uniformes de diferentes tipos de heces que permita el entrenamiento de un clasificador supervisado. Para dar solución a esta problemática se han creado unas agrupaciones iniciales, una por cada tipo de heces y otra para el colon, de forma que la creación de los núcleos iniciales no sea aleatoria como en un *K-Means* estándar. El proceso de creación de los mismos y la posterior clasificación de las heces de las imágenes es un complejo proceso. Éste tiene como entrada un conjunto de imágenes colonoscópicas en las que se pueden encontrar heces y se compone de los siguientes pasos: selección de regiones con heces líquidas (B3.6.1), selección de regiones con heces sólidas (B3.6.2), selección de regiones con heces tintadas (B3.6.3), selección de regiones del colon (B3.6.4), enventanado de la imagen (B3.6.5), rotación y escalado de las imágenes (B3.6.6), extracción de características (B3.6.7), reducción de características (B3.6.8), creación de agrupaciones (B3.6.9), clasificación (B3.6.10) y como resultado se consigue una imagen con las heces clasificadas (B3.6.11). A continuación se describe en detalle este proceso.

Selección de regiones con heces líquidas (B3.6.1): para la creación del núcleo correspondiente a las heces líquidas es necesario seleccionar dentro del conjunto de imágenes de entrada aquellas regiones que sólo contienen heces líquidas. Estas regiones deben ser lo más uniformes posibles, de forma que no contengan heces de otros tipos ni tampoco partes de las paredes del colon. Además, su tamaño deberá ser mayor al de las ventanas utilizadas en el proceso posterior de enventanado. Esta tarea tiene una dificultad intermedia, ya que las heces líquidas suelen aparecer

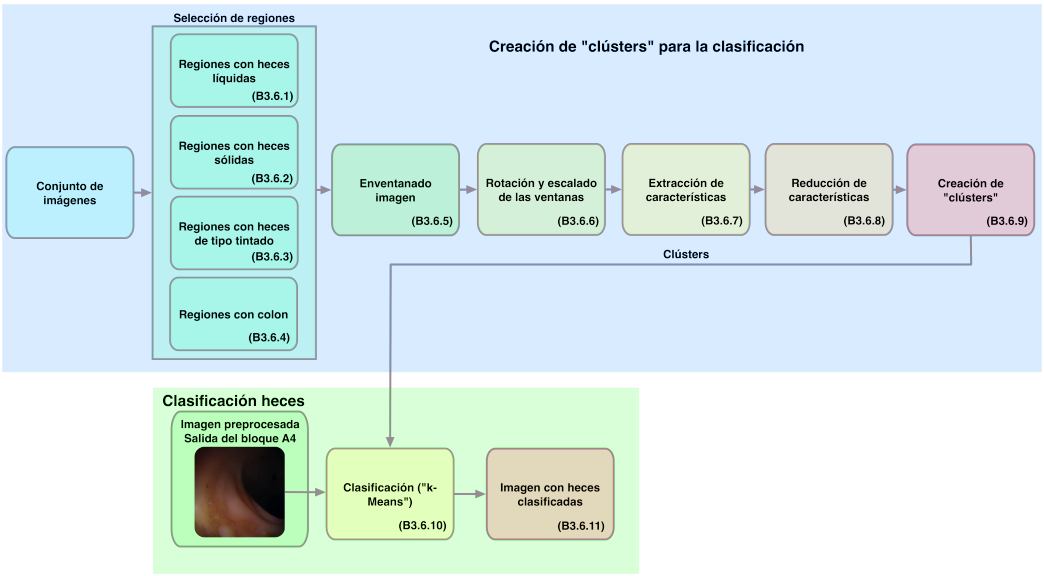


Figura 4.40: Proceso de creación de las agrupaciones para la clasificación de las heces.

en regiones uniformes, pero en muchos casos éstas son de tamaño reducido. Tras el recorte de múltiples regiones de heces líquidas pertenecientes a las diferentes imágenes, éstas deben guardarse para su posterior tratamiento.

Selección de regiones con heces sólidas (B3.6.2): de la misma forma que se ha realizado la selección de heces líquidas ha de realizarse la selección de heces sólidas. Este proceso es algo más sencillo que el anterior ya que las heces sólidas en la mayoría de los casos aparecen de forma más uniforme facilitando el recorte de las mismas. De igual manera que en el caso anterior las regiones con heces sólidas recortadas tienen que ser guardadas para su posterior tratamiento.

Selección de regiones con heces tintadas (B3.6.3): al igual que en los casos anteriores, hay que seleccionar aquellas zonas con heces tintadas. Este proceso es más complicado que los anteriores. Esto se debe a que suelen aparecer en regiones pequeñas y en muchas ocasiones mezcladas con otros tipos de heces, lo que dificulta la labor de recorte de estas zonas. Una vez hayan sido seleccionadas, éstas deben ser guardadas para su tratamiento.

Selección de regiones del colon (B3.6.4): por último se realiza una selección de las regiones pertenecientes al colon. Se trata de un sencillo proceso ya que existen multitud de regiones uniformes y con tamaño suficiente. Así como se ha realizado de forma previa, estas regiones deben ser guardadas para su tratamiento.

Enventanado de la imagen (B3.6.5): una vez haya sido realizado el proceso de selección de las regiones, éstas deben ser enventanadas para su análisis. Las ventanas utilizadas tienen un tamaño de 20x20 píxeles sin solapamiento, por lo que todas las regiones seleccionadas en los pasos anteriores deben tener un tamaño mayor a éste.

Rotación y escalado de las ventanas (B3.6.6): ya se ha explicado en el apartado B3.3 que es necesario realizar la rotación y escalado de las ventanas generadas en el proceso anterior para conseguir una mayor generalización mediante la posterior extracción de características. Esto aportará una mayor robustez al clasificador creado.

Extracción de características (B3.6.7): de la misma forma que se ha explicado en el apartado B3.4, se tiene que realizar una extracción de características de cada una de las regiones de los diferentes tipos de heces seleccionadas. De esta forma se obtendrá un conjunto de características por cada tipo de heces que se utilizará más adelante para la creación de las agrupaciones.

Reducción de características (B3.6.8): siguiendo el proceso descrito en el apartado B3.5 se procede a reducir el número de características, obteniendo el subconjunto de ellas con más poder de discriminación. Además de permitir una clasificación más precisa, el disponer de un conjunto de características con un menor tamaño facilita el manejo de datos y su tratamiento.

Creación de agrupaciones (B3.6.9): se debe crear una agrupación para cada tipo de heces y el colon, utilizando para ello los conjuntos de características reducidos creados previamente. Por cada una de las ventanas generadas se ha obtenido un conjunto de características que ha sido reducido, de forma que se obtendrán M

conjuntos de características de tamaño N (número de características). La creación de cada agrupación para cada tipo de heces se realiza mediante el siguiente proceso:

1. Concatenación de los conjuntos de características: por cada tipo de heces se obtienen M conjuntos de características con N descriptores cada uno de ellos. Es necesario realizar una concatenación de ellos obteniéndose una matriz de tamaño $M \times N$.

2. Cálculo de la mediana: se computará la mediana por columnas de la matriz obtenida en el punto anterior, de forma que se obtiene un vector de tamaño N que será una generalización de cada una de las características calculadas. Se ha utilizado la mediana para que los valores extremos tengan un menor efecto en el cálculo.

La figura 4.41 muestra una descripción gráfica del proceso de creación de las agrupaciones, indicando todos los procesos realizados hasta el momento. De esta forma se obtienen las agrupaciones correspondientes a las heces líquidas, sólidas, tintadas y el colon que serán utilizadas en las posteriores clasificaciones.

Clasificación *K-Means* (B3.6.10): la clasificación mediante un algoritmo *K-Means* requiere de dos entradas: la imagen a clasificar y las agrupaciones creadas. En primer lugar, se configura el clasificador con las agrupaciones generadas en el paso anterior. Por defecto este método de clasificación genera unas agrupaciones aleatorias para cada una de las clases y los datos se van clasificando en ellas en función de una medida de distancia entre sus características y los centros de las agrupaciones. Los datos se clasificarán en el grupo con el que haya menor distancia. Para una mayor eficacia, las agrupaciones se van modificando de forma que tengan una adaptación a los datos ya clasificados, consiguiéndose una mayor generalización. En el sistema de clasificación propuesto los grupos iniciales ya no son aleatorios, además de haberse limitado el proceso de adaptación de los mismos para tratar de no corromper las agrupaciones creadas.

Una vez el clasificador ha sido configurado se puede proceder a clasificar las heces de la imagen deseada. El clasificador tiene como entrada vectores de características procedentes del enventanado de la imagen a clasificar, de forma que la

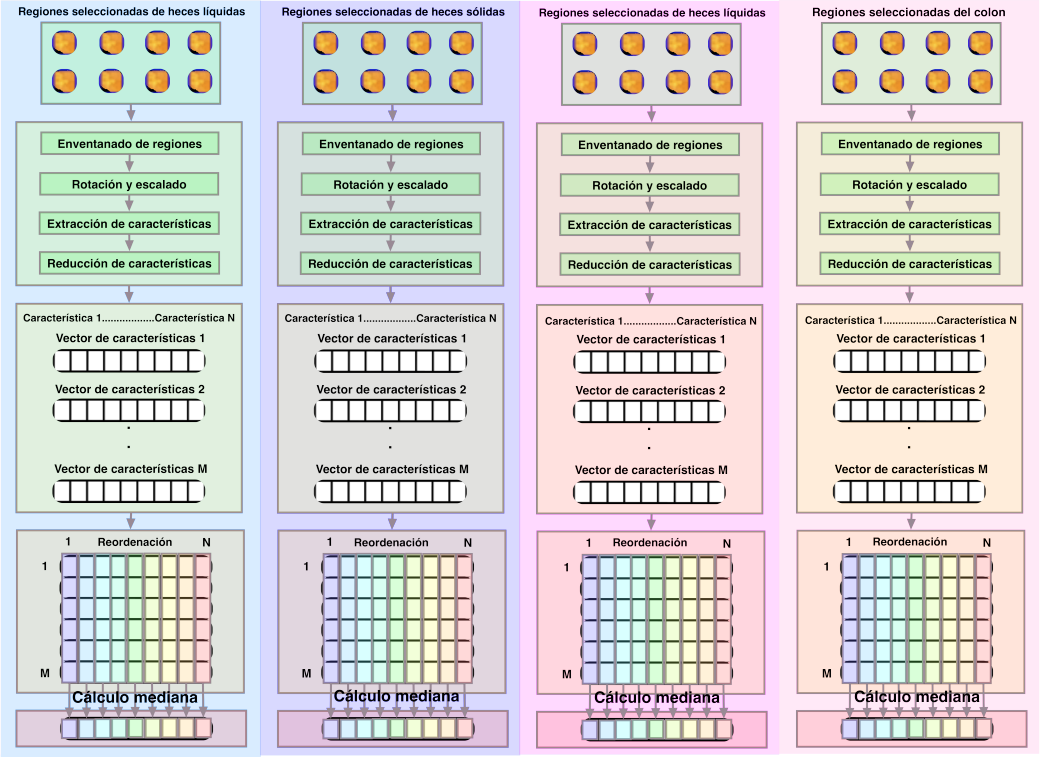


Figura 4.41: Creación de las agrupaciones para la clasificación de las heces.

salida obtenida del mismo también tendrá el mismo formato. Para poder interpretar los resultados de la salida obtenida es necesario volver a ordenarla para obtener la imagen clasificada. Este proceso se describe gráficamente en la figura 4.42 para una mejor interpretación. Se observa que la salida del clasificador es un vector de tamaño 1x9, de manera que impide su interpretación. En el paso 1 se realiza la reordenación, de forma que el vector inicial pasa a tener forma matricial, la misma que tenía la imagen enventanada inicial a clasificar. La reordenación dependerá del tamaño inicial de la imagen y del tamaño de enventanado utilizado. Como resultado se puede ver en el paso 2 como se obtiene una imagen que es fácil de entender.

Imagen con heces clasificadas (B3.6.11): como resultado de este proceso se obtiene una imagen con las heces clasificadas en los diferentes tipos: líquidas, sólidas y tintadas. Gracias a esta clasificación se permite el posterior cálculo de los porcentajes de cada tipo de heces que es el pilar fundamental para la valoración de

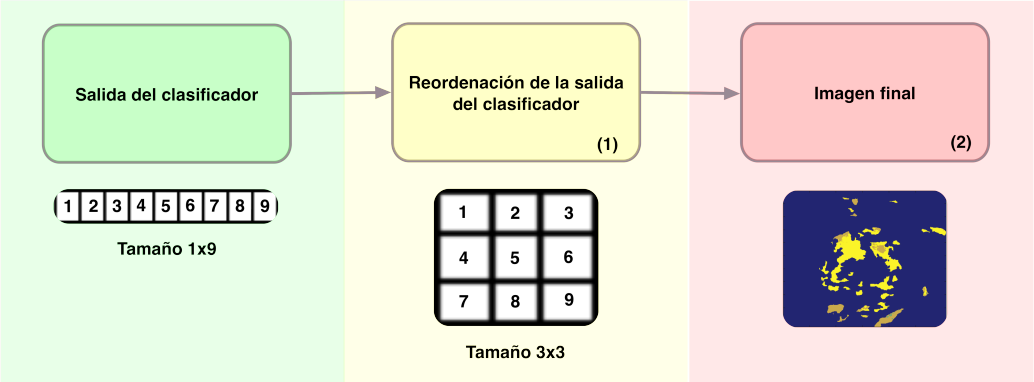


Figura 4.42: Reordenación de la salida del clasificador.

la ELCB.

Cálculo del porcentaje de heces por tipo (B3.7)

Una vez realizada la clasificación de las heces detectadas en la imagen se procede a calcular el porcentaje de cada uno de los tipos. Para ello es necesario tener la siguiente información: máscara con los bordes negros y la clasificación de las heces. La máscara de los bordes negros es necesaria para saber que cantidad de píxeles de la imagen pertenecen a ellos. Recordamos que los bordes negros son reconstruidos como parte del preprocesado de la imagen ya que de esta forma se evitaban falsos bordes. Estos bordes negros son los que se encuentran en el interior de la cuadrícula naranja mostrada en la figura 4.11 y que en la clasificación son definidas como parte del colon, por lo que deben descartarse. La clasificación de las heces realizada proporciona un valor entre 0 y 3 a cada píxel de la imagen. El valor 0 corresponde al colon, 1 a las heces líquidas, 2 a las heces tintadas y 3 a las heces sólidas. Con toda esta información se calcula el porcentaje de colon y de heces de cada tipo en la imagen.

Sistema de análisis de resultados de la precisión de la clasificación de heces diseñada (R2)

Tras el diseño del sistema de clasificación de las heces se procede a evaluar la precisión del mismo. Para ello se ha utilizado el mismo conjunto de 200 imágenes

colonoscópicas utilizadas en la evaluación de la precisión de la detección de las heces. En este caso se ha realizado una segmentación manual de los diferentes tipos de heces en cada imagen, de forma que se dispone de datos para contrastar los resultados obtenidos por el método propuesto y los proporcionados por ambos especialistas. Los datos disponibles para esta evaluación son:

- Porcentajes de heces líquidas, sólidas y tintadas para cada una de las 200 imágenes utilizadas, proporcionados por el especialista 1.
- Porcentajes de heces líquidas, sólidas y tintadas para cada una de las 200 imágenes utilizadas, proporcionados por el especialista 2.
- Porcentajes de heces líquidas, sólidas y tintadas para cada una de las 200 imágenes utilizadas, proporcionados por la clasificación diseñada.
- Porcentajes de heces líquidas, sólidas y tintadas para cada una de las 200 imágenes utilizadas, segmentadas de forma manual (validados por los especialistas y considerados reales).

Se comienza la evaluación de la precisión del sistema de clasificación de las heces determinando el tipo de distribución de los datos a tratar. Para ello se hará uso del test de Kolmogorov-Smirnov, el cual ha sido descrito previamente.

Para evaluar de una forma robusta las diferencias significativas entre los porcentajes de los diferentes tipos de heces proporcionados por los especialistas, el método propuesto y la realidad, se utilizará el test no paramétrico de la suma de rangos de Wilcoxon para muestras emparejadas (descrito previamente). Se evaluarán todos los emparejamientos posibles para los cuatro grupos disponibles de forma independiente para cada tipo de heces.

Además, se calculará el CCI para cada tipo de heces de forma independiente, comprobando la correlación existente entre el especialista 1, el especialista 2, el método propuesto y los porcentajes de heces reales presentes en las imágenes. Con ello se pretende determinar la analogía existente entre los porcentajes de los diferentes tipos de heces manejados.

Para finalizar con este bloque de evaluación se calculará el error existente en los porcentajes de los diferentes tipos de heces detectados por el especialista 1, el

especialista 2 y el método propuesto respecto al porcentaje real para cada una de las 200 imágenes utilizadas. Se calculará el EAM, la mediana y la desviación típica de los errores para determinar quien es más preciso. El cálculo del error se realiza haciendo uso de la ecuación 4.8.

Mediante este proceso se pretende validar la clasificación de las heces propuesta, demostrando su eficacia y buen desempeño. La información obtenida sobre este aspecto se muestra en el apartado 5.2.1.2 ≪Análisis de resultados de la precisión de la clasificación de heces diseñada (R2)≫ perteneciente al capítulo 5 ≪Resultados≫.

4.2.2.4 **Cálculo de la ELCB (B4)**

La metodología diseñada para el cálculo de la ELCB ha sido creada en colaboración con un conjunto de expertos endoscopistas. Se ha propuesto un cálculo de la ELCB basado en 6 imágenes pertenecientes a diferentes zonas del colon y que lo cubren en su totalidad. La ELCB realiza una valoración para las zonas del colon derecha, transversa e izquierda. En nuestro caso, para la evaluación del colon derecho se ha decidido utilizar dos imágenes, una del ciego y otra del ascendente. En cuanto a la evaluación del colon transverso se utilizará una imagen del propio colon transverso. Por último, para la evaluación del colon izquierdo se utilizan tres imágenes, la primera de ellas del colon descendente, la segunda del sigma y la tercera del recto. La figura 4.43 muestra una representación gráfica de la disposición de las imágenes a lo largo del colon.

La puntuación para cada una de las zonas especificadas por la ELCB (derecha, transversa e izquierda) se realiza analizando las imágenes pertenecientes a cada zona. En el caso del colon derecho se valoran las imágenes del ciego y colon ascendente, para el colon transverso, sólo la imagen del colon transverso y por último, para el colon izquierdo se valoran las imágenes del colon descendente, sigma y recto. Puede verse que tanto el colon derecho como el izquierdo tienen más de una imagen, por lo que se obtiene más de una valoración para cada uno de ellos. Como decisión consensuada del grupo de expertos consultados, se ha decidido que la puntuación otorgada al colon derecho sea la menor de las puntuaciones dadas a las imágenes del ciego y colon ascendente, siendo también la menor puntuación otorgada a las imágenes del colon descendente, sigma y recto en el caso del colon

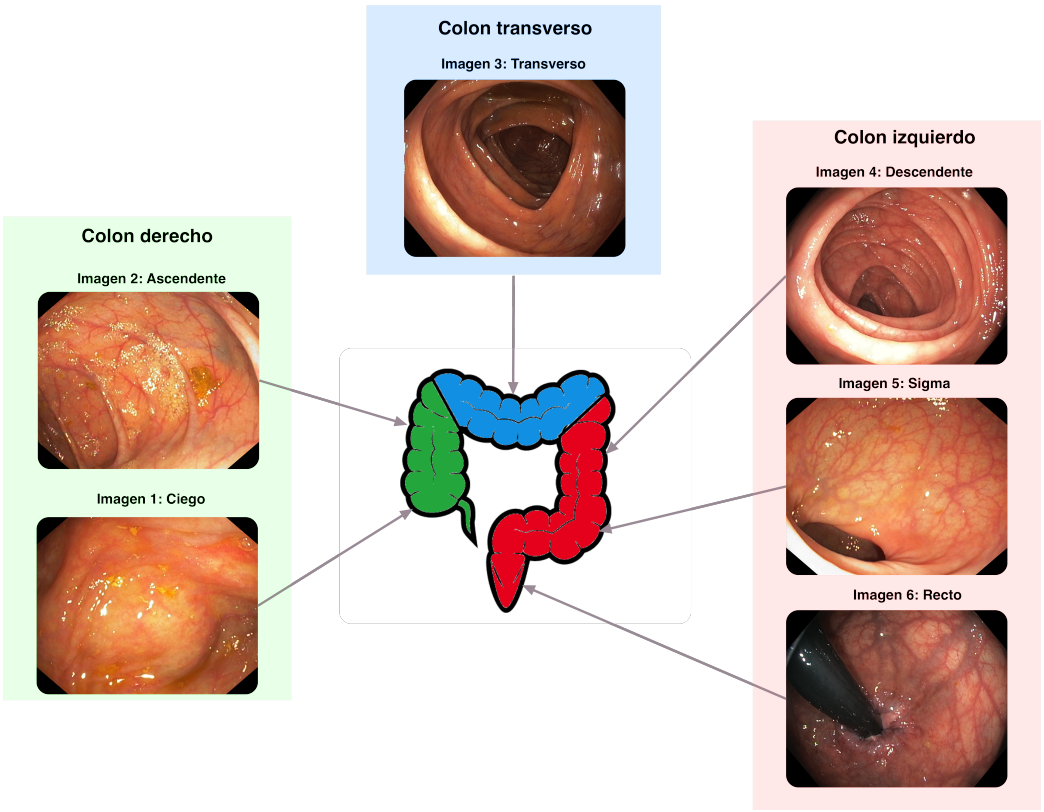


Figura 4.43: Imágenes necesarias para el cálculo de la ELCB.

izquierdo. Se ha pretendido deliberadamente diseñar una valoración de la preparación del colon mediante la ELCB lo mas restrictiva posible. Esto es debido a que es preferible dar una puntuación baja a una colonoscopia y que ésta tenga que ser repetida, a darle una mejor puntuación, no siendo repetida y pudiendo contener lesiones perdidas. Con ello se prima la salud del paciente sobre aspectos económicos (repetición de la prueba).

El cálculo de las puntuaciones de la ELCB de las imágenes está determinado por el porcentaje de heces de cada tipo presentes en la imagen y del peso específico (importancia) de cada una de ellas. El peso específico de las heces ha sido acordado junto con los especialistas, siendo para el caso de las heces sólidas $W_{Sólidas}$ = 1 por ser las más dañinas, $W_{Tintado}$ = 0.85 para las heces tintadas, ya que tienen un efecto intermedio y por último, $W_{Líquidas}$ = 0.75 para las heces líquidas por ser las menos dañinas. El cálculo de la ELCB para cada una de las imágenes se

realiza como muestra la figura 4.44. En función de la valoración obtenida se consigue una puntuación de la ELCB. La máxima valoración se consigue cuando la $Valoración <= 7$. La especificación de la ELCB indica que sólo se debe dar una puntuación de 3 a aquellas imágenes exentas de heces. En este caso se ha permitido contener hasta una valoración de 7, ya que existe la posibilidad de tener píxeles espurios. Para asignar una puntuación de 2 es necesario que $8 <= Valoración <= 30$. Para una puntuación de 1 es requisito que $31 <= Valoración <= 65$. Para finalizar, se asigna una puntuación de 0 cuando la $Valoración >= 66$.

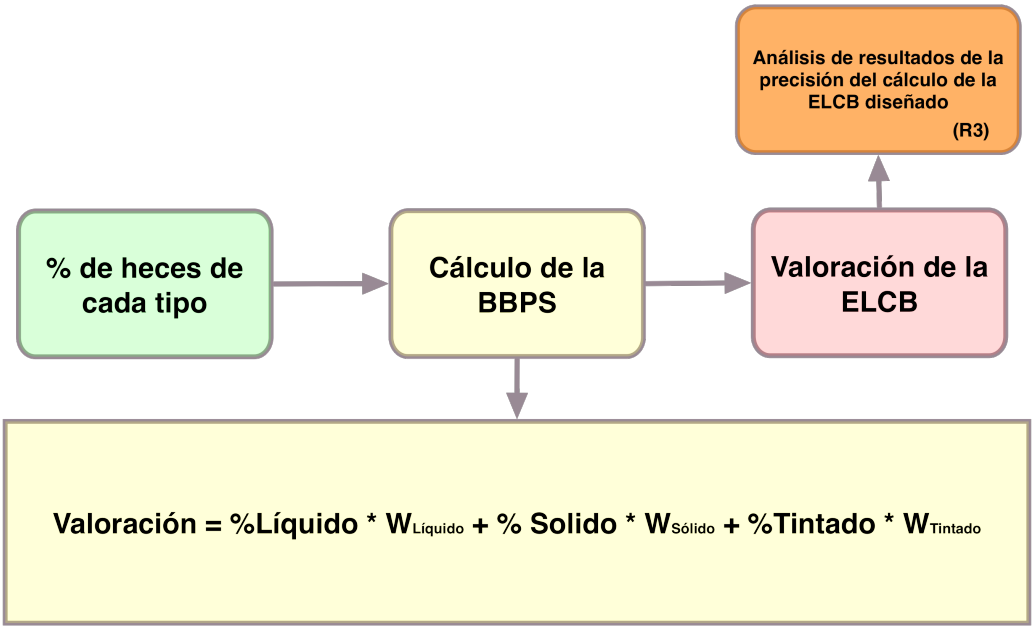


Figura 4.44: Metodología diseñada para el cálculo de la ELCB. W y $\%$ representan los pesos y porcentajes de heces de cada tipo.

Sistema de análisis de resultados de la precisión del cálculo de la ELCB diseñado (R3)

La validación del cálculo de la ELCB propuesto se realiza mediante la comparación de las puntuaciones proporcionadas por los especialistas, el método propuesto y una valoración "semi-real" haciendo uso de las 200 imágenes colonoscópicas utilizadas tanto en la evaluación de la precisión de la detección de heces, como en la

evaluación de la precisión de la clasificación de heces diseñada. Hay que tener en cuenta la complicación de la validación de este sistema, ya que no existe en la actualidad ningún método objetivo y validado para ello. Se sabe que las valoraciones de la ELCB proporcionadas por los especialistas sufren de cierta subjetividad, pero la variabilidad entre especialistas no es tan alta como cabría de esperar. Como se sabe, el calculo de la ELCB propuesto depende de los pasos dados con anterioridad (detección de heces (B2) y clasificación de heces (B3)) los cuales han sido validados y sujetos a un estudio de evaluación de su eficacia y precisión (bloques R1 y R2). Los datos disponibles para esta evaluación son:

- Valoraciones de la ELCB para cada una de las 200 imágenes utilizadas proporcionadas por el especialista 1.
- Valoraciones de la ELCB para cada una de las 200 imágenes utilizadas proporcionadas por el especialista 2.
- Valoraciones de la ELCB para cada una de las 200 imágenes utilizadas proporcionadas por el método propuesto.
- Valoraciones de la ELCB para cada una de las 200 imágenes utilizadas proporcionadas por el método propuesto haciendo uso de los porcentajes reales de cada tipo de heces ("semi-real").

Para comenzar, el sistema de evaluación de la precisión del cálculo de la ELCB comienza con la determinación del tipo de distribución de los datos a tratar. Para ello se hará uso del test de Kolmogorov-Smirnov, el cual ha sido descrito de forma previa.

Para evaluar de una forma exhaustiva las diferencias significativas entre las valoraciones de la ELCB proporcionadas por ambos especialistas, el método propuesto y la valoración basada en los porcentajes reales de los diferentes tipos de heces, se utilizará el test no paramétrico de la suma de rangos Wilcoxon para muestras emparejadas (descrito de forma previa). Se evaluarán todos los emparejamientos posibles para los cuatro grupos (especialista 1, especialista 2, método propuesto y método basado en los porcentajes reales de heces).

Además, se calculará el CCI para comprobar la correlación existente entre las valoraciones de la ELCB del especialista 1, el especialista 2, el método propuesto y la valoración obtenida, haciendo uso de los porcentajes reales presentes en las imágenes. Con ello se pretende analizar la analogía existente entre ellas.

Para finalizar con este bloque de evaluación se calculará el error existente en las valoraciones de la ELCB proporcionadas por el especialista 1, el especialista 2 y el método propuesto respecto a la valoración de la ELCB basada en los porcentajes de los diferentes tipos de heces presentes en cada una de las 200 imágenes utilizadas. Se calculará el EAM y la desviación típica de los errores para determinar quien es más preciso. El cálculo del error se realiza mediante la ecuación 4.8.

Con todo esto se ha pretendido que el cálculo de la ELCB diseñado esté asentado sobre datos fiables y precisos. Los resultados obtenidos se muestran en el apartado 5.2.1.3 ≪Análisis de resultados de la precisión del cálculo de la ELCB diseñado (R3)≫ del capítulo 5 ≪Resultados≫.

4.2.3 **Detección automática de pólipos. (C)**

El tercer módulo de la investigación que se presenta es el relativo a la detección automática de pólipos (véase figura 4.45). La necesidad de contar con herramientas de ayuda al diagnóstico por parte de los endoscopistas es una obviedad. Por un lado, la forma del colon con su multitud de huecos y pliegues hacen de la detección de pólipos una tarea con una alta complejidad, por otro lado, el aumento del número de colonoscopias realizadas en los últimos años hace que los especialistas se vean desbordados. Esto hace que no se pueda dedicar todo el tiempo necesario a las exploraciones, incrementándose el número de lesiones perdidas, con el perjuicio que esto supone para los pacientes.

El sistema de detección automática de pólipos propuesto se basa en la combinación del análisis de los bordes y la textura de las imágenes. La decisión de utilizar un enfoque combinado se debe en gran medida a la variedad de forma y localización de los pólipos en el colon. Esto dificulta la detección automática de pólipos, haciendo que la utilización de una única técnica no permita detectar todos los pólipos existentes de una forma eficaz. Mediante esta arquitectura se conseguirá una mejor detección gracias a la unión de las ventajas de ambos enfoques.

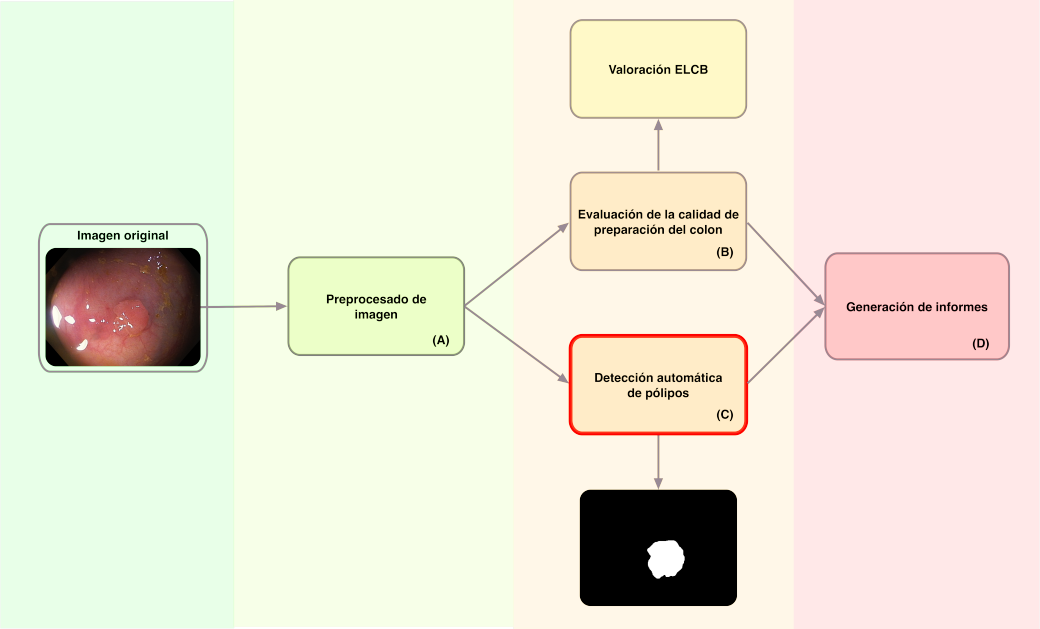


Figura 4.45: Módulo C. Detección automática de pólipos.

Este sistema se compone de tres diferentes bloques: detección automática de pólipos mediante el análisis de bordes (C1), detección automática de pólipos mediante el análisis de la textura (C2) y combinación de la detección de pólipos mediante los análisis de bordes y textura (C3). A continuación se realizará una descripción en detalle de cada uno de ellos.

4.2.3.1 Detección automática de pólipos mediante el análisis de bordes (C1)

El primero de los métodos de detección automática de pólipos llevado a cabo está basado en el análisis de los bordes (véase figura 4.46). Cuando se realiza una detección de bordes en una imagen colonoscópica se obtienen multitud de ellos, pero aquellos pertenecientes a los pólipos tienen unas características especiales en cuanto a su curvatura, intensidad y forma, lo que hace posible su detección automática. Hay que tener en cuenta que este enfoque obtiene mayor eficacia cuando el pólipo está más alejado de la cámara, es decir, cuando se consigue una vista completa de él, permitiéndose detectar todo su contorno. Para casos en los que el pólipo está situado más cerca de la cámara la textura será más efectiva, ya que facilita la captura en más detalle de los patrones que lo componen.

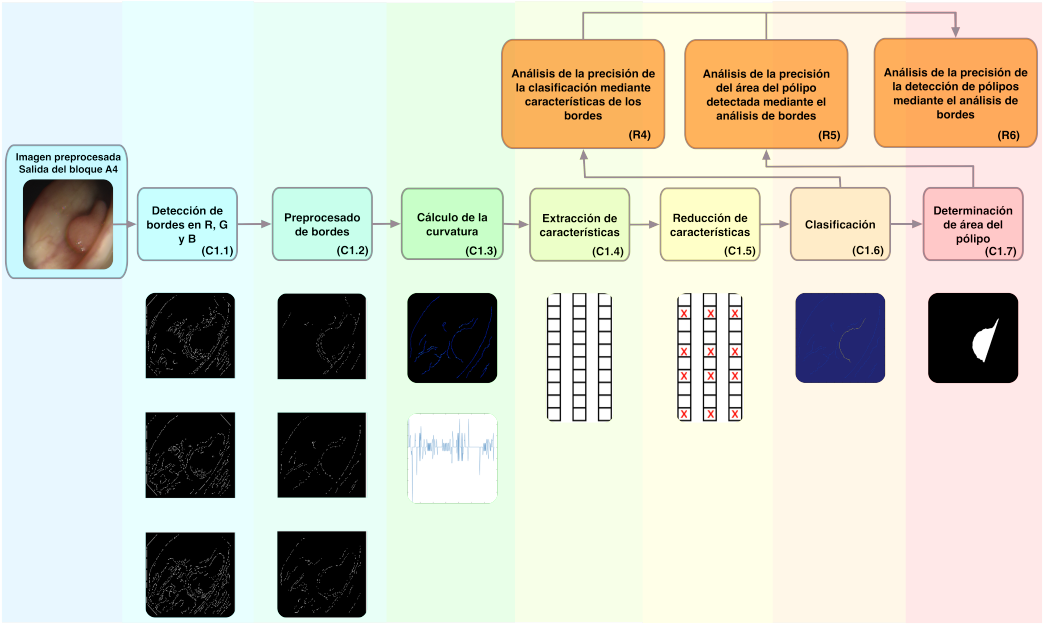


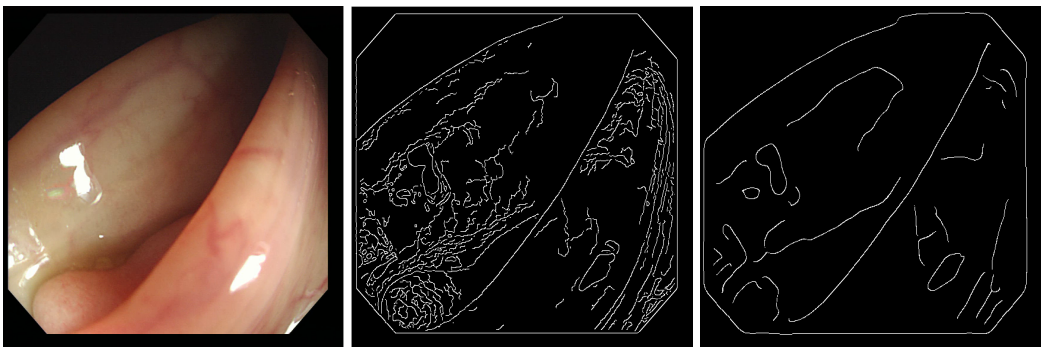
Figura 4.46: Bloque C1. Detección automática de pólipos mediante el análisis de los bordes.

El sistema de detección automática de pólipos mediante el análisis de los bordes diseñado se compone de los siguientes siete bloques: detección de bordes en los canales R, G y B (C1.1), preprocesado de bordes (C1.2), cálculo de la curvatura (C1.3), extracción de propiedades (C1.4), reducción de características (C1.5), clasificación (C1.6) y determinación del área del pólipo (C1.7). A continuación se realiza una descripción detallada de cada uno de los bloques.

Detección de bordes en canales R, G y B (C1.1)

El primer bloque del sistema es el de detección de bordes. Las imágenes a tratar están codificadas mediante el modelo de color RGB, por lo que se ha realizado una detección de bordes en cada uno de sus canales. De esta forma se consigue una detección más exacta, ya que no todos aparecen en todos los canales debido a la representación del color. Este bloque tiene como entrada una imagen preprocesada (salida del módulo A4) a la que se le aplicará el algoritmo de Canny para la detección de los bordes.

El algoritmo de Canny realiza un suavizado de la imagen mediante un filtrado gaussiano, cuya intensidad viene determinada por el parámetro σ, que es la desviación estándar del filtro. Este parámetro ha sido fijado en $\sqrt{2}$. Además, se han ajustado los valores de los dos umbrales que fija el método, siendo el primero de ellos 0.03 y el segundo 0.1. De esta forma se consigue eliminar multitud de bordes débiles que en su mayoría son debidos a la presencia de ruido en la imagen. El efecto del ajuste de estos parámetros puede verse en la figura 4.47 en la que en la imagen 4.47(a) se muestra una imagen colonoscópica, en la imagen 4.47(b) se muestran los bordes detectados sin el ajuste de parámetros y en la imagen 4.47(c) se proporcionan los bordes detectados ajustando los parámetros oportunos. Esta parametrización ha sido realizada mediante la prueba de diferentes umbrales y factores de suavizado en múltiples imágenes de la base de datos utilizada. Ésta es una tarea difícil y laboriosa, ya que es complicado cuantificar la bonanza de los parámetros elegidos.



(a) (b) (c)

Figura 4.47: Efectos del ajuste de parámetros en el algoritmo de Canny. a) Imagen colonoscópica original. b) Bordes detectados sin el ajuste de parámetros. c) Bordes detectados con el ajuste de parámetros.

Tras el cálculo de los bordes en los canales R, G y B es necesario el preprocesado de los mismos. Con ello se eliminarán ciertos aspectos que limitan el buen desempeño de los algoritmos a aplicar sobre ellos. Esta temática será tratada en el próximo apartado.

Preprocesado de bordes (C1.2)

Tras la detección de los bordes es indispensable el preprocesado de los mismos. A pesar de haber parametrizado el método de Canny para tratar de evitar la aparición de bordes no deseados, debido a las características de las imágenes se siguen detectando ciertos contornos que es necesario eliminar. Para ello se ha diseñado el sistema de preprocesado de bordes mostrado en la figura 4.48.

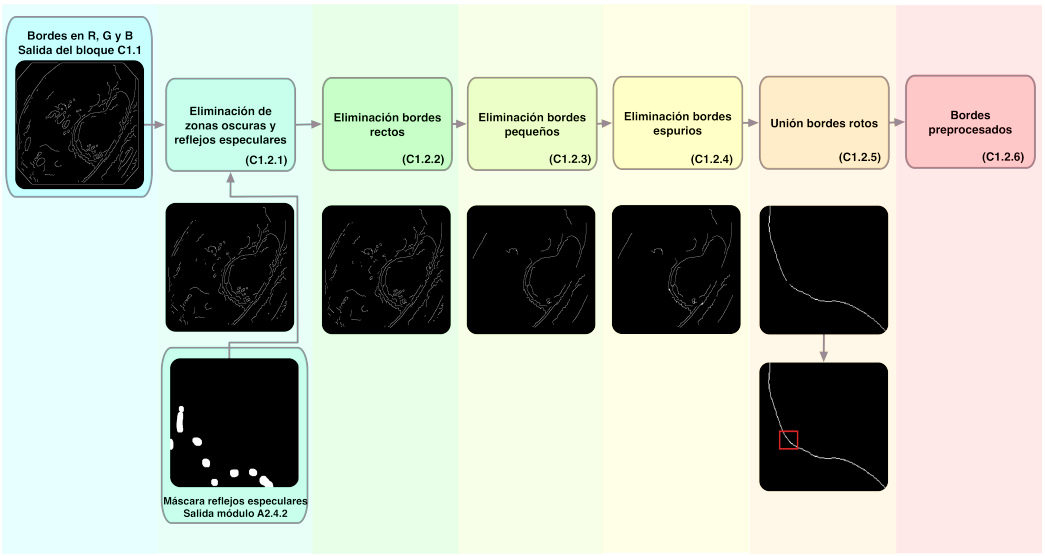


Figura 4.48: Preprocesado de bordes.

El sistema tiene como entrada las imágenes con los bordes en R, G y B obtenidas en el bloque C1.1 y consta de cinco bloques: eliminación de zonas oscuras y reflejos especulares (C1.2.1), eliminación de bordes rectos (C1.2.2), eliminación de bordes pequeños (C1.2.3), eliminación de bordes espurios (C1.2.4), unión de bordes rotos (C1.2.5) y bordes preprocesados (C1.2.6). Con ello se consigue como salida del sistema una imagen con los bordes preprocesados. A continuación se describe en detalle cada uno de estos pasos.

Eliminación de zonas oscuras y reflejos especulares (C1.2.1): el primer paso a la hora de realizar un preprocesado de los bordes es la eliminación de contornos en zonas oscuras y bordes residuales debidos a reflejos especulares. En muchas ocasiones son detectados bordes en zonas oscuras de la imagen. En su gran mayoría

son debidos a residuos de ruido no eliminados por el filtrado gaussiano del método de Canny. Estos bordes no son deseados ya que impiden delimitar objeto alguno, además de suponer un coste computacional innecesario, debido a que se analizarán sin esperanza de obtener resultado alguno de ellos. La eliminación de estos bordes se realiza mediante un proceso de tres pasos. Estos se describen a continuación:

1. Detección de zonas oscuras: se realiza una conversión de la imagen al modelo de color HSV. En él se realiza un umbralizado en el canal H, donde los píxeles que cumplan la condición H <0.08 son considerados de zonas oscuras. Así se obtiene la considerada máscara oscura.

2. Relleno de huecos en la máscara oscura: es común que en el interior de la máscara oscura existan regiones huecas. Éstas son rellenadas siempre y cuando su tamaño no sea mayor a una estructura de tipo disco de tamaño 5. Con ello conseguimos una máscara con regiones más uniformes.

3. Multiplicación de la máscara por la imagen de bordes: una vez refinada la máscara, las zonas oscuras están definidas por el valor 0 y el resto por el valor 1. Realizando su multiplicación con la imagen de bordes, en la que los bordes tienen valor 1 y el resto 0, obtenemos una imagen sin bordes en zonas oscuras.

En cuanto a la eliminación de los bordes detectados debidos a efectos persistentes de los reflejos especulares se ha desarrollado un algoritmo que busca y elimina estos contornos. Este método consta de tres pasos y para ello requiere disponer como entrada de la máscara con los reflejos especulares (salida de módulo A2.2.4). Este proceso se describe a continuación:

1. Cálculo de los centroides de los reflejos especulares: los reflejos especulares en su mayoría tienen forma redondeada, de manera que para fijar sus posiciones centrales se ha decidido utilizar sus centroides.

2. Búsqueda de posibles bordes especulares: una vez obtenidos los centroides, se buscan aquellos bordes que están a una distancia menor a 15 píxeles. Estos bordes son especulares, ya que al realizar la reconstrucción de los reflejos se sabe que no debería aparecer borde alguno.

3. Eliminación de bordes especulares: tras la detección de los bordes debidos a efectos de los reflejos especulares que no han podido ser resueltos mediante el preprocesado de la imagen, estos son eliminados.

Mediante este proceso se consigue una imagen sin bordes en zonas oscuras y bordes debidos a reflejos especulares. En la figura 4.49 puede verse el efecto de este preprocesado. La imagen 4.49(a) muestra los bordes iniciales y la imagen 4.49(b) la obtenida mediante este proceso. Cabe destacar que la imagen utilizada como base no ha sido preprocesada para destacar más los efectos y que estos sean más visibles.



(a) (b)

Figura 4.49: Resultado de la eliminación de los bordes negros. a) Imagen con bordes originales. b) Imagen sin bordes de la máscara negra ni especulares.

El próximo paso en el preprocesado de los bordes es la eliminación de bordes rectos que se aborda en el siguiente apartado.

Eliminación de bordes rectos (C1.2.2): la eliminación de bordes rectos se realiza para conseguir un ahorro de coste computacional. Los pólipos no contienen formas rectas, por lo que su análisis es en vano. Estos contornos de igual manera podrían haberse descartado mediante el análisis de los bordes, pero el tiempo de ejecución sería mayor, por lo que se ha decidido su eliminación en este preprocesado.

La detección de bordes rectos se realiza por medio del análisis de la excentricidad de la figura geométrica que los envuelve. La excentricidad tiene valor 1 para líneas rectas y valor 0 para círculos perfectos. Su cálculo se realiza mediante la ecuación 4.16, en la que a y b determinan de forma respectiva la diagonal mayor y menor de la figura a analizar.

$$Excentricidad = \frac{\sqrt{(a^2 - b^2)}}{a} \tag{4.16}$$

Aquellos bordes que obtienen un valor de excentricidad mayor a 0.9995 son considerados como rectos y por lo tanto son eliminados. El resultado de este proceso puede verse en la figura 4.50 en la que la imagen 4.50(a) muestra una imagen sin bordes de zonas oscuras ni especulares y la imagen 4.50(b) ofrece el resultado de la eliminación de los bordes rectos.



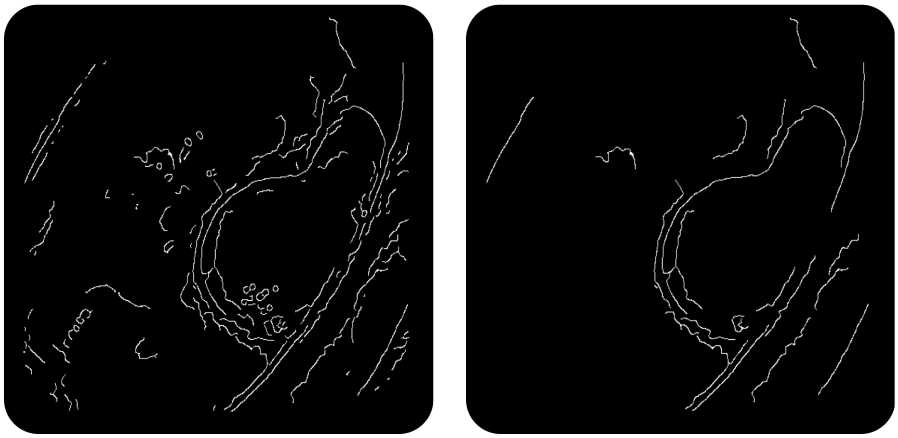
(a) (b)

Figura 4.50: Resultado de la eliminación de los bordes rectos. a) Imagen sin bordes de zonas oscuras ni especulares. b) Imagen sin bordes rectos.

El siguiente paso en el preprocesado de los bordes es la eliminación de bordes pequeños que se describe en el siguiente apartado.

Eliminación de bordes pequeños (C1.2.3): los bordes que tienen un tamaño reducido han de ser tratados porque, por un lado no pertenecen a los pólipos y por otro lado, suelen ser bastante ruidosos, de forma que obtienen unos cálculos de

curvatura, forma e intensidad inexactos. La detección de los bordes pequeños es realizada mediante el análisis de su perímetro. Todos aquellos bordes que tienen un perímetro menor a 15 píxeles son eliminados consiguiendo una imagen de bordes más limpia y adecuada. El resultado de este proceso puede verse en la figura 4.51, dónde la imagen 4.51(a) muestra la imagen sin bordes rectos obtenida en el paso anterior y la imagen 4.51(b) enseña el resultado obtenido.



(a) (b)

Figura 4.51: Resultado de la eliminación de los bordes pequeños. a) Imagen sin bordes rectos. b) Imagen sin bordes pequeños.

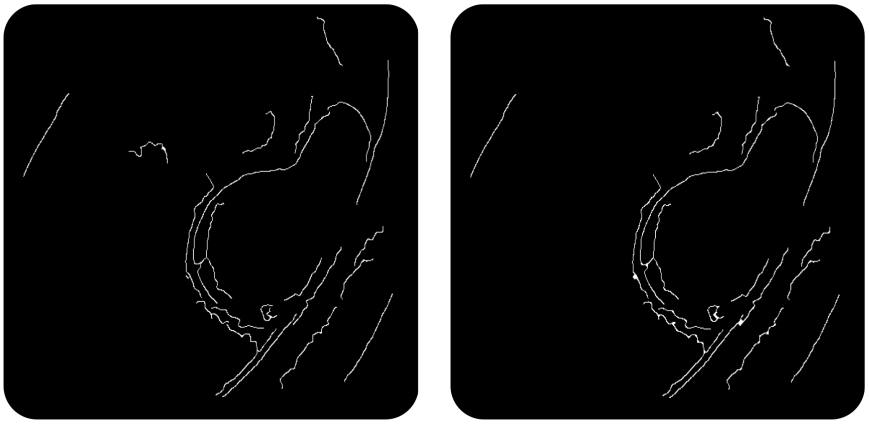
Tras este proceso se realiza la eliminación de bordes espurios. Ésta se describe a continuación.

Eliminación de bordes espurios (C1.2.4): la eliminación de bordes espurios es el último proceso con el que se descartan bordes. Son considerados bordes espurios aquellos que tienen una intensidad media mayor a 225 o una intensidad media menor a 25 en escala de grises, además también entran en este grupo aquellos bordes cuya envolvente tiene un área menor a 80 píxeles.

En el caso de su detección mediante el análisis de la intensidad, se considera un complemento a la eliminación de bordes de zonas oscuras y bordes pertenecientes a efectos no solucionados mediante el preprocesado de los reflejos especulares. Se

sabe que los pólipos nunca tienen unos valores de intensidad en estos rangos, por lo que es preferible su eliminación.

En cuanto al área, la existencia de un pólipo con un área menor a 80 píxeles es muy poco probable. Normalmente los bordes con una envolvente de área menor a 80 píxeles son debidos al ruido u otros efectos no deseados en la imagen. El resultado de la eliminación de los bordes espurios se puede ver en la figura 4.52, donde la imagen 4.52(a) muestra la imagen de bordes obtenida en el paso anterior y la imagen 4.52(b) proporciona el resultado conseguido.



(a) (b)

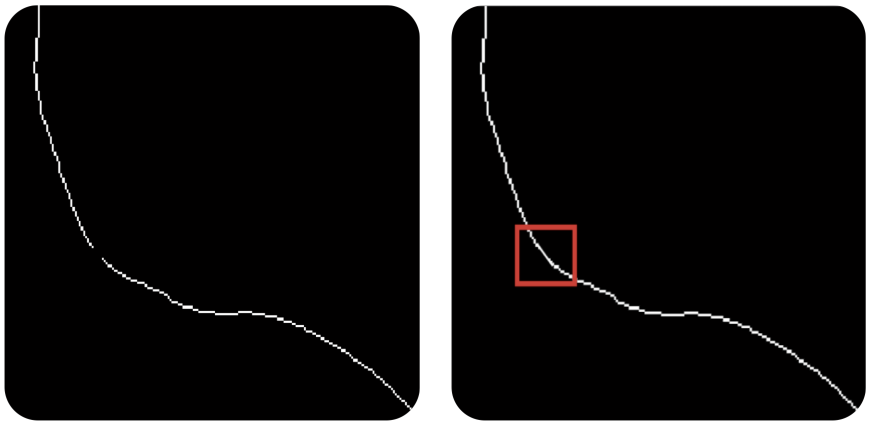
Figura 4.52: Resultado de la eliminación de los bordes espurios. a) Imagen sin bordes pequeños. b) Imagen sin bordes espurios.

Finalizada la eliminación de los bordes espurios se pasa a la última etapa del preprocesado de los bordes, la unión de bordes rotos.

Unión de bordes rotos (C1.2.5): el último paso del preprocesado de los bordes es la unión de bordes rotos. Existen ocasiones en las que los bordes pueden aparecer cortados. Esto es un problema porque a la hora de calcular propiedades del mismo, en caso de no ser tratados, se realizará el cálculo para dos bordes de forma independiente, cuando en realidad es un único contorno, que debido a las características de la imagen o del algoritmo utilizado para su detección aparece

partido. Para ello se ha propuesto la unión de aquellos bordes que aparecen cortados con una distancia máxima de un píxel. Con ello se consigue una reconstrucción que facilita su posterior análisis.

El resultado de la unión de los bordes rotos se puede ver en la figura 4.53 donde la imagen 4.53(a) muestra un borde partido y la imagen 4.53(b) presenta la unión realizada. Mediante este paso los bordes quedan preprocesados y preparados para ser analizados.



(a) (b)

Figura 4.53: Resultado de la eliminación de los bordes rotos. a) Imagen con borde roto. b) Imagen con borde unido.

Bordes preprocesados (C1.2.6): como salida del sistema de preprocesado de los bordes detectados se obtienen unos contornos útiles y libres de efectos adversos. Estos bordes estarán listos para ser administrados a los algoritmos que calculan la curvatura y extraen propiedades de ellos.

Cálculo de la curvatura (C1.3)

El cálculo de la curvatura de los bordes preprocesados será uno de los descriptores que nos permitirá realizar una detección de pólipos. A partir de la curvatura se extraen una serie de características que permiten la discriminación entre aquellos bordes pertenecientes a los pólipos y los que no. Este proceso tiene como entrada

los bordes preprocesados obtenidos del punto anterior y consta de cinco pasos: suavizado gaussiano de los bordes (C1.3.1), adelgazamiento de los bordes (C1.3.2), eliminación de ramificaciones (C1.3.3), reordenación de los puntos de los bordes (C1.3.4) y cálculo de la curvatura (C1.3.5). En la figura 4.54 se puede ver el sistema diseñado para este propósito.

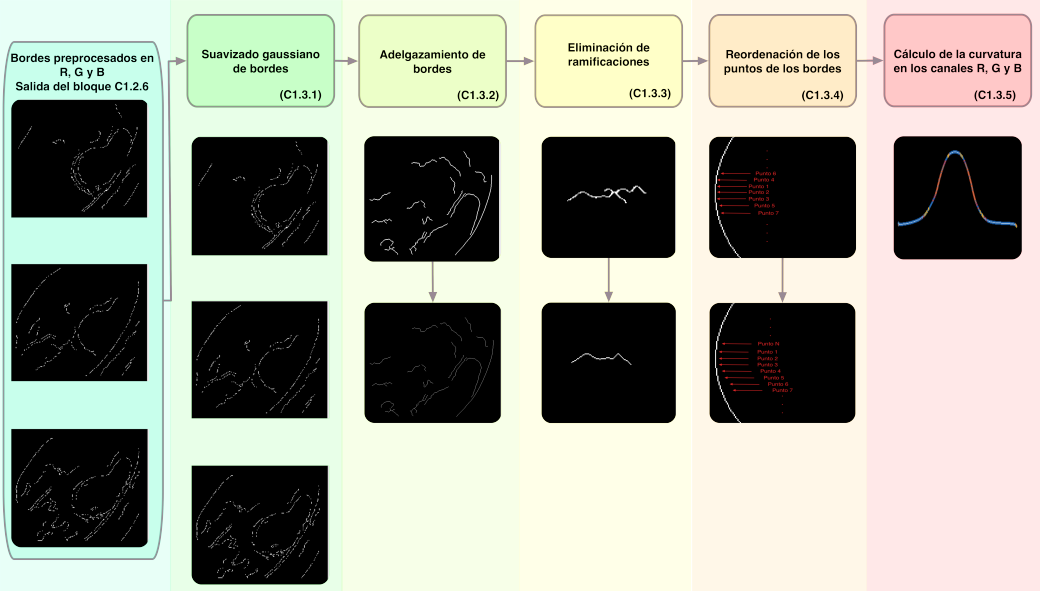


Figura 4.54: Cálculo de la curvatura de los bordes.

A pesar de haber sido realizado un preprocesado de los bordes en el anterior apartado es necesario aplicar nuevas técnicas para el cálculo de la curvatura. Se ha decidido separar estas tareas del preprocesado de bordes porque son específicos para el cálculo de la curvatura. A continuación se realiza una descripción de cada uno de los bloques que componen el sistema de cálculo de la curvatura de los bordes.

Suavizado gaussiano de los bordes (C1.3.1): en muchas ocasiones los bordes detectados son muy abruptos, de modo que tienden a ofrecer valores de curvatura muy variantes. Para poder realizar un cálculo de la curvatura preciso, es requisito indispensable eliminar esas asperezas de los bordes, de forma que la curvatura obtenida tenga valores mucho más estables. El suavizado gaussiano se ha

realizado mediante una estructura de disco de tamaño 2 y un parámetro de suavizado $\sigma = 5$. El resultado de este proceso puede verse en la figura 4.55, donde la imagen 4.55(a) muestra los bordes preprocesados sin suavizado gaussiano y la figura 4.55(b) muestra el resultado conseguido mediante el suavizado.



(a) (b)

Figura 4.55: Resultado de aplicar un suavizado gaussiano a los bordes. a) Bordes preprocesados sin suavizado gaussiano. b) Bordes preprocesados con suavizado gaussiano.

Puede observarse que los bordes son mucho más suaves, eliminando los contornos agudos. Una vez realizado este proceso se procede a realizar el adelgazamiento de los bordes, el cual se expone a continuación.

Adelgazamiento de los bordes (C1.3.2): para poder realizar un cálculo preciso de la curvatura es necesario que los bordes tengan una anchura máxima de 1 píxel. Esto es debido a que, por un lado se requiere realizar una ordenación de los píxeles del contorno (esta tarea se aborda más adelante) y por otro lado tratar de eliminar píxeles que proporcionan información repetida. Este proceso se realiza mediante una operación morfológica de adelgazamiento repetitiva hasta conseguir bordes con el mínimo grosor posible. La salida de este proceso puede verse en la figura 4.56, donde la imagen 4.56(a) muestra unos bordes gruesos procedentes del

suavizado gaussiano y la imagen 4.56(b) muestra el adelgazamiento sufrido por ellos.



(a) (b)

Figura 4.56: Resultado del adelgazamiento de los bordes. a) Bordes preprocesados con suavizado gaussiano sin adelgazar. b) Bordes preprocesados con suavizado gaussiano adelgazados.

Finalizado el adelgazamiento de los bordes se procede a realizar la eliminación de las ramificaciones. Esta tarea se describe en el siguiente apartado.

Eliminación de ramificaciones (C1.3.3): las ramificaciones en los bordes son aquellos píxeles que están conectados a más de 2 píxeles, formando una bifurcación. Como ya se ha mencionado previamente, se requiere de una ordenación de los puntos que componen un borde para un correcto cálculo de su curvatura, tarea que impiden las ramificaciones. La metodología diseñada para su tratamiento es la siguiente:

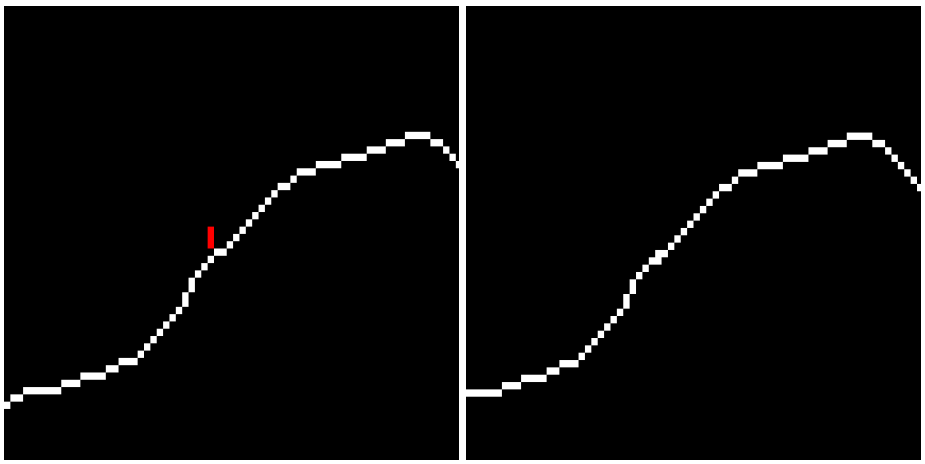
1. Detección de las ramificaciones: aquellos píxeles con una conectividad mayor a 2 son ramificaciones.

2. Resta de los bordes y las ramificaciones: los píxeles detectados en el punto anterior son borrados de la imagen de bordes, de forma que desaparece la bifurcación quedando los bordes separados.

3. Eliminación de la ramificación: los bordes obtenidos mediante la resta del paso 2 que tengan una longitud menor a 10 píxeles son eliminados.

4. Unión de bordes cortados: cuando se haya eliminado una ramificación (paso 3) se realiza la unión de los bordes separados en el punto 2, quedando un borde completo. El píxel que los une será el detectado como ramificación en el paso 1. En caso de que las ramificaciones tengan una longitud mayor a 10 píxeles se dejará unido al contorno inicial aquel que sea más largo.

El resultado de este proceso puede verse en la figura 4.57 donde la imagen 4.57(a) muestra una ramificación y la imagen 4.57(b) la eliminación de la misma.



(a) (b)

Figura 4.57: Resultado de la eliminación de las ramificaciones. a) Borde con una ramificación en color rojo. b) Borde con la ramificación eliminada.

Tras la eliminación de las bifurcaciones se procede a realizar el último paso previo al cálculo de la curvatura, la reordenación de los bordes. Este proceso se describe en el siguiente apartado.

Reordenación de los puntos de los bordes (C1.3.4): el entorno de programación utilizado para el desarrollo de los algoritmos es Matlab. Este software realiza una ordenación automática de los puntos de los bordes en función de su posición

en la imagen, comenzando de Oeste a Este y de Norte a Sur. Esto produce incongruencias que imposibilitan el cálculo de la curvatura, ya que en muchas ocasiones los puntos tratados no son consecutivos. Este efecto se puede ver en la imagen 4.58(a) de la figura 4.58.

Para solucionar esta problemática se ha diseñado un algoritmo que realiza una ordenación consecutiva de los puntos, permitiendo el cálculo de la curvatura. Éste consta de dos pasos:

1. Búsqueda del punto de inicio del borde: el punto de inicio del borde es aquel que tiene una conectividad 1. Esta condición es cumplida por el punto inicial y final, pudiendo ser seleccionado cualquiera de ellos con igual resultado.

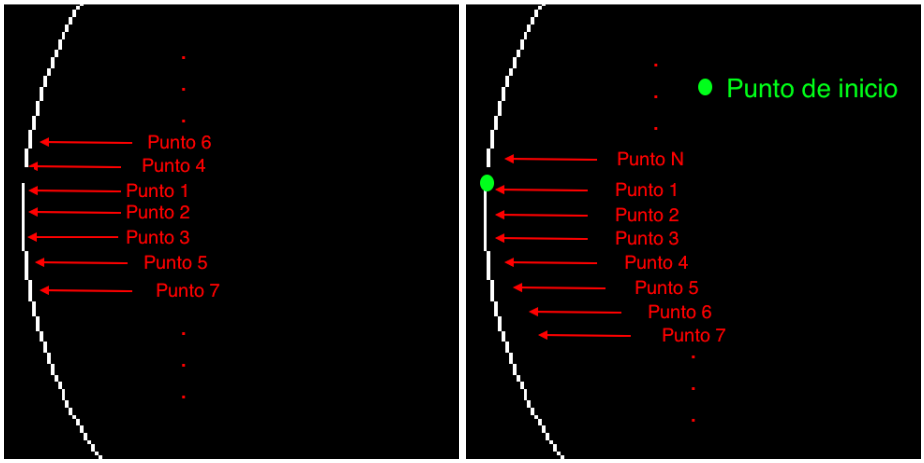
2. Ordenación de los puntos: una vez obtenido un punto de inicio se van ordenando los puntos en función del vecino más cercano. Hay que recordar que los bordes tienen un ancho de 1 píxel y carecen de bifurcaciones.

Mediante este proceso se consigue reordenar los puntos de los bordes para un correcto cálculo de su curvatura. Una descripción gráfica del resultado puede verse en la imagen 4.58(b) de la figura 4.58. Tras este proceso es posible afrontar el cálculo de la curvatura con garantías.

Cálculo de la curvatura (C1.3.5): el cálculo de una curva plana en coordenadas cartesianas (representación de una imagen) está basada en la teoría clásica del triedro de Frenet para una curva plana. Se calcula explícitamente la curvatura de la curva plana en coordenadas cartesianas $y = f(x)$, teniendo en cuenta que su interpretación y fórmula coincide con la de Newton. Éste basaba la definición y cálculo de la curvatura en las siguientes afirmaciones:

- Un círculo tiene una curvatura constante que es inversamente proporcional a su radio.

- El círculo más grande que es tangente a la curva (por su lado cóncavo) en un punto tiene la misma curvatura que la curva en el punto.



(a) (b)

Figura 4.58: Resultado de la reordenación de los puntos. a) Borde con puntos desordenados. b) Borde con puntos ordenados.

De esta forma el centro de este círculo queda definido como la intersección de las rectas normales a la curva en los puntos próximos a ella. Ello permite calcular el centro y radio del círculo, por tanto, el centro y el radio de la curvatura.

Para calcular la curvatura de una curva plana en coordenadas cartesianas es necesario considerar una curva plana parametrizada por su longitud de arco $\sigma(s) = (x(s), y(s)$, definiéndose el vector tangente unitario a la curva en un punto genérico P mediante la ecuación 4.17.

$$\frac{d\sigma}{ds} = (x'(s), y'(s) \tag{4.17}$$

De forma lógica se puede imaginar que la curvatura de la curva es igual a la variación de su vector tangente en su traslación a lo largo de ella, lo que conduce a las siguientes definiciones:

- Es denominado vector de la curva en P al vector definido en la ecuación 4.18.

$$\frac{d^2\sigma}{ds^2} = (x'(s), y'(s) \tag{4.18}$$

- La curvatura K en el punto P queda definida como el módulo del vector de curvatura en P. Esto queda demostrado dado que el vector de curvatura es ortogonal al vector tangente como puede verse a continuación. $d\sigma/ds$ es unitario, derivando en la expresión $(d\sigma/ds) \times (d\sigma/ds) = 1$ se obtiene que $(d^2\sigma/ds^2) \times (d\sigma/ds) = 0$, es decir, ambos vectores son ortogonales.

  A partir de aquí se deduce que $(d^2\sigma/ds^2) =_K N$, siendo N el vector normal unitario en P. Por tanto, el centro de curvatura de la curva en P es el punto C situado sobre la normal en P a una distancia $1/K$ de P, siendo esto $OC = OP + (1/K)N$.

  Además, el círculo de centro C y radio $1/K$ está contenido en el plano osculador π de la curva, que es el plano que pasa por tres puntos próximos de la curva cuando dos de ellos tienden a confundirse con el tercero (P en este caso), esto es $\pi \equiv OX = OP + \langle (d\sigma/ds), (d^2\sigma/ds^2) \rangle$. De esta forma, el centro de curvatura C es el punto de intersección de las rectas normales a la curva en puntos arbitrariamente próximos a ella. Por motivos obvios, el círculo de centro C y radio $1/K$ se llama círculo osculador.

N define la normal principal a la curva y $(d^2\sigma/ds^2) =_K N$ es la primera ecuación de Frenet, que para una curva no necesariamente plana y que en coordenadas arbitrarias se escribe $D^{\bigtriangledown}D =_K N$, siendo D y N los vectores tangente unitario y normal principal y $\bigtriangledown$ la conexión del espacio en el que vive la curva. El plano osculador en un punto viene determinado por los vectores D y N.

En el caso de las coordenadas cartesianas, $D^{\bigtriangledown}D$ consiste en derivar respecto al parámetro s de la curva, pues los coeficientes de la conexión $\bigtriangledown$ en cartesianas son nulos.

Con todo esto, el cálculo de la curvatura de la curva $y = f(x)$ es una parametrización de la curva $\sigma(x) = (x, f(x))$. La métrica sobre la que se describe la curva viene especificada por $ds^2 = dx^2 + f'(x)^2dx^2 = (1 + f'(x)^2)dx^2$, es decir, la diferencia de arco se expresa como $ds = \sqrt{1 + f'(x)^2}dx$.

El vector tangente se define por $(d\sigma/dx) = (1, f'(x))$ y el vector tangente unitario como indica la ecuación 4.19.

$$\frac{d\sigma}{ds} = \frac{1}{\sqrt{1+f'(x)^2}}(1, f'(x)) = ((1+y'^2)^{-1/2}, y'(1+y'^2)^{-1/2}) \tag{4.19}$$

A partir de la anterior ecuación se obtiene la expresión del vector de curvatura definido en la ecuación 4.20.

$$\frac{d^2\sigma}{ds^2} = (\frac{d(1+y'^2)^{-1/2}}{dx}\frac{dx}{ds'}, \frac{d(y'(1+y^2)^{-1/2})}{dx}\frac{dx}{ds'}) = y''(1+y^2)^{-2}(-y', 1) \tag{4.20}$$

A partir de ésta, calculando su módulo se obtiene la expresión de la curvatura especificada por la ecuación 4.21.

$$K = \frac{y''}{(1+y'^2)^{-3/2}} \tag{4.21}$$

En la figura 4.59 se muestra una representación gráfica del cálculo de la curvatura sobre una curva, en la cual los puntos que la componen tienen diferente color en función del valor de ésta.

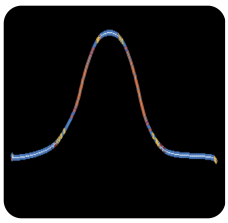


Figura 4.59: Resultado del cálculo de la curvatura.

Extracción de características (C1.4)

La caracterización de las propiedades de los bordes es crucial para la detección de pólipos. Para ello se ha diseñado el sistema combinado que se muestra en la figura 4.60. Esta arquitectura consta de tres bloques: extracción de características de curvatura (C1.4.1), extracción de características de los bordes (C1.4.2) y la combinación de ambos (C1.4.3). Estos son descritos en los siguientes apartados.

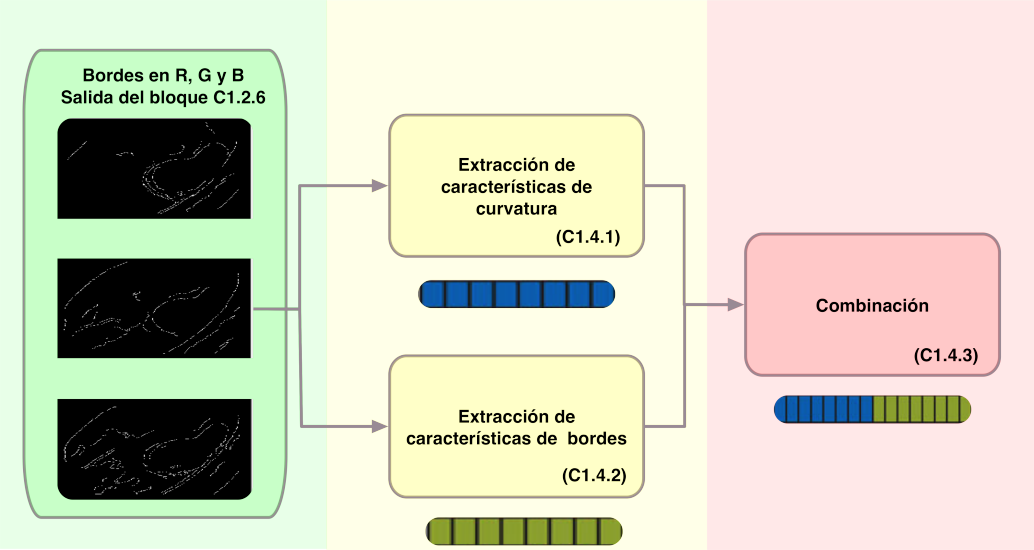


Figura 4.60: Extracción de propiedades de la curvatura y los bordes.

Extracción de características de las curvaturas (C1.4.1): la caracterización de las curvaturas de los bordes se realiza mediante la extracción de descriptores en el dominio frecuencial y temporal. Para ello se ha diseñado el sistema mostrado en la figura 4.61, el cual consta de tres pasos: extracción de características frecuenciales (C1.4.1.1), extracción de características temporales (C1.4.1.2) y la combinación de ambas (C1.4.1.3). Mediante el uso de ambos espacios se logra una extracción de patrones mucho más robusta, lo que deriva en una mejor detección de pólipos. Los valores obtenidos en el cálculo de la curvatura pueden representarse como una señal discreta, ya que por cada punto que compone un borde obtenemos un valor de curvatura, es por ello que se ha realizado este planteamiento.

Para comenzar se realiza la descripción del sistema de extracción de características frecuenciales (C1.4.1.1). En él se extraen las siguientes características:

- Densidad espectral de potencia (PSD): la densidad espectral (DE) de una señal es una función matemática que nos informa de cómo está distribuida la potencia de dicha señal sobre las distintas frecuencias de las que está formada. La definición matemática de la DE es diferente dependiendo de si se trata de señales definidas en energía, en cuyo caso hablamos de densidad espectral de energía (DEE), o en potencia, en cuyo caso hablamos de PSD. Una señal

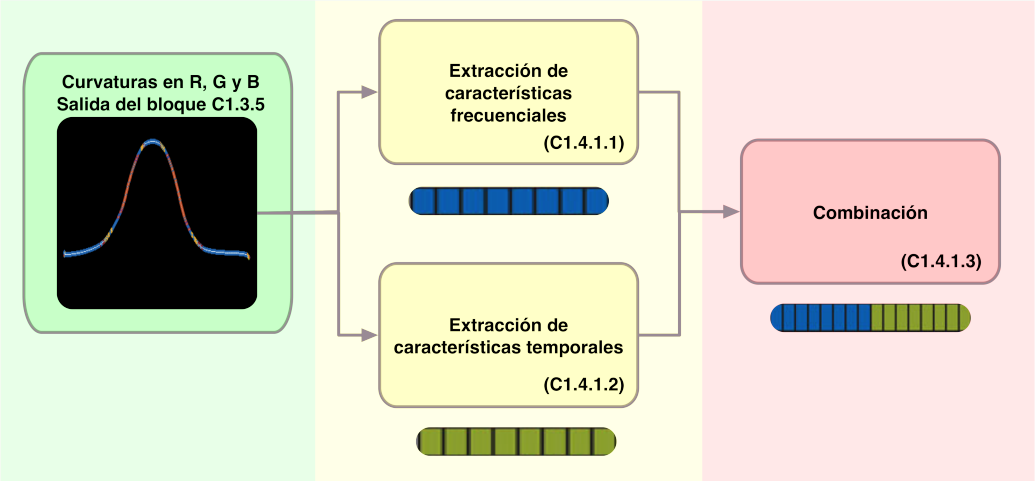


Figura 4.61: Extracción de propiedades de la curvatura.

$x(t)$ está definida en potencia si su potencia media es finita ($0 < P_x < \infty$) y por tanto, su energía media es infinita ($E_x = \infty$). La PSD se calcula usando el teorema de Wiener-Khinchin [Wei06] el cual relaciona la PSD con la transformada de Fourier de la función de autocorrelación definida en la ecuación 4.22 expresada en W/Hz.

$$S_{xx}(f) = TF\{R_{xx}(\tau)\} = \int_{-\infty}^{\infty} R_{xx}(\tau)e^{-2\pi i f r}dr \tag{4.22}$$

Donde TF significa transformada de Fourier y R_{xx} es la función de autocorrelación de $x(t)$. El valor de $S_{xx}(0)$ es la potencia de la componente continua (DC) de la señal. La integral de esta función en todo el eje f es el valor de la potencia total de la señal $x(t)$, siendo ésta expresada por la ecuación 4.23.

$$P = \int_{-\infty}^{\infty} S_{xx}(f)df \tag{4.23}$$

- Media de la frecuencia: se obtiene la transformada rápida de Fourier (FFT) de la señal de la curvatura y se realiza una integración de la misma para calcular la media.

- Mediana de la frecuencia: se obtiene la FFT de la señal de la curvatura y se realiza una integración de la misma para calcular la mediana.

- Medida de ancho de banda ocupado (OBM): es la banda de frecuencias que comprende toda frecuencia discreta a la que corresponde por lo menos el 0.5 % de la potencia media total emitida.

- Potencia del ancho de banda (BP): para su cómputo, en primer lugar se calcula el espectro de potencia utilizando un periodograma y una ventana de tipo kaiser. A continuación, se calcula un nivel de referencia como el nivel de potencia máximo del espectro de potencia. El ancho de banda se calcula a partir de las intersecciones de frecuencias en las que el espectro cae por debajo del nivel de referencia por 3 dB o se encuentra con el extremo del espectro.

- Rango dinámico libre de espurios (SFDR): es una especificación de suma importancia que permite caracterizar el desempeño dinámico de un generador de señales. El SFDR describe la relación entre la amplitud de la frecuencia fundamental generada y la amplitud de la armónica más prominente. En un mundo ideal, en el dominio de la frecuencia de una señal analógica pura, toda la potencia está concentrada en la frecuencia deseada. Sin embargo, debido al ruido y la no linealidad de los componentes, incluso el mejor generador de señales también genera componentes armónicas (o múltiplos) del tono deseado. Para medir el SFDR de una señal se genera un tono a una frecuencia dada. Posteriormente se utiliza un analizador de espectros para medir la amplitud del tono fundamental y la amplitud del siguiente tono mayor. Típicamente, la espuria corresponde a una de las armónicas. El cálculo del SFDR se realiza mediante la ecuación 4.24.

$$SFDR = \frac{Amplidud\ fundamental\ (sB)}{Amplitud\ espuria\ máxima(sB)} \tag{4.24}$$

- Relación señal a ruido (SNR): se define como la proporción existente entre la potencia de la señal que se transmite y la potencia del ruido que la corrompe.

Este margen es medido en decibelios. El rango dinámico y SNR pueden utilizarse como sinónimos para referirse a este margen que hay entre el ruido de fondo y el nivel de referencia. No ocurre lo mismo cuando el rango dinámico indica la distancia entre el nivel de pico y el ruido de fondo.

- Relación señal a ruido y distorsión (SINAD): es un parámetro que mide la calidad de la señal frente a perturbaciones como el ruido y la distorsión. SINAD es un acrónimo que viene del inglés y significa *signal-to-noise and distortion ratio*, considerándose S como la potencia de la señal, N la del ruido y D la de las distorsiones. Todas las potencias deben ser manejadas en unidades naturales, nunca en logarítmicas, ya que el cálculo sería incorrecto. La SINAD es definida por la ecuación 4.25.

$$SINAD = \frac{S + N + D}{N + D} \tag{4.25}$$

- Distorsión armónica total (THD): es la relación entre el contenido armónico de la señal y la primera armónica o fundamental. Su valor se ubica entre el $0\,\%$ e ∞. Es el parámetro de medición de distorsión más conocido, por lo que es recomendable para medir la distorsión en parámetros individuales. Su cálculo se realiza mediante la ecuación 4.26.

$$THD = \frac{\sqrt{\sum_{2}^{n} V_n^2}}{V_1} \tag{4.26}$$

Donde V_n es el voltaje del enésimo armónico y $n = 1$ es la frecuencia fundamental.

- Análisis wavelet: la transformada wavelet genera bloques de información en escala y tiempo de una señal. Estos bloques se generan desde una única función fija llamada wavelet madre $\Psi(t)$, como se define en la ecuación 4.27 mediante operaciones de traslación y dilatación.

$$\Psi_{a,b} = \frac{w(\frac{x-b}{a})}{\sqrt{|a|}}; a, b \in \Re, a \neq 0 \tag{4.27}$$

Donde a y b son números reales del conjunto $\Re$, a permite hacer las dilataciones y contracciones de la señal y b permite cambiar la posición de la señal en el tiempo. Cuando la variable a es igual a 0 la señal se indetermina. El proceso de transformación wavelet de una señal se llama análisis y el proceso inverso para reconstruir la señal se llama síntesis. Este análisis genera diferentes subbandas, por lo que distintos niveles de descomposición se pueden generar de acuerdo a las necesidades de la aplicación. Dichas subbandas en el plano de la frecuencia no son uniformes y se encuentran divididas de forma logarítmica. En donde para un rango de $[0 - fn]$ las muestras de una señal son la mitad para cada nivel de escalamiento. Se ha decidido realizar una descomposición de 10 niveles mediante la wavelet madre Daubechies, obteniéndose para cada uno de ellos su energía, varianza y desviación estándar como rasgos característicos.

- Centroide espectral: es una medida utilizada en el procesamiento de señales digitales para caracterizar un espectro. Indica el centro de gravedad del espectro. Se calcula como la media ponderada de las frecuencias presentes en la señal, utilizando para ello la transformada de Fourier. La ecuación 4.28 muestra su formulación matemática.

$$Centroide\ de\ gravedad = \frac{\sum_{n=0}^{N-1} f\,(n)\,x\,(n)}{\sum_{n=0}^{N-1} x\,(n)} \tag{4.28}$$

  Donde $x(n)$ representa el valor ponderado de la frecuencia en el intervalo n, y $f(n)$ representa la frecuencia central del mismo.

- Flujo espectral: es una medida de la rapidez con la que el espectro de potencia de una señal está cambiando. Se calcula comparando el espectro de potencia para una ventana de señal con el espectro de potencia de la ventana anterior. De forma general se calcula como la distancia euclidiana entre los dos espectros normalizados. De esta forma el flujo del espectro no depende de la potencia total ni de consideraciones de fase.

- Ancho de banda de ruido equivalente (ENBW): dado un sistema con una función de transferencia $H(s)$, el espectro de cualquier ruido de entrada será

modelado por ella. Bajo la existencia de ruido blanco es conveniente reemplazar la función de transferencia por un filtro de tipo *brickwall* en el que la potencia del ruido deberá ser igual a cierta frecuencia δf que tras ser filtrada pasa a ser 0. Esa frecuencia es definida de tal manera que la potencia total de salida del ruido es igual para el filtro y el sistema, por lo tanto, el área bajo este rectángulo debe ser la igual que el área bajo la $H(s2)$ original del sistema.

Para continuar, se procede con la descripción de la extracción de características temporales (C1.4.1.2) propuesta. Éstas son las siguientes:

- Sumatorio de la curvatura: se realiza el cálculo del sumatorio de los valores de la curvatura obtenidos para cada punto que compone un borde.
- Valor medio de la curvatura: se calcula el valor medio de la curvatura de los valores obtenidos para cada punto que compone un borde.
- Valor mediano de la curvatura: la mediana es el valor que ocupa el lugar central de todos los datos cuando estos están ordenados de menor a mayor.
- Desviación estándar de la curvatura: es una medida del grado de dispersión de los datos respecto al valor promedio.
- Asimetría: es la medida que indica la simetría de la distribución de una variable respecto a la media aritmética sin necesidad de hacer la representación gráfica. Los coeficientes de asimetría indican si hay el mismo número de elementos a la izquierda y derecha de la media. Existen tres tipos de curva de distribución según su asimetría:
  - Asimetría negativa: la cola de la distribución se alarga para valores inferiores a la media.
  - Simétrica: hay el mismo número de elementos a la izquierda y derecha de la media. En este caso, coinciden la media, mediana y moda. La distribución se adapta a la forma de la campana de Gauss o distribución normal.

  - Asimetría positiva: la cola de la distribución se alarga para los valores superiores a la media. El cálculo de la asimetría se ha realizado mediante el coeficiente de Fisher (CA_F) que evalúa la proximidad de los datos a su media $\bar{x}$. Cuanto mayor sea la suma $\sum(x_i - \bar{x})^3$ mayor será la asimetría. Sea el conjunto $X = (x1, x2, \ldots, xN)$ la simetría de Fisher viene definida en la ecuación 4.29.

$$CA_F = \frac{\sum_{i=1}^{N}((x_i - \bar{x})^3}{N_s^3} \tag{4.29}$$

    Donde $\bar{x}$ es la media y s la desviación típica. Los valores de CA_F quedan clasificados de la siguiente forma:

    Si $CA_F < 0$: la distribución tiene una asimetría negativa y se alarga a valores menores que la media.

    Si $CA_F = 0$: la distribución es simétrica.

    Si $CA_F > 0$: la distribución tiene una asimetría positiva y se alarga a valores mayores que la media.

- Curtosis: mide cómo de escarpada o achatada está una curva o distribución. Este coeficiente indica la cantidad de datos que hay cercanos a la media, de manera que a mayor grado de curtosis más escarpada será la forma de la curva. La curtosis se mide promediando la cuarta potencia de la diferencia entre cada elemento del conjunto y la media, dividido entre la desviación típica elevada también a la cuarta potencia. Sea el conjunto $X = (x1, x2, \ldots, xN)$, el coeficiente de curtosis viene definido por la ecuación 4.30.

$$Curtosis = \frac{\sum_{i=1}^{N}(x_i) - \bar{x}^4}{N_s^4} - 3 \tag{4.30}$$

  Donde $\bar{x}$ es la media y s la desviación típica.

- Valores máximo y mínimo de la curvatura: representan el máximo y mínimo valor de la curvatura calculada.

- Número de cruces por cero: los cruces por cero de los valores de la curvatura son un rasgo característico muy relevante. Esto se debe a que los cambios

de signo determinan una variación en la curvatura, pasando de cóncava a convexa o viceversa.

- Entropía: es considerada como una medida de la incertidumbre y de la información necesaria para, en cualquier proceso, poder acotar, reducir o eliminar la incertidumbre.

Una vez extraídas las características en el dominio frecuencial y temporal, es necesario realizar la combinación (C1.4.1.3) de las mismas. Las propiedades del dominio frecuencial dan como resultado un vector de características, al igual que ocurre con las propiedades temporales. La combinación de ambas se realiza mediante la concatenación de ambos vectores como puede verse en la figura 4.61.

Extracción de características de los bordes (C1.4.2): continuando con la extracción de características, en este apartado se aborda la caracterización de los bordes detectados en las imágenes. Se trata de un complemento a la caracterización de la curvatura descrita previamente. Para ello se ha diseñado el sistema mostrado en la figura 4.62, el cual consta de tres pasos: extracción de características de color (C1.4.2.1), extracción de características de forma (C1.4.2.2) y la combinación de ambas (C1.4.2.3). A continuación se realiza una descripción de cada uno de los pasos.

La extracción de características de color (C1.4.2.1) se realiza sobre la figura envolvente del borde en escala de grises, ya que un contorno como tal no dispone de propiedad de color alguna. Para ello se han utilizado los siguientes descriptores:

- Intensidad media: determina el valor de intensidad medio de la región que envuelve al borde.

- Intensidad máxima: determina el valor de intensidad máximo de la región que envuelve al borde.

- Intensidad mínima: determina el valor de intensidad mínimo de la región que envuelve al borde.

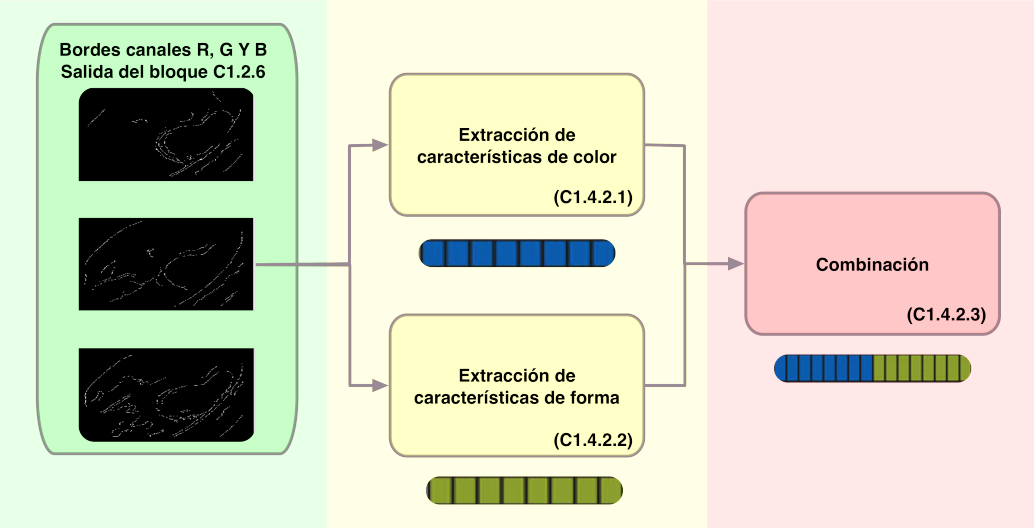


Figura 4.62: Extracción de propiedades de los bordes.

En cuanto a la extracción de características de forma (C1.4.2.2) se pretende caracterizar la morfología de los bordes, ya que es uno de los principales rasgos a la hora de diferenciar los tipos de bordes. Estos descriptores se obtienen de la figura envolvente del borde. Para ello se han utilizado los siguientes descriptores:

- Área: viene determinado por el número de píxeles que componen la figura envolvente del borde.
- Eje mayor: se trata del eje mayor de la figura envolvente del borde.
- Eje menor: se trata del eje menor de la figura envolvente del borde.
- Excentricidad: este descriptor ha sido definido en el módulo ≪Eliminación de bordes rectos (C1.2.2)≫ y sirve para ver cómo de curvo es un borde, teniendo valor 1 para líneas rectas y valor 0 para círculos perfectos.
- Solidez: es la relación entre los píxeles de la figura envolvente y los que pertenecen al propio borde.
- Perímetro: determina la longitud del borde y es igual a la suma de la cantidad de puntos del mismo.

Por último, tras extraer las propiedades de color y forma es necesaria la combinación (C1.4.2.3) de las mismas. La combinación de ambas se realiza mediante la concatenación de ambos vectores como puede verse en la figura 4.62.

Combinación de la extracción de características de curvatura y bordes (C1.4.3): tanto la extracción de características de la curvatura como la de propiedades de los bordes generan sendos vectores con los descriptores calculados. La combinación se realiza mediante la concatenación y normalización de ambos.

Reducción de características (C1.5)

El proceso de selección de las características más relevantes se realiza mediante el sistema diseñado en el módulo B3.5. El conjunto de características de entrada está compuesto por propiedades de las curvaturas y de los bordes. Tras la reducción de las mismas se obtiene un subconjunto con mayor potencial discriminante que hace ser más efectivos a los algoritmos de detección automática de pólipos diseñados.

Todos los datos extraídos en este proceso serán tratados en los apartados 5.2.2.1 ≪Análisis de la precisión de la clasificación mediante características de los bordes (R4)≫ y 5.2.2.4 ≪Análisis de la precisión de la clasificación de las características de la textura (R7)≫ del capítulo 5 ≪Resultados≫.

Clasificación (C1.6)

Ejecutada la reducción de características se procede a realizar un entrenamiento del clasificador seleccionado y la clasificación de las mismas. Mediante este proceso se permitirá detectar aquellos bordes pertenecientes a los pólipos haciendo posible su detección automática. El sistema diseñado para la clasificación (véase figura 4.63) consta de cuatro bloques: conjunto de datos de entrenamiento (1), conjunto de datos de prueba (2), entrenamiento del clasificador (3) y clasificación (4). A continuación se realiza una descripción de cada uno de ellos.

1. Conjunto de datos de entrenamiento: para poder hacer uso de clasificadores supervisados es necesario disponer de datos de entrenamiento. Este conjunto de datos se obtiene mediante validación cruzada (se explica en el siguiente

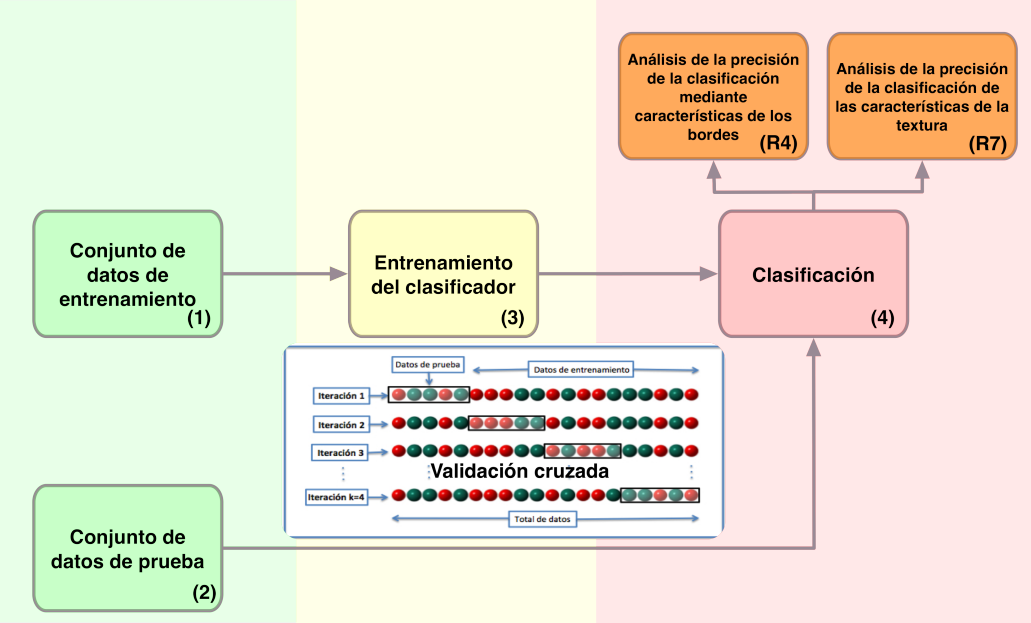


Figura 4.63: Metodología empleada para realizar la clasificación de los datos.

apartado). Como es lógico se requiere conocer la clase a la que pertenecen los datos para poder realizar el entrenamiento del clasificador.

2. Conjunto de datos de prueba: es utilizado para evaluar la eficacia del clasificador una vez realizado su entrenamiento haciendo uso del conjunto de datos de entrenamiento. Al igual que en el caso anterior, este conjunto de datos se obtiene mediante validación cruzada.

3. Entrenamiento del clasificador: se debe seleccionar una técnica de clasificación supervisada para poder realizar la clasificación de los datos. El entrenamiento del mismo se realiza mediante los datos del conjunto de entrenamiento. Con ello se consigue ajustar el clasificador proporcionándole la capacidad discriminante. En esta investigación se han probado múltiples clasificadores con el objetivo de encontrar aquel que se ajuste mejor a la problemática tratada.

4. Clasificación: mediante la clasificación o prueba del clasificador se comprueba la eficacia del sistema. Para realizar la clasificación se ha optado por usar

una validación cruzada de diez iteraciones. Toda la información sobre la prueba del sistema de clasificación se proporciona en los apartados 5.2.2.1 ≪Análisis de la precisión de la clasificación mediante características de los bordes (R4)≫ y 5.2.2.4 ≪Análisis de la precisión de la clasificación de las características de la textura (R7)≫ del capítulo 5 ≪Resultados≫, donde se muestran las siguientes métricas: porcentaje de instancias clasificadas correctamente, el estadístico Kappa, EAM, precisión, sensibilidad, valor-F y área ROC.

Validación cruzada: la validación cruzada es una técnica empleada para evaluar los resultados de un análisis estadístico y garantizar de esta forma que son independientes de la partición entre los datos de entrenamiento y prueba. Consiste en el calculo repetitivo de la media aritmética obtenida de las medidas de evaluación sobre las diferentes particiones. Es utilizada en entornos donde se busca una predicción y que además se quiera estimar cómo de preciso es un modelo que se llevará a la práctica. Esta técnica es muy utilizada en IA para validar modelos generados.

La validación cruzada proviene de la mejora del método de retención. Éste consiste en fraccionar en dos grupos complementarios los datos de muestra, realizar el análisis de un subconjunto (datos de entrenamiento) y validar el análisis en el otro subconjunto (datos de prueba), de forma que la función de aproximación sólo se ajusta con el conjunto de datos de entrenamiento y a partir de aquí calcula los valores de salida para el conjunto de datos de prueba (datos no utilizados antes). La principal ventaja de este método es su rapidez de ejecución, sin embargo, no es demasiado preciso debido a la variación de los resultados obtenidos para diferentes datos de entrenamiento. La evaluación puede depender en gran medida de cómo es la división entre los datos de entrenamiento y de prueba, y por lo tanto puede ser significativamente diferente en función de cómo se realice esta división. Debido a estas carencias aparece el concepto de validación cruzada.

Suponiendo que se dispone de un modelo con uno o más parámetros de ajuste desconocidos y unos datos de entrenamiento que queremos analizar, el proceso de ajuste optimiza los parámetros del modelo para que éste se ajuste a los datos de entrenamiento tan bien como pueda. Si cogemos una muestra independiente como dato de prueba (validación) del mismo grupo que los datos de entrenamiento,

normalmente el modelo no se ajustará a los datos de prueba igual de bien que a los datos de entrenamiento. Esto se denomina sobreajuste y acostumbra a pasar cuando el tamaño de los datos de entrenamiento es pequeño o cuando el número de parámetros del modelo es grande. La validación cruzada es una manera de predecir el ajuste de un modelo a un hipotético conjunto de datos de prueba cuando no disponemos del conjunto explícito de datos de prueba.

En la validación cruzada de K iteraciones (10 en el sistema propuesto) los datos de muestra se dividen en K subconjuntos. Uno de los subconjuntos se utiliza como datos de prueba y el resto $(K - 1)$ como datos de entrenamiento. El proceso de validación cruzada es repetido durante k iteraciones, con cada uno de los posibles subconjuntos de datos de prueba. Para finalizar, se realiza la media aritmética de los resultados de cada iteración para obtener un único resultado. Este método es muy preciso puesto que evaluamos a partir de K combinaciones de datos de entrenamiento y de prueba, pero aun así tiene una desventaja, y es que, a diferencia del método de retención, es lento desde el punto de vista computacional. En la práctica, la elección del número de iteraciones depende de la medida del conjunto de datos. En el centro de la figura 4.63 puede verse una representación gráfica del proceso de validación cruzada.

Sistema de análisis de la precisión de la clasificación mediante características de los bordes (R4)

Mediante el proceso de evaluación de la precisión de la clasificación se realiza una validación de las características extraídas de la curvatura y los bordes. Éste permite garantizar que los descriptores son eficaces a la hora de realizar una clasificación de los bordes, detectando aquellos pertenecientes a los pólipos. Con ello se verifica que sea posible una detección automática de pólipos mediante el análisis de las propiedades de los bordes propuesto. En caso de no poderse realizar una clasificación precisa, el método diseñado no sería útil ya que la metodología en la que se basa no es válida. Es preciso aclarar que la evaluación de la precisión de la clasificación se realiza sobre las propiedades extraídas de las imágenes pertenecientes a la base de datos secundaria *CVC Colon Database*. Este proceso se ha realizado mediante el software WEKA constando de varios pasos que se describen continuación:

1. Elección de los clasificadores a utilizar en la evaluación: se seleccionan diversos clasificadores para realizar la clasificación y evaluación de los datos.

2. Elección de los métodos de reducción de características: es necesario tener el conjunto de características original y el reducido mediante las técnicas seleccionadas, siguiendo el proceso descrito en el apartado ≪Reducción de características (B3.5)≫.

3. Realización de las clasificaciones: se realizarán las clasificaciones correspondientes (siguiendo el proceso descrito en el módulo C1.6) mediante los diferentes clasificadores elegidos y utilizando los conjuntos de características originales y los respectivos reducidos por las técnicas de reducción elegidas en el paso 2.

4. Comparación de las tasas de acierto: una vez realizadas las clasificaciones descritas en el paso 3, se obtienen las métricas de evaluación de la calidad de clasificación para los diferentes clasificadores (precisión, sensibilidad, área ROC, porcentaje de instancias clasificadas correctamente, estadístico Kappa, EAM y valor-F. Estos se describen a continuación) y los diferentes conjuntos de características (conjunto original y reducidos), de forma que se permite determinar el clasificador y la técnica de reducción más apropiada.

Para poder realizar una buena interpretación de los resultados se realiza una breve descripción de los indicadores de precisión utilizados en la evaluación:

- Precisión: también conocido como valor predictivo positivo (VPP), denota la proporción de casos verdaderamente positivos entre los casos positivos detectados por la clasificación. Su cálculo se realiza mediante la ecuación 4.31. Es un valor fundamental que depende de la prevalencia, un índice que es independiente de la calidad de la clasificación.

$$Precisión = \frac{VP}{(VP + FP)} \tag{4.31}$$

  De aquí en adelante VP se corresponderá con los verdaderos positivos y FP con los falsos positivos.

- Sensibilidad: también conocida como exhaustividad o *recall*, nos indica la capacidad de nuestro clasificador para dar como casos positivos los casos realmente positivos. Es decir, la sensibilidad caracteriza la capacidad de la prueba para detectar la enfermedad en sujetos enfermos. Su cálculo se realiza mediante la ecuación 4.32.

$$Sensibilidad = \frac{VP}{(VP + FN)} \tag{4.32}$$

  De aquí en adelante FN se corresponderá con los falsos negativos.

- Área ROC: una curva ROC es una representación gráfica de la sensibilidad frente a la especificidad para un sistema clasificador binario según se varía el umbral de discriminación. Se trata del ratio de verdaderos positivos (RVP) frente al ratio de falsos positivos (RFP) también según se varía el umbral de discriminación (valor a partir del cual decidimos que un caso es un positivo). ROC también puede significar característica operativa relativa porque es una comparación de dos características operativas (RVP y RFP) según cambiamos el umbral para la decisión. El análisis de la curva ROC proporciona herramientas para seleccionar los modelos posiblemente óptimos y descartar modelos subóptimos independientemente del coste de la distribución de las dos clases sobre las que se decide. El análisis ROC se relaciona de forma directa y natural con el análisis de coste/beneficio en la toma de decisiones diagnósticas. Para la elección entre dos pruebas diagnósticas distintas se recurre a las curvas ROC ya que es una medida global e independiente del punto de corte. Por esto, en el ámbito sanitario, las curvas ROC también se denominan curvas de rendimiento diagnóstico. La elección se realiza mediante la comparación del área bajo la curva (ABC) de ambas pruebas. Este área posee un valor comprendido entre 0.5 y 1, donde 1 representa un valor diagnóstico perfecto y 0.5 es una prueba sin capacidad discriminatoria diagnóstica.

- Porcentaje de instancias clasificadas correctamente: se trata del ratio entre el número de instancias clasificadas correctamente y el total de instancias.

- Estadístico Kappa (K): es una medida estadística que ajusta el efecto del azar en la proporción de la concordancia observada para elementos cualitativos (variables categóricas). En general se cree que es una medida más robusta que el simple cálculo del porcentaje de concordancia, ya que K tiene en cuenta el acuerdo que ocurre por azar. El cálculo K se realiza mediante la ecuación 4.33.

$$K = \frac{Pr(a) - Pr(e)}{1 - Pr(e)} \tag{4.33}$$

  Donde $Pr(a)$ es el acuerdo relativo observado entre los observadores, $Pr(e)$ es la probabilidad hipotética de acuerdo por azar utilizando los datos observados para calcular las probabilidades de que cada observador clasifique de forma aleatoria cada categoría. Si los evaluadores están completamente de acuerdo, entonces $K = 1$. Si no hay acuerdo entre los calificadores distinto al que cabría esperar por azar, $K = 0$.

- EAM: es el indicador usado para medir cómo de similares son dos muestras independientes. Su cálculo se realiza mediante la ecuación 4.34.

$$EAM = \frac{1}{n} \sum_{i=1}^{n} |f_i - y_i| \tag{4.34}$$

  Donde n representa el total de datos, f_i el valor de la muestra número i del primer grupo e y_i el valor de la muestra i del segundo grupo.

- Valor-F: en estadística es la medida de precisión que tiene un test. Se emplea en la determinación de un valor único ponderado de la precisión y la exhaustividad. Se suele emplear en la fase de pruebas de algoritmos de búsqueda, recuperación y clasificación de datos. El valor-F se considera como una media armónica que combina los valores de la precisión y de la exhaustividad. Su cálculo se lleva a cabo mediante la ecuación 4.35.

$$F = 2\frac{Precisión \cdot Exhaustividad}{Precisión + Exhaustividad} \tag{4.35}$$

Mediante los indicadores de evaluación de la eficacia de la clasificación propuestos se permitirá extraer las siguientes conclusiones:

1. Comprobar si el método de detección de pólipos mediante el análisis de las propiedades de las curvaturas y de los bordes es efectivo y en qué medida.
2. Se determina el clasificador y método de reducción de características que mejor se ajusta a la problemática tratada.

Este primer sistema de evaluación, como puede apreciarse, es crucial para poder validar el método de detección automática de pólipos, ya que será quien determine si es posible discriminar entre bordes pertenecientes a los pólipos y otros contornos de la imagen. Este mismo procedimiento será utilizado en el sistema de análisis de la precisión de la clasificación de las características de la textura (R7). Todos los datos y descripciones detalladas sobre esta evaluación pueden verse en el apartado 5.2.2.1 ≪Análisis de la precisión de la clasificación mediante características de los bordes (R4)≫ perteneciente al capítulo 5 ≪Resultados≫.

Determinación del área del pólipo (C1.7)

La detección de bordes pertenecientes a los pólipos no es suficiente, ha de determinarse el área que delimitan para poder definir el contorno de la lesión detectada. Para llevar a cabo esta tarea se ha diseñado un sistema compuesto de cuatro pasos (véase figura 4.64): bordes detectados como pólipos (C1.7.1), detección de puntos de inicio y final (C1.7.2), unión de extremos (C1.7.3) y creación del área del pólipo (C1.7.4). A continuación se realiza una descripción detallada de cada uno de ellos.

Bordes detectados como pólipos (C1.7.1): el proceso de determinación del área del pólipo tiene como entrada aquellos contornos pertenecientes al mismo. A partir de ellos se tratará de segmentar de la forma más precisa la lesión localizada.

Detección de puntos de inicio y final (C1.7.2): tras la clasificación de los bordes identificados como pertenecientes a los pólipos, el primer paso a realizar es detectar los puntos de inicio y final de cada uno de ellos. Ambos puntos cumplen una condición, tienen conectividad uno, es decir, solo están conectados con un píxel vecino, por lo que su identificación es tarea sencilla.

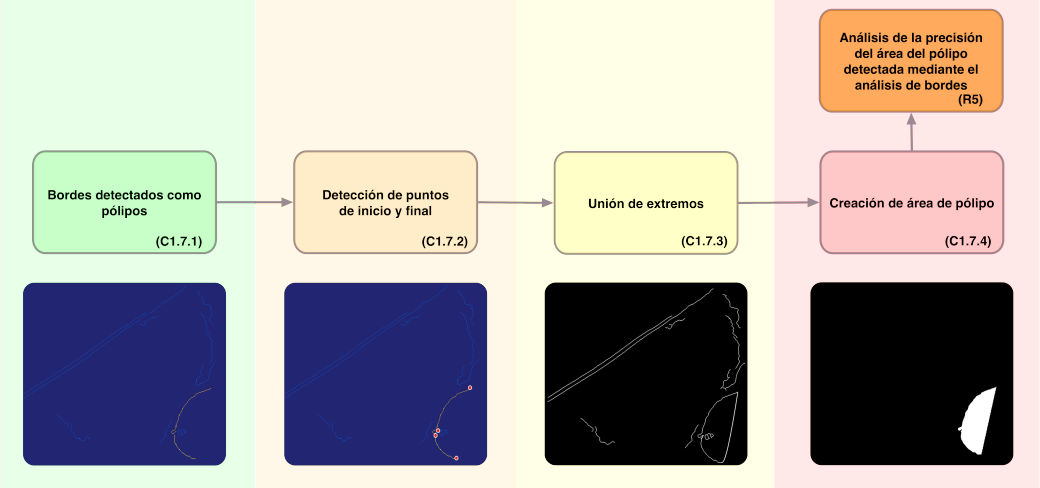


Figura 4.64: Determinación del área del pólipo.

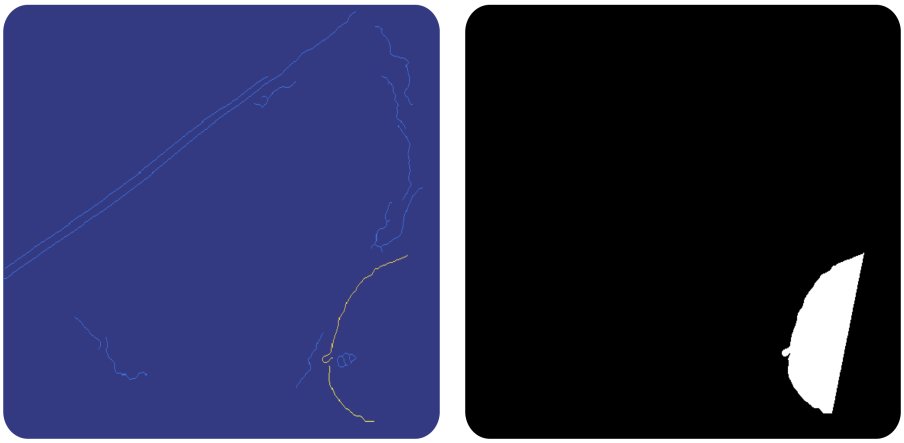
Unión de extremos (C1.7.3): habiéndose obtenido los puntos de inicio y final de los bordes se procede a realizar la unión de los mismos. Hay que tener en cuenta que pueden existir varios bordes pertenecientes a un pólipo en una misma imagen, por lo que este proceso se divide en dos alternativas:

- Detectado un único borde perteneciente al pólipo en la imagen: se trata de la situación más sencilla para determinar el área del pólipo. Existiendo un solo borde del pólipo se realiza la unión de los puntos inicial y final del mismo, quedando delimitada el área del pólipo. La unión de los puntos se realiza mediante el siguiente proceso: teniendo los puntos $A(x_A, y_A)$ y $B(x_B, y_B)$, las coordenadas de los puntos (x e y) de la línea que los une $\overline{AB}$, siendo la pendiente de la recta $m_{\overline{AB}} = (y_B - y_A)/(x_B - x_A)$, las coordenadas de x e y vienen determinadas por las ecuaciones $x = ((y - y_A)/(m_{\overline{AB}})) + x_A$ e $y = m_{\overline{AB}}(x - x_A) + y_A$.

- Detectados varios bordes pertenecientes al pólipo en la imagen: cuando se dispone de más de un borde, el proceso de unión de los mismos tiene mayor complicación. En primer lugar han de calcularse las distancias entre todos los puntos de inicio y final de los bordes detectados. Una vez realizado esto hay dos posibles situaciones:

- La menor distancia entre dos puntos (inicio o final) es menor a 300 píxeles: en este caso los bordes se van uniendo de forma iterativa en función de la distancia mínima entre ellos hasta que todos los puntos estén unidos generando una figura cerrada.
- La menor distancia entre dos puntos (inicio o final) es mayor a 300 píxeles: quiere decir que existe más de una lesión en la imagen debiéndose generar varios contornos cerrados. El proceso de unión sigue el mismo proceso que en el caso anterior pero generando regiones independientes.

Creación del área del pólipo (C1.7.4): como resultado del proceso de unión de los bordes se obtiene una máscara que proporciona la localización del pólipo detectado definiendo su extensión. Es igual de importante la detección del pólipo como la determinación de su extensión, ya que en muchas ocasiones debido a la similitud de los tejidos es una tarea compleja. En la figura 4.65 se muestra el resultado del proceso de unión propuesto, mostrándose en la imagen 4.65(a) los bordes detectados y en la imagen 4.65(b) la máscara obtenida de su unión.



(a) (b)

Figura 4.65: Resultado de la creación del área del pólipo. a) Bordes detectados como pertenecientes al pólipo en rojo. b) Máscara con el área del pólipo generada.

Una vez definido el proceso de generación del área del pólipo detectada, es necesario evaluar su eficacia para poder validarlo. Para ello se ha diseñado el sistema de evaluación de la precisión del área del pólipo detectada mediante el análisis de los bordes. Éste se describe en el siguiente apartado.

Sistema de análisis de la precisión del área del pólipo detectada mediante el análisis de bordes (R5)

Una vez que se ha descrito la metodología propuesta para determinar el área del pólipo detectado, es de gran necesidad evaluar su precisión. Las imágenes colonoscópicas utilizadas para realizar la detección de pólipos son pertenecientes a la base de datos *CVC Colon Database* la cual también proporciona las máscaras con la ubicación exacta de los pólipos (véase figura 3.3). Éstas han sido creadas por especialistas, de forma que serán tomadas como una detección perfecta de la posición y extensión del pólipo. Mediante la comparación de las áreas de los pólipos detectadas y las reales se pretende evaluar el método diseñado.

La evaluación de la precisión de las segmentaciones de pólipos obtenidas mediante el análisis de los bordes se realizará mediante los siguientes índices: cobertura de área anotada (CAA), coeficiente Dice (CD), exactitud, precisión (descrita previamente), sensibilidad (descrita previamente) y especificidad. Estos se describen a continuación:

- CAA: es una métrica para la evaluación de la precisión de segmentaciones. Se trata de la proporción del área real del pólipo (máscara proporcionada por *CVC Colon Database*) cubierta mediante la segmentación obtenida por el método propuesto. Su cálculo se realiza mediante la ecuación 4.36.

$$CAA = 100\frac{D \cap R}{R} \tag{4.36}$$

  Donde D representa al área detectada y R al área real del pólipo.

- CD: el coeficiente Dice al igual que el CAA es una métrica para la evaluación de la calidad de las segmentaciones. En este caso determina como son de similares dos segmentaciones diferentes. Su cálculo es realizado mediante la ecuación 4.37.

$$CD = 100\frac{2 \cdot VP}{(FP + 2 \cdot VP + FN)} \tag{4.37}$$

- Exactitud: se refiere a cómo de cerca del valor real se encuentra el valor medido. En términos estadísticos, la exactitud está relacionada con el sesgo de una estimación. Cuanto menor es el sesgo más exacta es una estimación. Cuando se expresa la exactitud de un resultado, se expresa mediante el error absoluto que es la diferencia entre el valor experimental y el valor verdadero. La ecuación 4.38 representa su formulación matemática.

$$Exactitud = \frac{(VP + VN)}{(VP + VN + FP + FN)} \tag{4.38}$$

  De aquí en adelante VN representa a los verdaderos negativos.

- Especificidad: indica la capacidad de un estimador para dar como casos negativos los casos realmente sanos, es decir, la proporción de sanos correctamente identificados. La especificidad caracteriza la capacidad de la prueba para detectar la ausencia de la enfermedad en sujetos sanos. Su cálculo se realiza mediante la ecuación 4.39.

$$Especificidad = \frac{VN}{(VN + FP)} \tag{4.39}$$

Este segundo sistema de evaluación permite cuantificar cómo de precisa es el área del pólipo determinada por nuestro sistema mediante el uso de métricas objetivas. Este mismo procedimiento será utilizado en el sistema de análisis de la precisión del área del pólipo detectada mediante el análisis de la textura (R8). Todos los datos y descripciones detalladas sobre esta evaluación pueden verse en el apartado 5.2.2.2 ≪Análisis de la precisión del área del pólipo detectada mediante el análisis de bordes (R5)≫ del capítulo 5 ≪Resultados≫.

Sistema de análisis de la precisión de la detección de pólipos mediante el análisis de bordes (R6)

Por último y en tercer lugar, una vez descritas las evaluaciones de la precisión de la clasificación y del área del pólipo detectada, se realiza una evaluación de la eficacia de la detección de pólipos mediante el análisis de los bordes, que no es más que una valoración global de la técnica diseñada. Este método está basado en diferentes propiedades de los bordes, los cuales no siempre son detectados por los algoritmos. En muchas ocasiones no son hallados por la presencia de ruido, baja calidad de la imagen o bajo contraste, por lo que es necesario evaluar este aspecto. Para ello se plantea el cálculo del porcentaje de imágenes de la base de datos *CVC Colon Database* en las que se ha conseguido detectar pólipos mediante el presente análisis. Todos los datos y descripciones detalladas sobre esta evaluación pueden verse en el apartado 5.2.2.3 ≪Análisis de la precisión de la detección de pólipos mediante el análisis de bordes (R6)≫ perteneciente al capítulo 5 ≪Resultados≫.

4.2.3.2 Detección automática de pólipos mediante el análisis de la textura (C2)

El segundo de los métodos de detección automática de pólipos llevado a cabo se basa en el análisis de la textura de las imágenes (véase figura 4.66). La textura de los pólipos tiene propiedades diferentes a otros elementos del colon, como pueden ser las paredes o las heces. En base a este concepto se ha procedido a diseñar un sistema de detección automática de pólipos. Al contrario que en el análisis de los bordes este enfoque obtiene mayor eficacia cuando el pólipo está más cerca de la cámara, es decir, cuando se pueden ver con nitidez los patrones de su superficie.

Este sistema se compone de seis bloques: enventanado de la imagen (C2.1), rotación y escalado de las ventanas (C2.2), extracción de características (C2.3), reducción de características (C2.4), clasificación (C2.5) y determinación del área del pólipo (C2.7). A continuación se realiza una descripción detallada de cada uno de los bloques.

Enventanado de la imagen (C2.1)

Para poder proceder a realizar un análisis de la textura y el color de una imagen es necesario realizar un enventanado, habiéndose descrito su necesidad en el módulo

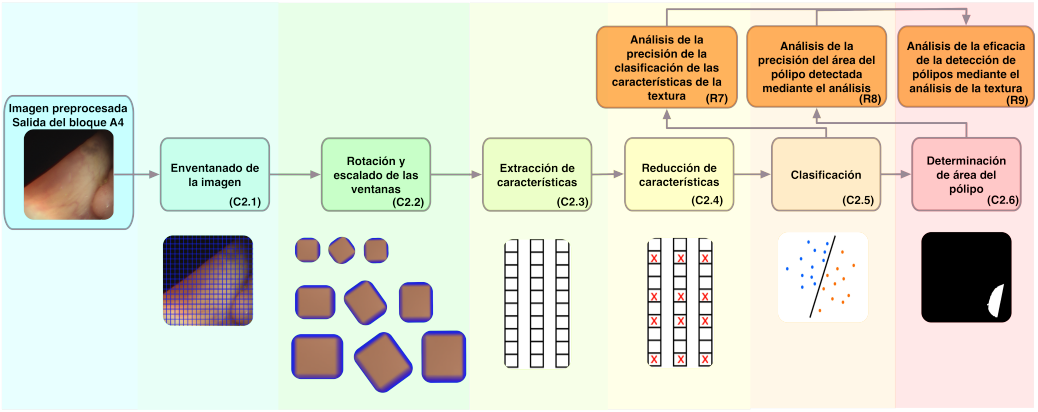


Figura 4.66: Detección automática de pólipos mediante el análisis de la textura.

B3.2. Las ventanas utilizadas tienen un tamaño de 20x20 píxeles sin solapamiento. Como puede verse, las características del enventanado utilizado en la detección de pólipos y en la evaluación de la calidad de preparación del colon son las mismas. Esto se debe a dos motivos: la eficacia mostrada por esta configuración y su eficiencia computacional. Mediante los parámetros tamaño de ventana y solapamiento se debe encontrar el equilibrio entre la precisión de la detección y el tiempo de ejecución, habiéndose encontrado esta armonía en la parametrización descrita.

Rotación y escalado de las ventanas (C2.2)

Al igual que en el apartado B3.3, es necesario realizar la rotación y escalado de las ventanas generadas en el proceso anterior para conseguir una mayor generalización y efectividad. El incremento de efectividad es debida a la invariancia a la rotación y el escalado conseguida por este proceso, aportando una mayor robustez a las características extraídas.

Extracción de características (C2.3)

La extracción de características de la textura y el color para la detección automática de pólipos se realiza mediante el sistema diseñado en el módulo B3.4. Éste ha sido diseñado para tener la capacidad de analizar la textura y el color tanto de las heces presentes en las imágenes colonoscópicas, como de los pólipos presentes en

ellas. En el caso de la detección de pólipos, la entrada al sistema de extracción de características es una imagen colonoscópica y como salida se extraen conjuntos de características pertenecientes a las ventanas extraídas de ellas.

La textura y el color son descriptores determinantes a la hora de detectar pólipos colorrectales, ya que en muchas ocasiones presentan patrones diferentes a las paredes del colon, de forma que se permite una detección automática. El enfoque de la textura es más apropiado para detectar pólipos situados a una distancia corta-media respecto a la cámara, ya que ahí es donde se permite observar con detalle su superficie. En el caso del color, éste actúa de una forma eficaz a cualquier distancia ya que no se ve afectado por ella.

Reducción de características (C2.4)

El proceso de reducción de las características aplicado ha sido descrito en el apartado ≪Reducción de características (B3.5)≫. El conjunto de características de entrada estará compuesto por las propiedades extraídas mediante los diferentes descriptores utilizados. Tras la reducción de las mismas se obtiene un subconjunto con un mayor potencial discriminante que hace ser más efectivos a los algoritmos de detección automática de pólipos. Todos los resultados obtenidos en este proceso serán tratados en el apartado 5.2.2.4 ≪Análisis de la precisión de la clasificación de las características de la textura (R7)≫ del capítulo 5 ≪Resultados≫.

Clasificación (C2.5)

Una vez ha sido realizada la reducción de características se procede a realizar el entrenamiento y prueba del clasificador. Para ello se hará uso del sistema de clasificación descrito en el módulo C1.6. Partiendo de las características proporcionadas por los diferentes descriptores de la textura y el color se hará posible una detección automática de las regiones que contienen pólipos. Por otra parte, es necesario evaluar la precisión del presente módulo, de forma que se puedan validar los diseños y desarrollos realizados. La metodología empleada para esta evaluación se presenta en el siguiente apartado.

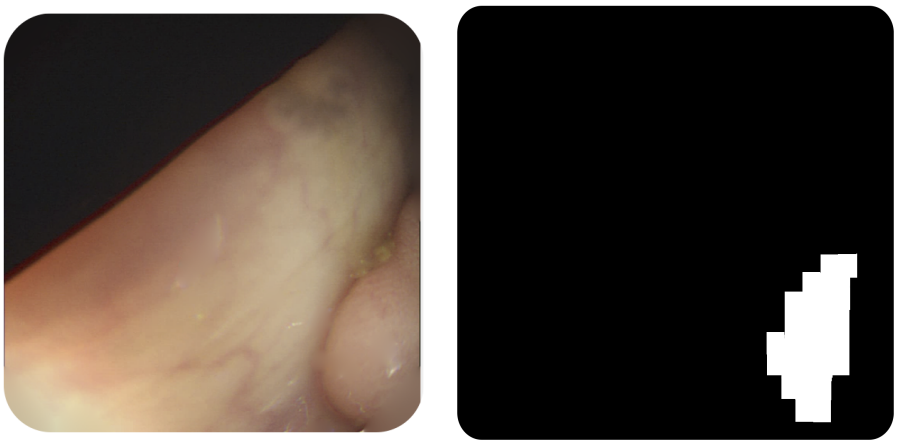
Sistema de análisis de la precisión de la clasificación de las características de la textura (R7)

Al igual que en la evaluación de la precisión de la clasificación mediante las características de los bordes (bloque R4), es necesario realizar el mismo procedimiento para el caso de la clasificación mediante el análisis de la textura. Mediante este proceso se permite garantizar que las características son eficaces a la hora de realizar una clasificación de regiones de las imágenes, detectando aquellas pertenecientes a los pólipos. De esta forma se verifica que sea posible una detección automática de pólipos mediante el análisis de la textura propuesto. En caso de no ser posible la realización de una clasificación precisa, el método diseñado no sería útil, ya que la metodología en la que se basa no es válida. Esta evaluación es realizada sobre las propiedades extraídas de las imágenes pertenecientes a la base de datos secundaria *CVC Colon Database*. Todos los datos y descripciones detalladas sobre esta evaluación pueden verse en el apartado 5.2.2.4 ≪Análisis de la precisión de la clasificación de las características de la textura (R7)≫ perteneciente al capítulo 5 ≪Resultados≫.

Determinación del área del pólipo (C2.6)

Al igual que ocurre en el caso de la detección automática de pólipos mediante el análisis de bordes, es preciso realizar el mismo proceso en el caso del análisis de la textura. Una vez ha sido realizada la clasificación de las ventanas extraídas de la imagen, es necesario ordenar la salida del clasificador como se ha mostrado en la figura 4.42, volviendo a reconstruir la imagen. Como salida de este proceso se obtiene una máscara que indica la ubicación y extensión del pólipo, en caso de haberse detectado. En función del tamaño de las ventanas utilizadas la precisión será mayor o menor. Utilizando ventanas más pequeñas se obtiene una localización más precisa, sacrificando el tiempo de cómputo, en caso de usar ventanas de mayor tamaño, la localización es menos precisa, obteniéndose un tiempo de cómputo menor. Por otra parte, al tratase de ventanas cuadradas los bordes de los pólipos no serán curvos, por lo que el mayor problema de esta alternativa es la poca fidelidad de forma obtenida, aunque este inconveniente queda reducido a mera anécdota por la alta eficacia de detección que ofrece. En la figura 4.67 se muestra el resultado

del proceso de creación del área del pólipo propuesto, mostrándose en la imagen 4.67(a) una imagen colonoscópica y en la imagen 4.67(b) la máscara obtenida.



(a) (b)

Figura 4.67: Resultado de la creación del área del pólipo mediante el análisis de la textura. a) Imagen original. b) Máscara con el área del pólipo generada.

Una vez definido el proceso de generación del área del pólipo detectado mediante el análisis de la textura es requisito indispensable la evaluación de su eficacia para poder validarlo. Para ello se ha diseñado el sistema de evaluación que se describe en el siguiente apartado.

Sistema de análisis de la precisión del área del pólipo detectada mediante el análisis de la textura (R8)

De la misma forma que se ha diseñado la evaluación de la precisión del área del pólipo detectada mediante el análisis de los bordes (bloque R5), es preciso realizar el mismo proceso para la evaluación de la precisión del área del pólipo detectada mediante análisis de la textura. La metodología empleada es igual en ambos casos, permitiendo cuantificar cómo de precisa es el área del pólipo determinada por el sistema propuesto mediante el uso de métricas objetivas. Todos los datos y descripciones detalladas sobre esta evaluación pueden verse en el apartado 5.2.2.5 ≪Análisis de la precisión del área del pólipo detectada mediante el análisis de la textura (R8)≫ perteneciente al capítulo 5 ≪Resultados≫.

Sistema de análisis de la precisión de la detección de pólipos mediante el análisis de la textura (R9)

El último módulo de evaluación del sistema de análisis de la textura diseñado es la evaluación de la eficacia de dicho enfoque. El proceso a seguir y los objetivos buscados son iguales que en el caso del análisis de la precisión de la detección de pólipos mediante análisis de los bordes (R6). El análisis de la textura es dependiente a la visualización de los patrones de la misma, siendo estos más visibles cuanto más cerca estén de la cámara que toma las imágenes. Por ello se plantea el cálculo del porcentaje de imágenes de la base de datos *CVC Colon Database* en las que se ha conseguido detectar pólipos mediante el presente análisis. Todos los datos y descripciones detalladas sobre esta evaluación pueden verse en el apartado 5.2.2.6 ≪Análisis de la precisión de la detección de pólipos mediante el análisis de la textura (R9)≫ perteneciente al capítulo 5 ≪Resultados≫.

4.2.3.3 Combinación de la detección de pólipos mediante los análisis de bordes y textura (C3)

Al haberse diseñado un sistema combinado para la detección automática de pólipos, ha de ser definido el protocolo mediante el cual se deben aunar los resultados obtenidos por los análisis de bordes y textura. Cada uno de ellos tiene sus puntos fuertes y débiles, por lo que se tratará de explotar las ventajas de cada uno de ellos minimizando los inconvenientes. Para ello se ha diseñado una metodología que se describe en el siguiente apartado.

Integración de las detecciones mediante el análisis de bordes y textura (C3.1)

La integración de las detecciones de pólipos mediante el análisis de bordes y textura se realiza mediante las reglas definidas en la figura 4.68.

La estructura del esquema de integración está basada en dos preguntas, a partir de las cuales se toman las decisiones pertinentes para aunar los dos enfoques de detección usados. Éstas son las siguientes:

- ¿Pólipo detectado? Esta pregunta tiene dos posibles respuestas:

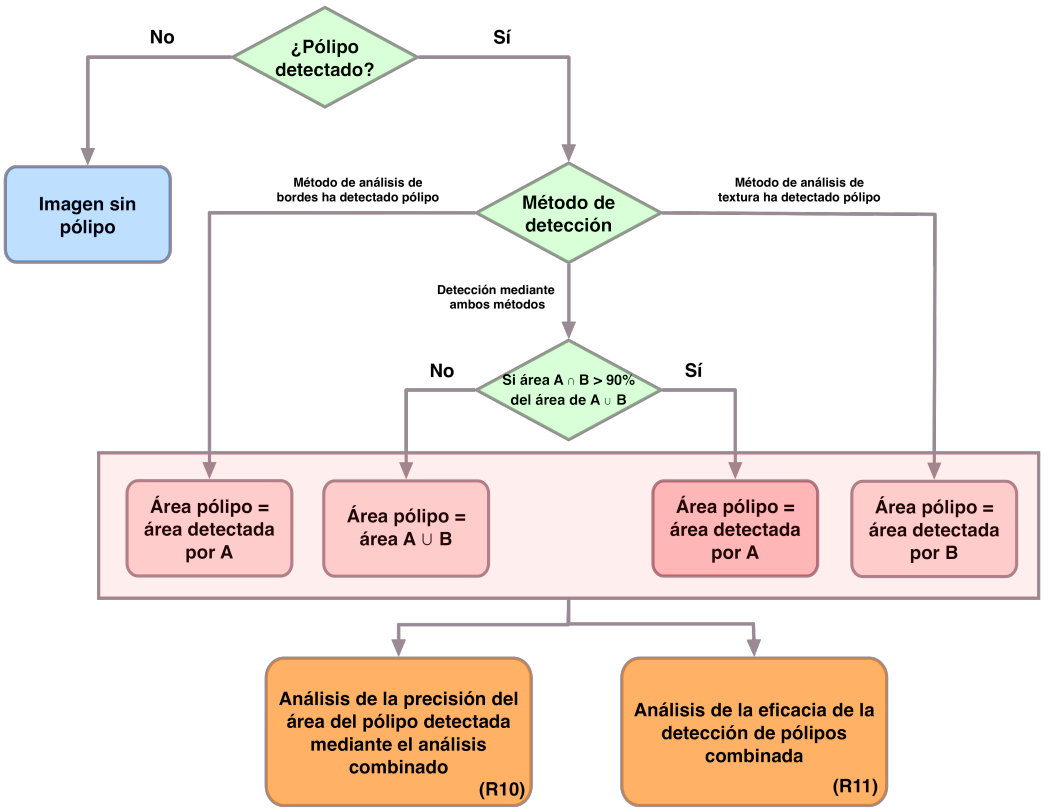


Figura 4.68: Metodología diseñada para la integración de las detecciones mediante el análisis de los bordes y de la textura. A y B corresponden a las detecciones de pólipos mediante el análisis de los bordes y de la textura de forma respectiva.

Sí: en caso de haberse detectado algún pólipo en la imagen es necesario proceder a realizar la segunda de las cuestiones propuestas.

No: en caso de no haber sido posible detectar ningún pólipo no es necesaria integración alguna, habiéndose finalizado el proceso.

- Método de detección: en el momento en el que ha sido detectado un pólipo, es necesario conocer qué técnica ha sido capaz de descubrirlo. Esta pregunta tiene tres posibles respuestas, cada una de ellas con un proceso diferente asociado. A continuación se realiza una descripción de las mismas.

  – Pólipo detectado mediante el análisis de bordes: cuando sólo el método de análisis de los bordes ha detectado un pólipo el resultado final del

sistema de detección automática de pólipos combinado será el especificado por este método.

- Pólipo detectado mediante el análisis de textura: cuando sólo el método de análisis de la textura ha detectado un pólipo el resultado final del sistema de detección automática de pólipos combinado será el especificado por este método.
- Ambos métodos han detectado pólipo: por último, en caso de que ambos métodos hayan sido capaces de detectar un pólipo es necesario proceder a realizar una combinación. La decisión de combinación se basa en las operaciones intersección ($\cap$) y unión ($\cup$) de las áreas del pólipo detectadas por ambos enfoques. En caso de que la intersección de las áreas sea mayor al 90 % del área de la combinación de ambas, se determinará como área final de la detección aquella determinada por el análisis de bordes. Esta decisión se debe a que este enfoque produce unos contornos más fieles a la forma del pólipo. En caso contrario el área final será la determinada por la unión de las áreas de ambos enfoques. Cuando existe una baja proporción de píxeles compartidos por las áreas es debido a que alguno de los métodos no ha detectado todos los píxeles pertenecientes a los pólipos, por lo que mediante la unión se consigue una detección más precisa.

Haciendo uso de estas reglas se lleva a cabo la combinación de los diferentes enfoques utilizados en la detección de pólipos. Con ello se mejora de manera sustancial los resultados obtenidos por las técnicas individuales. Una vez diseñado y desarrollado el sistema, es preciso evaluar su eficacia, temática que se aborda en el siguiente apartado.

Sistema de análisis de la precisión del área del pólipo detectada mediante el análisis combinado (R10)

Mediante el procedimiento utilizado en los sistemas de análisis de la precisión del área del pólipo detectada mediante el análisis de los bordes (R5) y de la textura (R8), se evaluará la precisión del área del pólipo detectada mediante el análisis

combinado haciendo uso de métricas objetivas. Los resultados deberán ser más precisos que en los enfoques individuales ya que se buscan los puntos fuertes de ambos. Toda la información sobre esta evaluación puede verse en el apartado 5.2.2.7 ≪Análisis de la precisión del área del pólipo detectada mediante el análisis combinado (R10)≫ perteneciente al capítulo 5 ≪Resultados≫.

Sistema de análisis de la precisión de la detección de pólipos mediante el análisis combinado (R11)

De la misma forma que se ha realizado una evaluación de la eficacia de las técnicas de detección automática de pólipos mediante el análisis de la textura y de los bordes (bloques R6 y R9), se lleva a cabo una evaluación de la eficacia de la detección de pólipos combinada, calculando el porcentaje de imágenes de la base de datos *CVC Colon Database* en las que se ha conseguido detectar pólipos mediante este enfoque. Todos los datos y descripciones detalladas sobre estas evaluaciones pueden verse en el apartado 5.2.2.8 ≪Análisis de la precisión de la detección de pólipos mediante el análisis combinado (R11)≫ del capítulo 5 ≪Resultados≫.

4.2.4 Generación de informes (D)

El último de los módulos que componen la tesis doctoral llevada a cabo es el de generación de informes (véase figura 4.69). Es el encargado de unificar los resultados obtenidos de los módulos: evaluación de la calidad de preparación del colon mediante la ELCB (B) y detección automática de pólipos (C).

Para poder diseñar un sistema de ayuda al diagnóstico médico es requisito fundamental unificar toda la información generada de forma que se facilite su interpretación por parte de los especialistas. En el caso que nos ocupa, se generará un informe por cada colonoscopia analizada incluyendo la información que se describe a continuación.

En primer lugar, el informe contiene la información referente a la evaluación de la calidad de preparación del colon mediante la ELCB (véase bloque D1 de la figura 4.5). Se indica para cada zona del colon (derecho, transverso e izquierdo, bloques D1.1, D1.2 y D1.3 de la figura 4.5), la puntuación de la ELCB obtenida por cada

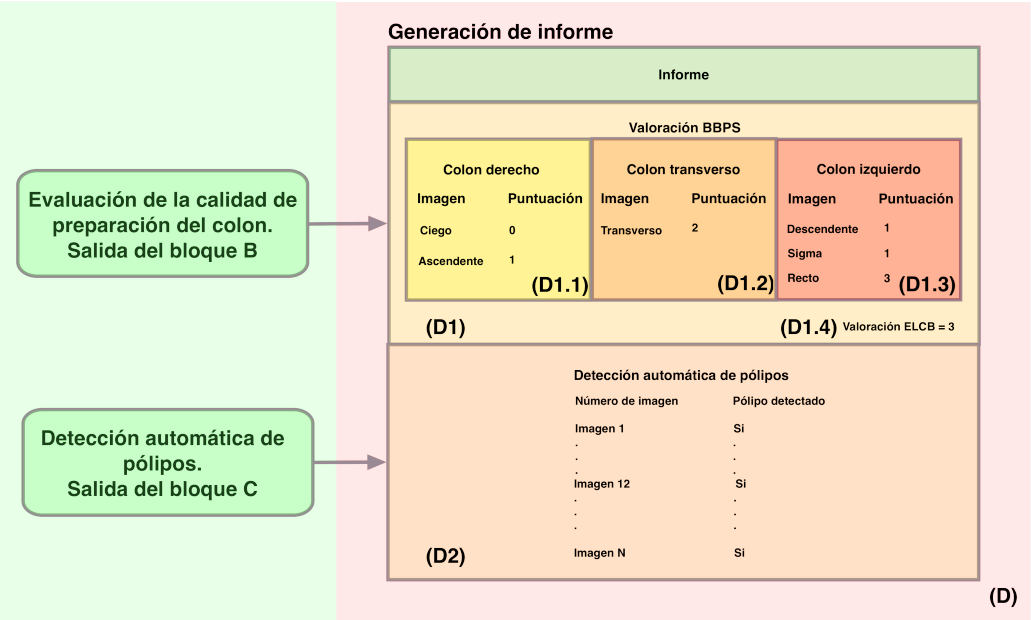


Figura 4.69: Módulo D. Generación de informes.

una de las imágenes correspondientes (ciego, ascendente, transverso, descendente, sigma y recto), así como la valoración final de la ELCB.

En segundo lugar, se indica la información relevante a la detección automática de pólipos (véase bloque D2 de la figura 4.5). La información sobre la detección automática de pólipos indica sólo el identificativo de la imagen en la que se ha detectado algún pólipo. Se ha decidido incluir de forma exclusiva el identificativo de las imágenes en las que se ha detectado algún pólipo para no extender más de lo necesario los informes.

Con todo esto, la información queda unificada en un único informe, de forma que se proporciona una ayuda al diagnóstico médico gracias a la aportación de datos objetivos alternativos a la interpretación del especialista.

4.3 Sumario

En este capitulo se ha realizado un completo recorrido del sistema diseñado compuesto por los módulos: **preprocesado de imágenes colonoscópicas (A)**, **evaluación de la calidad de preparación del colon mediante la ELCB (B)**, **detección**

automática de pólipos (C) y **generación de informes (D)**, lo que compone el sistema de evaluación de colonoscopias integral.

Primeramente se han expuesto las bondades de los módulos diseñados en alto nivel, es decir, aportando una primera idea de los mismos de manera superficial, con un nivel de abstracción alto, lo que facilita la comprensión del lector y lo adecua al siguiente nivel.

Tras explicar el alto nivel de los sistemas se ha realizado una explicación en bajo nivel de los mismos, realizando una abstracción lo más baja posible. Así, se ha realizado una explicación pormenorizada de cada sistema y de los módulos internos que los componen, enumerando las entradas y salidas ligadas a cada uno de ellos. Gracias a esto el lector se ha podido hacer una idea aproximada y realista de lo que estos sistemas ofrecen por separado y en conjunto y lo que este conjunto puede ofrecer a los endoscopistas. Esto es debido a que el sistema ofrece una solución global que actúa en los dos **puntos clave de la colonoscopia**, la **evaluación de la calidad de preparación del colon** y la **detección de pólipos**. El beneficio principal aportado por la evaluación de la calidad de preparación del colon mediante la ELCB es la **estandarización de la escala**, basándose a partir de ahora en parámetros objetivos, lo que permitirá dotar de mayor validez a la misma, además de posibilitar la comparación entre las evaluaciones de diferentes centros de salud, cosa que hasta la fecha no era posible. En cuanto a la detección automática de pólipos, se proporciona un mecanismo de seguridad para **reducir el número de cánceres de intervalo generados por lesiones perdidas**.

Para finalizar, se ha verificado el cumplimiento de los subobjetivos 2 y 4 definidos para la presente investigación (véase apartado 1.3 ≪Objetivos≫). Estos decían de forma respectiva: “Diseñar un método para la evaluación automática de la calidad de preparación del colon del paciente basada en la ELCB” y “Diseñar un método para la detección y segmentación automática de pólipos en imágenes colonoscópicas”.

"You can't always get what you want, but if you try sometimes, you might find, you get what you need."

Mick Jagger

CAPÍTULO

5

Resultados

Este capítulo describe los resultados obtenidos a partir del diseño propuesto en el capítulo anterior y se organiza como sigue. La sección 5.1 ≪Definición del experimento≫, describe la base de datos utilizada para la extracción de resultados. La sección 5.2 ≪Evaluación de los resultados≫, aborda el conjunto de resultados para cada uno de los bloques descritos en el diseño: sistema de evaluación de la calidad de preparación del colon mediante la ELCB y sistema de detección automática de pólipos. Para finalizar, el capítulo se cierra con la sección 5.3 ≪Sumario≫ que no es más que una breve descripción de lo tratado.

5.1 Definición del experimento

El análisis de los resultados obtenidos por los algoritmos de evaluación de la calidad de preparación del colon y detección automática de pólipos es realizado mediante 11 bloques. En el análisis del sistema propuesto para la evaluación de la calidad de preparación del colon mediante la ELCB se han utilizado 200 imágenes colonoscópicas de la base de datos principal, las cuales contienen diferentes cantidades de heces. Este conjunto es utilizado en los apartados: 5.2.1.1 ≪Análisis de resultados de la precisión de la detección de heces diseñada (R1)≫, 5.2.1.2 ≪Análisis de resultados de la precisión de la clasificación de heces diseñada (R2)≫,

5.2.1.3 ≪Análisis de resultados de la precisión del cálculo de la ELCB diseñado (R3)≫ y 5.2.1.4 ≪Comparativa del método de evaluación de la calidad del colon propuesto respecto a estudios del estado del arte≫. En cuanto a la evaluación de los resultados obtenidos por el sistema de detección de pólipos diseñado, se hará uso de la base de datos *CVC Colon Database*, la cual se compone de 380 imágenes colonoscópicas que contienen pólipos. Además, también proporciona las máscaras correspondientes a la posición exacta de los mismos que serán utilizadas para contrastar los resultados. Esta base de datos será utilizada en los siguientes apartados: 5.2.2.1 ≪Análisis de la precisión de la clasificación mediante características de los bordes (R4)≫, 5.2.2.2 ≪Análisis de la precisión del área del pólipo detectada mediante el análisis de bordes (R5)≫, 5.2.2.3 ≪Análisis de la precisión de la detección de pólipos mediante el análisis de bordes (R6)≫, 5.2.2.4 ≪Análisis de la precisión de la clasificación de las características de la textura (R7)≫, 5.2.2.5 ≪Análisis de la precisión del área del pólipo detectada mediante el análisis de la textura (R8)≫, 5.2.2.6 ≪Análisis de la eficacia de la detección de pólipos mediante el análisis de la textura (R9)≫, 5.2.2.7 ≪Análisis de la precisión del área del pólipo detectada mediante el análisis combinado (R10)≫, 5.2.2.8 ≪Análisis de la eficacia de la detección de pólipos mediante el análisis combinado (R11)≫ y 5.2.2.9 ≪Comparativa del método de detección automática de pólipos propuesto respecto a estudios del estado del arte≫.

5.2 Evaluación de los resultados

En esta sección se comienza con la evaluación de los resultados obtenidos para cada uno de los bloques de análisis propuestos. En primer lugar se procede con el estudio de la eficacia del sistema de evaluación de la calidad de preparación del colon, para continuar después con el sistema de detección automática de pólipos.

5.2.1 Análisis de resultados del sistema de evaluación de la calidad de preparación del colon mediante la ELCB

El análisis de los resultados obtenidos por el sistema de evaluación de la calidad de preparación del colon mediante la ELCB se realiza en los siguientes apartados:

5.2.1.1 ≪Análisis de resultados de la precisión de la detección de heces diseñada (R1)≫, 5.2.1.2 ≪Análisis de resultados de la precisión de la clasificación de heces diseñada (R2)≫, 5.2.1.3 ≪Análisis de resultados de la precisión del cálculo de la ELCB diseñado (R3)≫ y 5.2.1.4 ≪Comparativa del método de evaluación de la calidad del colon propuesto respecto a estudios del estado del arte≫. Esto se debe a que la puntuación de la ELCB obtenida está asentada en métodos previos que requieren de una validación, asegurándose de esta forma la fiabilidad de los resultados. Es necesario añadir que, para poder afrontar este proceso con garantías se ha contado con la colaboración de dos experimentados endoscopistas que han proporcionado cada uno de ellos la siguiente información:

- Porcentaje de heces observado en cada una de las 200 imágenes a evaluar.
- Porcentaje de cada tipo de heces observado en cada una de las 200 imágenes a evaluar.
- Puntuación de la ELCB otorgada a cada una de las 200 imágenes a evaluar.

Sin más dilación se comienza con el análisis de los resultados obtenidos.

5.2.1.1 **Análisis de resultados de la precisión de la detección de heces diseñada (R1)**

La base fundamental para poder evaluar la calidad de preparación del colon, de forma independiente a la escala a utilizar, es la detección de heces. Por este motivo se hace necesario analizar la precisión del sistema diseñado para tal propósito. Para poder afrontar este proceso se dispone de cuatro conjuntos de datos, estos son los siguientes:

- Porcentaje de heces observado por el especialista 1 para cada una de las 200 imágenes a evaluar.
- Porcentaje de heces observado por el especialista 2 para cada una de las 200 imágenes a evaluar.
- Porcentaje de heces detectado por el sistema diseñado para cada una de las 200 imágenes a evaluar.

- Porcentaje de heces real obtenido mediante una segmentación manual de cada una de las 200 imágenes a evaluar (validado por los especialistas colaboradores y considerado real).

A partir de este conjunto de datos se procede a realizar las siguientes evaluaciones: determinación de la normalidad del conjunto de datos, análisis estadístico por parejas de los porcentajes totales de heces detectados, análisis del CCI para los porcentajes de heces totales detectados y análisis de las tasas de error en los porcentajes de heces detectados. En los siguientes apartados se describe de forma detallada el proceso realizado, técnicas utilizadas y los resultados obtenidos.

Determinación de la normalidad del conjunto de datos

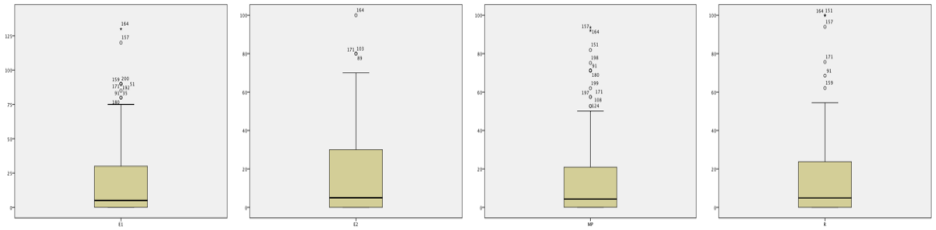
Todo proceso de análisis de datos debe comenzar por determinar el tipo de distribución de los mismos. De ello depende el modelo de técnicas a aplicar sobre ellos. En caso de seguir una distribución normal se hará uso de métodos paramétricos, utilizándose no paramétricos en caso contrario. Esta comprobación ha sido llevada a cabo mediante el test de normalidad de Kolmogorov-Smirnov.

El conjunto de datos utilizado ha obtenido unos valores de significancia $p = 0$ para todos los grupos (especialistas 1 y 2, método propuesto y la realidad), por lo que presentan una distribución no normal. Por este motivo, es necesario aplicar un método no paramétrico en el análisis estadístico por parejas. En la figura 5.1 se representa de forma gráfica la distribución de los conjuntos de datos analizados, mostrándose los valores del estadístico y su significancia en la tabla 5.1.

Tras haber realizado el análisis de la normalidad de los datos se procede a realizar el análisis estadístico por parejas de los grupos de datos. Al haberse determinado que los datos no siguen una distribución normal se utilizará el test de la suma de rangos por parejas de Wilcoxon, el cual es no paramétrico.

Análisis estadístico por parejas de los porcentajes totales de heces detectados

Es sabido que la evaluación de la calidad de preparación del colon haciendo uso de escalas como la ELCB es subjetiva (véase apartado 2.1.8.2 ≪Escalas para la evaluación de la preparación del colon≫). Mediante este análisis se pretende comprobar que grado de discordancia existe entre los porcentajes de heces observados en las



(a) (b) (c) (d)

Figura 5.1: Distribución de los datos de los porcentajes totales de heces. a) Datos del especialista 1. b) Datos del especialista 2. c) Datos del método propuesto. d) Datos de las valoraciones reales.

Tabla 5.1: Valores y significancia estadística del test de Kolmogorov-Smirnov. De aquí en adelante E1, E2, MP, R, K-S y *p* representarán al especialista 1, especialista 2, método propuesto, valores reales, el valor del test y la significancia estadística de forma respectiva.

	K-S	***p***
E1	0.267	0
E2	0.277	0
Mp	0.249	0
R	0.241	0

imágenes por los especialistas, el método propuesto y el porcentaje real existente. De esta forma, por un lado se justificará la necesidad de contar con métodos automáticos basados en parámetros objetivos para evaluar la calidad de preparación del colon y por otro lado, se medirán las diferencias entre las valoraciones a analizar, pudiéndose determinar quien ha obtenido mejores resultados.

Para poder abordar este objetivo ha sido necesario utilizar el test de la suma de rangos por parejas de Wilcoxon, el cual comprueba la existencia de diferencias significativas entre dos grupos ($p < 0.05$). De esta forma se podrá determinar si ambos pertenecen a una misma distribución y en qué grado. El análisis ha sido realizado mediante la aplicación del test a todo el conjunto de duplas posibles entre los grupos disponibles (especialistas 1 y 2, método propuesto y real), obteniéndose los resultados proporcionados por la tabla 5.2.

Tabla 5.2: Resultados del test de la suma de rangos por parejas de Wilcoxon para los porcentajes de heces totales detectados. De aquí en adelante la columna "dupla" representará todas las posibles parejas entre los grupos disponibles, siendo p el valor de la significancia. En todas las tablas de resultados relacionadas con el presente test, el valor de p para las duplas [E1, R], [E2, R] y [MP, R] será mejor cuanto más alto sea ya que indicará la no existencia de diferencias significativas con la realidad, demostrándose una mayor precisión.

Dupla	***p***
[E1, E2]	0.008
[E1, MP]	0.005
[E1, R]	0
[E2, MP]	0.251
[E2, R]	0.018
[MP, R]	**0.534**

En vista de los resultados obtenidos se pueden extraer una serie de conclusiones acerca de la determinación del porcentaje de heces presente en una imagen colonoscópica. Ésta es una evaluación crítica ya que es el pilar fundamental sobre el que se basan las escalas de evaluación de la calidad de preparación del colon. A continuación se describen las conclusiones extraídas:

1. Las valoraciones de los porcentajes de heces proporcionados por el especialista 1 y el especialista 2 (dupla [E1, E2]) han obtenido un valor de significancia $p = 0.008$, por lo que existen diferencias significativas entre ellas. Esto demuestra la discrepancia existente entre ellos a la hora de determinar la cantidad de heces existente en el colon, confirmando que las valoraciones de las escalas validadas sufren de subjetividad.

2. Las valoraciones de los porcentajes de heces proporcionados por el especialista 1 y el método de detección de heces propuesto (dupla [E1, MP]) han obtenido un valor de significancia $p = 0.005$, por lo que existen diferencias significativas entre ellas.

3. Las valoraciones de los porcentajes de heces proporcionados por el especialista 1 y las reales (dupla [E1, R]) han obtenido un valor de significancia $p =$

0. Este resultado confirma que el especialista 1 no ha sido capaz de determinar de una forma precisa los porcentajes de heces presentes en las imágenes.

4. Las valoraciones de los porcentajes de heces proporcionados por el especialista 2 y el método propuesto (dupla [E2, MP]) han obtenido un valor de significancia $p = 0.251$, por lo que no existen diferencias significativas entre ambos. Esto no quiere decir que sus valoraciones sean similares, ya que el valor de significancia no es elevado. Se puede hacer la interpretación de que las valoraciones proporcionadas por el especialista 2 se parecen más a las obtenidas por el método propuesto que las del especialista 1 ($p = 0.005$ para la dupla [E1, MP]).

5. Las valoraciones de los porcentajes de heces proporcionados por el especialista 2 y la realidad (dupla [E2, R]) han obtenido un valor de significancia $p = 0.018$. Esto indica que existen diferencias significativas con la realidad y que sus valoraciones han sido un poco más precisas que las del especialista 1 ($p = 0$ para la dupla [E1, R]).

6. Las valoraciones de los porcentajes de heces proporcionados por el método propuesto y la realidad (dupla [MP, R]) han obtenido un valor de significancia $p = 0.534$. De esta manera se puede demostrar de forma objetiva que los algoritmos diseñados para la detección de heces arrojan unos resultados muy precisos y que además, superan con creces a las valoraciones proporcionadas por ambos especialistas ($p = 0$ y $p = 0.018$ para las duplas [E1, R] y [E2, R]).

Mediante este análisis queda demostrada la discrepancia existente en la determinación del porcentaje de heces en las imágenes colonoscópicas por parte de los especialistas ($p = 0.008$ para la dupla [E1, E2]). Además, ha quedado probado que el método propuesto ($p = 0.534$ para la dupla [MP, R]) es mucho más preciso que los especialistas ($p = 0$ y $p = 0.018$ para las duplas [E1, R] y [E2, R]).

Por otra parte, es necesario indicar la dificultad que supone determinar un porcentaje de heces preciso en las imágenes colonoscópicas, ya que se ven afectadas por bordes negros y reflejos especulares. Esto hace perder la perspectiva del tamaño real de la imagen penalizando la precisión de los porcentajes otorgados por los especialistas.

Análisis del CCI para los porcentajes de heces totales detectados

Tras haber analizado las diferencias significativas existentes entre en los porcentajes de heces determinados por los especialistas y el método propuesto, se procederá a analizar la correlación existente entre todas las duplas de grupos posibles mediante el CCI. A partir de este proceso se pretende valorar el grado de analogía existente entre los grupos. En la tabla 5.3 se pueden observar los resultados obtenidos por el CCI para las diferentes parejas de grupos disponibles.

Tabla 5.3: Resultados obtenidos por el CCI para todas las duplas de los grupos disponibles. De aquí en adelante el valor del CCI para las duplas [E1, R], [E2, R] y [MP, R] será mejor cuanto más alto sea. Esto será un indicativo de una alta analogía con la realidad.

Dupla	CCI	Grado
[E1, E2]	0.82	Alta
[E1, MP]	0.735	Alta
[E1, R]	0.8	Alta
[E2, MP]	0.821	Alta
[E2, R]	0.847	Alta
[MP, R]	**0.949**	**Muy alta**

Tras la presentación de los resultados obtenidos por el CCI se pueden extraer las siguientes conclusiones:

1. El CCI obtenido por los especialistas (dupla [E1, E2]) es de 0.82 por lo que ambos presentan una alta correlación a la hora de determinar el porcentaje de heces en las imágenes. Es cierto que sus valoraciones en muchos casos son diferentes, como se ha visto en el análisis estadístico ($p = 0.008$ para la dupla [E1, E2]) pero guardan cierta analogía. Esto es deseable, ya que a pesar de proporcionar porcentajes diferentes, todos ellos siguen cierta concordancia.

2. El CCI obtenido por la pareja formada por el especialista 1 y el método propuesto (dupla [E1, MP]) es de 0.735. Este es un buen resultado, ya que a pesar de haber diferencias significativas entre ambos grupos ($p = 0.005$ para

la dupla [E1, MP]), la correlación es alta, indicando una buena analogía entre grupos.

3. El CCI obtenido por la pareja formada por el especialista 1 y la realidad (dupla [E1, R]) es de 0.8. Este es un gran resultado debido a que la correlación es alta demostrando que ha realizado las valoraciones de los porcentajes de heces con una cierta correspondencia respecto a la realidad, a pesar de haberse encontrado diferencias significativas entre ambos grupos ($p = 0$ para la dupla [E1, R]).

4. El CCI obtenido por la pareja formada por el especialista 2 y el método propuesto (dupla [E2, MP]) es de 0.821. Este resultado sugiere que, al igual que en la dupla especialista 1 y método propuesto (CCI = 0.735 para la dupla [E1, MP]), ambos grupos muestran una alta correlación respecto al método propuesto mostrando una armonía, siendo ésta mayor en el caso del especialista 2.

5. El CCI obtenido por la pareja formada por el especialista 2 y la realidad (dupla [E2, R]) es de 0.847 a pesar de haberse encontrado diferencias significativas entre ellos ($p = 0.018$ para la dupla [E2, R]). Se trata de una alta correlación, lo que indica una buena correspondencia respecto a la realidad. También es preciso indicar que el especialista 2 ha obtenido un grado de correlación mayor respecto a la realidad que el especialista 1 (CCI = 0.8 para la dupla [E1, R]).

6. El CCI obtenido por la pareja formada por el método propuesto y la realidad (dupla [MP, R]) es de 0.949. Esta puntuación indica una correlación muy alta, superior a la de los especialistas (CCI = 0.8 y CCI = 0.847 para las duplas [E1,R] y [E2, R]), demostrando una mayor analogía con la realidad.

Como valoración general, ha de destacarse que los grados de correlación entre todas las duplas es alta o muy alta. Esto indica que determinan las valoraciones bajo criterios homogéneos, lo que es deseable, ya que ninguno de los grupos genera resultados con una baja correlación respecto al resto. Es posible la existencia de diferencias significativas entre ellos, como ya ha quedado demostrado mediante

el test de la suma de rangos por parejas de Wilcoxon realizado de forma previa, pero a pesar de ello, los valores del CCI conseguidos son buenos. Estos resultados son debidos a que ambos test miden aspectos diferentes de los datos, pudiéndose dar esta circunstancia. Asimismo, se ha demostrado que el método propuesto ha obtenido un grado de correlación mayor respecto a la realidad (CCI = 0.949 para la dupla [MP, R]) que ambos especialistas (CCI = 0.8 y CCI = 0.847 para las duplas [E1, R] y [E2, R]).

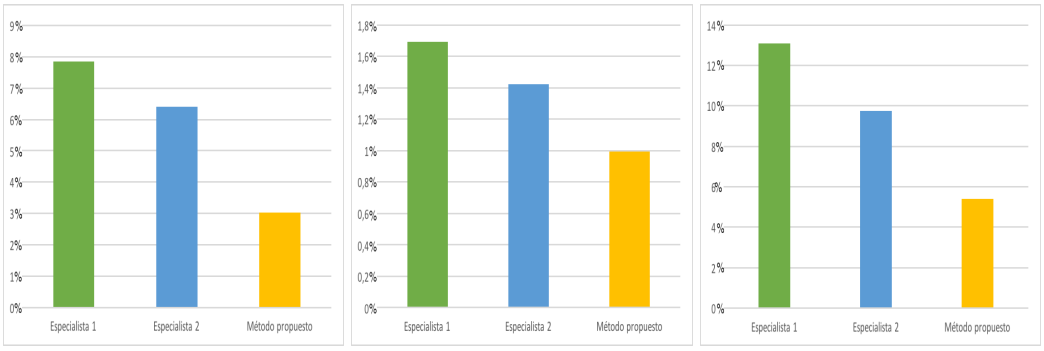
Análisis de las tasas de error en los porcentajes de heces detectados

El último análisis que se realiza sobre los porcentajes de heces determinados por los especialistas y el método propuesto es el análisis de los errores cometidos. De esta forma se pretende proporcionar datos numéricos que ayuden a una mejor interpretación de los resultados. Como ya se ha descrito de forma previa, el error es determinado por la ecuación 4.8 e indica la desviación sufrida en los porcentajes de heces determinados por cada evaluador respecto al valor real. Los resultados conseguidos por ambos especialistas y el método propuesto pueden verse en la tabla 5.4.

Tabla 5.4: Resultados obtenidos para el análisis del error en la determinación del porcentaje de heces presente en las imágenes por parte de los especialistas y el método propuesto. De aquí en adelante EAM indicará el error absoluto medio, M_e la mediana del error y σ la desviación típica del error.

	EAM	M_e	σ
E1	7.84 %	1.69 %	13.09 %
E2	6.4 %	1.42 %	9.75 %
MP	**3.03 %**	**0.99 %**	**5.42 %**

Para mostrar de forma gráfica la representación de los resultados se proporciona la figura 5.2. Ésta muestra unos diagramas de barras comparando el EAM, la mediana y la desviación típica del error obtenido por el especialista 1, el especialista 2 y el método propuesto.



(a) (b) (c)

Figura 5.2: Análisis de los errores de los porcentajes de heces determinados por los especialistas y el método propuesto. De aquí en adelante, la gráfica verde corresponderá al especialista 1, la azul al especialista 2 y la amarilla al método propuesto, siendo a) el EAM, b) la mediana del error y c) la desviación típica del error.

A la vista de los resultados es posible manifestar la alta eficacia de los algoritmos diseñados. Fijándonos en el caso del EAM, los especialistas 1 y 2 han conseguido unas valoraciones de un 7.84 % y de un 6.4 %, siendo de un 3.03 % en el caso del método diseñado. Esto indica una reducción del EAM que se traduce en una diferencia de un 4.81 % respecto al especialista 1 y de un 3.37 % respecto al especialista 2. En cuanto a la mediana del error, los especialistas 1 y 2 han obtenido unas valoraciones de un 1.69 % y de un 1.42 %, siendo de un 0.99 % para el diseño llevado a cabo. Esto supone una reducción de la mediana del error que se traduce en una diferencia de un 0.7 % respecto al primer especialista y de un 0.43 % respecto al segundo. Por último, centrándonos en la desviación típica del error, los especialistas 1 y 2 han obtenido unos valores de un 13.09 % y de un 9.75 % de forma respectiva, siendo de un 5.42 % para el método propuesto. Los resultados indican una reducción del presente indicador, correspondiéndose con una diferencia de un 7.67 % respecto al especialista 1 y de un 4.33 % respecto al especialista 2. Esto indica que las valoraciones proporcionadas por los algoritmos desarrollados son más consistentes que las de los especialistas, ya que el error que comenten a lo largo de todas las imágenes es mucho menor y menos oscilante, lo que es deseable.

Como conclusión general sobre el análisis del error, se puede afirmar una vez más que el método propuesto ofrece una precisión mucho mayor que la obtenida

por los especialistas. De esta forma se valida la detección automática de heces propuesta, la cual es la base de la valoración de la ELCB que se pretende calcular.

5.2.1.2 **Análisis de resultados de la precisión de la clasificación de heces diseñada (R2)**

Tras haber realizado una evaluación de los algoritmos diseñados para la detección automática de las heces se procede a evaluar el sistema propuesto para la clasificación de las mismas. El propósito final a alcanzar es el desarrollo de un método capaz de calcular la ELCB sobre imágenes colonoscópicas. Para ello se requiere descomponer las heces en diferentes tipos: líquidas, tintadas y sólidas. La primera validación para asegurar el correcto funcionamiento del sistema fue asegurar que la detección de heces era precisa y eficaz, lo cual ha quedado demostrado. A continuación, se procede a evaluar la precisión de la clasificación de las mismas. Para tal propósito, en primer lugar se evalúa la normalidad del conjunto de datos. En segundo lugar, se evalúan las diferencias significativas por parejas de todos los grupos en la determinación de los diferentes tipos de heces. En tercer lugar, se calcula el CCI por parejas de los porcentajes de heces de cada tipo determinados por todas las duplas de los grupos. Por último, en cuarto lugar, se evalúan las tasas de error cometidas por los especialistas y el método propuesto respecto a la realidad en la determinación del porcentaje de cada tipo de heces. Para poder afrontar este proceso se dispone del siguiente conjunto de datos:

- Porcentajes de heces líquidas, tintadas y sólidas observados por el especialista 1 para cada una de las 200 imágenes a evaluar.
- Porcentajes de heces líquidas, tintadas y sólidas observados por el especialista 2 para cada una de las 200 imágenes a evaluar.
- Porcentajes de heces líquidas, tintadas y sólidas detectados por el sistema diseñado para cada una de las 200 imágenes a evaluar.
- Porcentajes de heces líquidas, tintadas y sólidas reales obtenidos mediante una segmentación manual de cada una de las 200 imágenes a evaluar (validado por los especialistas colaboradores y considerado real).

A continuación se comienza con el análisis de la normalidad del conjunto de datos, el cual nos determinará el tipo de distribución de los mismos, así como el tipo de métodos estadísticos a utilizar.

Determinación de la normalidad del conjunto de datos

Para poder proceder a evaluar el sistema de clasificación de las heces diseñado, es necesario determinar el tipo de distribución que siguen los datos a tratar. Para ello se ha hecho uso del test de normalidad de Kolmogorov-Smirnov.

El conjunto de datos utilizado ha obtenido unos valores de significancia $p = 0$ para todos los grupos y tipos de heces, por lo que presentan una distribución no normal. Por este motivo se aplicará el test no paramétrico de la suma de rangos por parejas de Wilcoxon para evaluar las diferencias significativas entre los porcentajes de cada tipo de heces detectados por el especialista 1, el especialista 2, el método propuesto y la realidad. Para ver de una forma gráfica la representación de los datos a utilizar se añade la figura 5.3.

Los valores extraídos por el test de normalidad de Kolmogorov-Smirnov pueden observarse en la tabla 5.5.

Tabla 5.5: Valores y significancia del test de Kolmogorov-Smirnov de cada tipo de heces. De aquí en adelante H representará a las heces.

	K-S $\mathbf{H_{Líquidas}}$	***p*** $\mathbf{H_{Líquidas}}$	**K-S** $\mathbf{H_{Tintadas}}$	***p*** $\mathbf{H_{Tintadas}}$	**K-S** $\mathbf{H_{Sólidas}}$	***p*** $\mathbf{H_{Sólidas}}$
E1	0.336	0	0.377	0	0.445	0
E2	0.437	0	0.368	0	0.47	0
MP	0.266	0	0.327	0	0.33	0
R	0.272	0	0.328	0	0.322	0

Determinada la distribución de los datos se realiza el análisis estadístico por parejas de los grupos mediante el test de la suma de rangos por parejas de Wilcoxon.

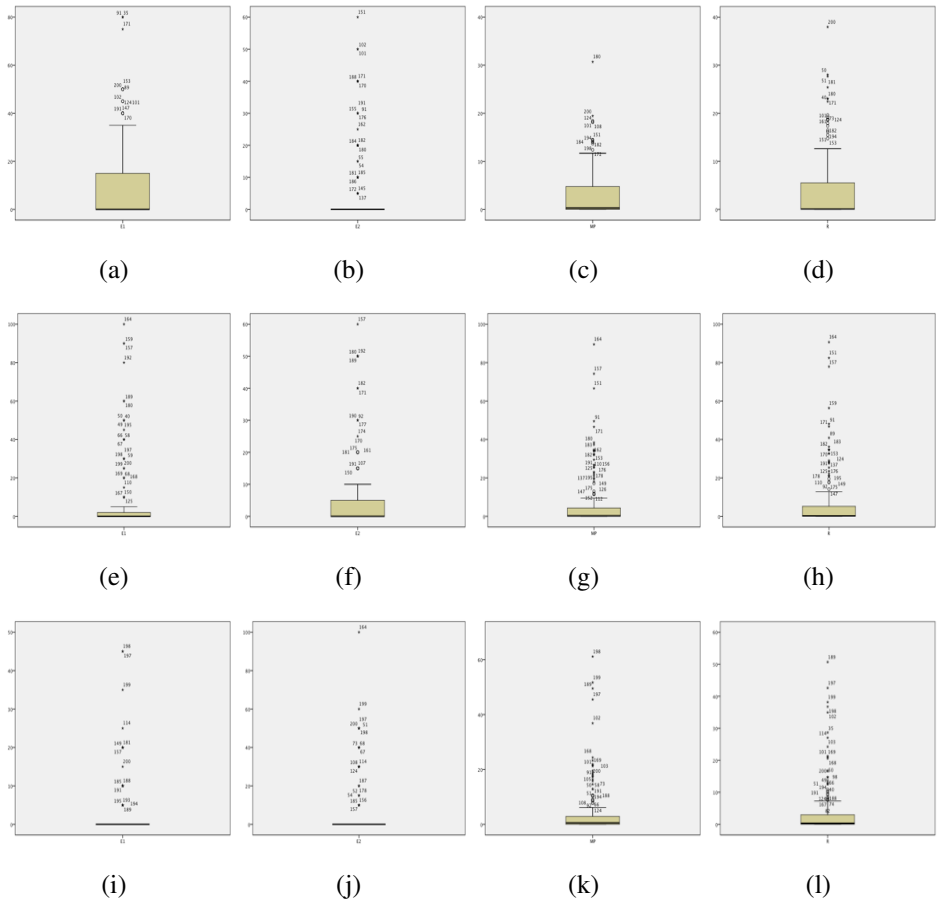


Figura 5.3: Distribución de los datos de los porcentajes totales de cada tipo de heces. a) Datos de heces líquidas del especialista 1. b) Datos de heces líquidas del especialista 2. c) Datos de heces líquidas del método propuesto. d) Datos de heces líquidas de las valoraciones reales. e) Datos de heces tintadas del especialista 1. f) Datos de heces tintadas del especialista 2. g) Datos de heces tintadas del método propuesto. h) Datos de heces tintadas de las valoraciones reales. i) Datos de heces sólidas del especialista 1. j) Datos de heces sólidas del especialista 2. k) Datos de heces sólidas del método propuesto. l) Datos de heces sólidas de las valoraciones reales.

Análisis estadístico por parejas de los porcentajes de cada tipo de heces detectados

En este apartado se aplicará el test de la suma de rangos por parejas de Wilcoxon a los datos de los porcentajes de los diferentes tipos de heces detectados en las

imágenes. De esta forma se pretende realizar un análisis estadístico que permita determinar las diferencias significativas entre las valoraciones de los especialistas, el método propuesto y la realidad.

Es sabida la complejidad que supone determinar qué porcentaje de heces presenta una imagen, pero la clasificación de las mismas en diferentes tipos supone una mayor dificultad. Mediante este análisis se pretende, por un lado demostrar la subjetividad de esta tarea, así como la disparidad de criterios existente entre los dos especialistas participantes en los experimentos y por otro lado, determinar si el sistema de clasificación propuesto es eficaz y válido. Para poder llevar a cabo esta evaluación se han formado todas las duplas posibles entre los grupos disponibles, obteniéndose los resultados proporcionados por la tabla 5.6.

Tabla 5.6: Resultados del test de la suma de rangos por parejas de Wilcoxon para los porcentajes determinados de cada tipo de heces.

Dupla	p $\mathbf{H_{Líquidas}}$	p $\mathbf{H_{Tintadas}}$	p $\mathbf{H_{Sólidas}}$
[E1, E2]	0	0.531	0.03
[E1, MP]	0.007	0	0
[E1, R]	0	0.006	0.003
[E2, MP]	0.003	0	0
[E2, R]	0.038	0.048	0
[MP, R]	**0.112**	**0.471**	**0.095**

Una vez presentados los resultados obtenidos por el test se muestran las conclusiones extraídas para la clasificación de las heces líquidas:

1. Los porcentajes de heces líquidas proporcionados por ambos especialistas (dupla [E1, E2]) han obtenido una significancia estadística $p = 0$. De esta manera se demuestra la disparidad de las valoraciones a la hora de detectar este tipo de heces por parte de los especialistas. Este resultado refuerza la idea de la subjetividad existente en la evaluación de las imágenes.

2. Los porcentajes de heces líquidas proporcionados por el especialista 1 y el método propuesto (dupla [E1, MP]) han dado como resultado una significan-

cia estadística $p = 0.007$, lo que indica la existencia de diferencias significativas entre ambos grupos.

3. Los porcentajes de heces líquidas proporcionados por el especialista 1 y los reales (dupla [E1, R]) han obtenido un valor de significancia $p = 0$. Mediante este resultado se confirma que el especialista 1 no ha sido capaz de determinar de una forma precisa el porcentaje de heces presente en las imágenes.

4. Los porcentajes de heces líquidas proporcionados por el especialista 2 y el método propuesto (dupla [E2, MP]) han obtenido un valor de significancia $p = 0.003$, por lo que existen diferencias significativas entre ambos. La conclusión que se extrae de este resultado es que las valoraciones del especialista 2 son menos próximas a las del método propuesto que las proporcionadas por el especialista 1 ($p = 0.007$ para la dupla [E1, MP]).

5. Los porcentajes de heces líquidas proporcionados por el especialista 2 y los reales (dupla [E2, R]) han obtenido un valor de significancia $p = 0.038$, lo que indica que existen diferencias significativas con la realidad. Asimismo, se verifica que el especialista 2 ha sido mucho más certero que el 1 en esta clasificación ($p = 0$ para la dupla [E1, R]).

6. Los porcentajes de heces líquidas proporcionados por el método propuesto y los reales (dupla [MP, R]) han obtenido un valor de significancia $p = 0.112$. Esto indica que no se han observado diferencias significativas, por lo que se demuestra que los algoritmos diseñados para la detección de heces líquidas arrojan unos resultados muy precisos, superando con creces a las valoraciones proporcionadas por ambos especialistas ($p = 0$ para la dupla [E1, R] y $p = 0.038$ para la dupla [E2, R]).

Para continuar, se describen las conclusiones extraídas de los resultados de la clasificación de las heces tintadas:

1. Los porcentajes de heces tintadas proporcionados por ambos especialistas (dupla [E1, E2]) han obtenido una significancia estadística $p = 0.531$. En este caso se verifica una unidad en las valoraciones de ambos especialistas a la

hora de detectar este tipo de heces, cosa que no ocurría en las líquidas ($p = 0$ para la dupla [E1, E2]).

2. Los porcentajes de heces tintadas proporcionados por el especialista 1 y el método propuesto (dupla [E1, MP]) han dado como resultado una significancia estadística $p = 0$, lo que indica que existen diferencias significativas entre ambos grupos. Por otra parte, este valor es menor que en el caso de las heces líquidas ($p = 0.007$ para la dupla [E1, MP]).

3. Los porcentajes de heces tintadas proporcionados por el especialista 1 y los reales (dupla [E1, R]) han obtenido un valor de significancia $p = 0.006$. Esto es un indicativo de que el especialista 1 no ha sido capaz de determinar de una forma precisa los porcentajes presentes de este tipo de heces en las imágenes, aunque si ha obtenido una mejor valoración que en las heces líquidas ($p = 0$ para la dupla [E1, R]).

4. Los porcentajes de heces tintadas proporcionados por el especialista 2 y el método propuesto (dupla [E2, MP]) han obtenido un valor de significancia $p = 0$, por lo que existen diferencias significativas entre ambos. Las conclusiones que se extraen de este resultado son las siguientes: las valoraciones de ambos especialistas distan bastante de la clasificación realizada por los algoritmos diseñados ($p = 0$ para las duplas [E1, MP] y [E2, MP]), además, el especialista 2 ha obtenido una mayor significancia con el método propuesto en el caso de las heces líquidas ($p = 0.003$ para la dupla [E2, MP]).

5. Los porcentajes de heces tintadas proporcionados por el especialista 2 y los reales (dupla [E2, R]) han obtenido un valor de significancia $p = 0.048$, lo que indica la existencia de una tendencia de diferencia significativa con la realidad. Mediante este resultado se demuestra que el especialista 2 ha obtenido mejores resultados en las heces tintadas que en las líquidas ($p = 0.038$ para la dupla [E2, R]). Por otra parte, al igual que en las heces líquidas, queda demostrado que el especialista 2 ha conseguido mejores valoraciones que el especialista 1 ($p = 0.006$ para la dupla [E1, R]) en esta clasificación.

6. Los porcentajes de heces tintadas proporcionados por el método propuesto y los reales (dupla [MP, R]) han obtenido un valor de significancia $p = 0.471$, por lo que no existen diferencias significativas con los porcentajes reales. De esta forma se demuestra que la clasificación de este tipo de heces es muy precisa y que además supera con creces a las valoraciones proporcionadas por ambos especialistas ($p = 0.006$ y $p = 0.048$ para las duplas [E1, R] y [E2, R]). Por otra parte, se ha descubierto que el método de clasificación diseñado ha conseguido mejores resultados para las heces tintadas que para las líquidas ($p = 0.112$ para la dupla [MP, R]).

Por último, se presentan las conclusiones extraídas de los resultados de la clasificación de las heces sólidas:

1. Los porcentajes de heces sólidas proporcionados por ambos especialistas (dupla [E1, E2]) han obtenido una significancia estadística $p = 0.03$, por lo que se verifican diferencias significativas entre ellos. Respecto a la significancia estadística de esta dupla en los diferentes tipos de heces, ésta ha sido más alta en el caso de las heces tintadas ($p = 0.531$), seguida por las sólidas, siendo más baja en las líquidas ($p = 0$).

2. Los porcentajes de heces sólidas proporcionados por el especialista 1 y el método propuesto (dupla [E1, MP]) han dado como resultado una significancia estadística $p = 0$, lo que indica que existen diferencias significativas entre ambos grupos. Este valor ha sido igual al obtenido en las heces tintadas y menor al de las heces líquidas ($p = 0.007$ para la dupla [E1, MP]).

3. Los porcentajes de heces sólidas proporcionados por el especialista 1 y los reales (dupla [E1, R]) han obtenido un valor de significancia $p = 0.003$. Esto confirma que el especialista 1 no ha sido capaz de determinar de una forma precisa los porcentajes presentes de este tipo de heces en las imágenes. Respecto a la clasificación del resto de tipos de heces, esta última ha obtenido peores resultados que en el caso de las tintadas ($p = 0.006$ para la dupla [E1, R]) y mejores que en las líquidas ($p = 0$ para la dupla [E1, R]).

4. Los porcentajes de heces sólidas proporcionados por el especialista 2 y el método propuesto (dupla [E2, MP]) han obtenido un valor de significancia $p = 0$, por lo que existen diferencias significativas entre ambos. Las conclusiones que se extraen de este resultado son las siguientes. Por un lado, las valoraciones de ambos especialistas han tenido una baja significancia respecto al método propuesto en el caso de las heces sólidas ($p = 0$ para las duplas [E1, MP] y [E2, MP]). Por otro lado, en cuanto a la comparativa de la presente dupla con los diferentes tipos de heces, se ha igualado la significancia conseguida en las heces tintadas, empeorándose la obtenida en las líquidas ($p = 0.003$ para la dupla [E2, MP]).

5. Los porcentajes de heces sólidas proporcionados por el especialista 2 y los reales (dupla [E2, R]) han obtenido un valor de significancia $p = 0$, lo que indica que existen diferencias significativas entre ellos. En comparación a la clasificación del resto de tipos de heces han obtenido peores resultados que en el caso de las heces líquidas ($p = 0.038$ para la dupla [E2, R]) y que las heces tintadas ($p = 0.048$ para la dupla [E2, R]). Por otra parte, la detección de heces sólidas realizada por el especialista 1 ($p = 0.003$ para la dupla [E1, R]) ha conseguido mejores resultados que la realizada por el especialista 2.

6. Los porcentajes de heces sólidas proporcionados por el método propuesto y los reales (dupla [MP, R]) han obtenido un valor de significancia $p = 0.095$, por lo que no existen diferencias significativas entre ellos. Comparando estos resultados con los obtenidos por el resto de tipos de heces se han conseguido peores resultados que en las líquidas ($p = 0.112$ para la dupla [MP, R]) y tintadas ($p = 0.471$ para la dupla [MP, R]). De esta forma se vuelve a demostrar que los algoritmos diseñados para la detección de heces sólidas arrojan unos resultados muy precisos y que además, superan a las valoraciones proporcionadas por ambos especialistas ($p = 0.003$ y $p = 0$ para las duplas [E1, R] y [E2, R]).

Tras haber realizado el presente análisis, se puede concluir que es cierta la disparidad en las valoraciones proporcionadas por los especialistas a la hora de determinar el porcentaje de cada tipo de heces en las imágenes. Sólo han sido capaces

de obtener valoraciones similares en el caso de las heces tintadas (p = 0.531 para la dupla [E1, E2]), viéndose la disparidad de criterios en las líquidas (p = 0 para la dupla [E1, E2]) y sólidas (p = 0.03 para la dupla [E1, E2]). Estos resultados ratifican la subjetividad que sufre la evaluación de la calidad de preparación del colon y refuerzan la idea de la necesidad de contar con herramientas de apoyo. Asimismo, ha quedado plasmada la eficacia del sistema de clasificación propuesto para todos los tipos de heces, obteniendo unos mejores resultados respecto a la realidad que los especialistas en todos los casos ($p_{\text{Líquidas}}$ = 0.112, p_{Tintadas} = 0.471 y $p_{\text{Sólidas}}$ = 0.095 para la dupla [MP, R]).

Análisis del CCI para los porcentajes de los diferentes tipos de heces detectados

El siguiente sistema de análisis de la clasificación de heces se realiza mediante el CCI. Para ello, se procede a estudiar la correlación existente entre todas las duplas de grupos posibles para las valoraciones de los porcentajes de cada tipo de heces detectados por cada uno de ellos. En la tabla 5.7 se presentan los resultados obtenidos por el CCI para las diferentes parejas disponibles.

Tabla 5.7: Resultados obtenidos por el CCI para todas las duplas de los grupos disponibles.

Dupla	CCI $H_{\text{Líquidas}}$	Grado	CCI H_{Tintadas}	Grado	CCI $H_{\text{Sólidas}}$	Grado
[E1, E2]	0.653	Media	0.342	Baja	0.435	Baja
[E1, MP]	0.26	Muy baja	0.372	Baja	0.639	Media
[E1, R]	0.388	Baja	0.382	Baja	0.598	Media
[E2, MP]	0.297	Muy baja	0.349	Baja	0.416	Baja
[E2, R]	0.305	Baja	0.313	Baja	0.338	Baja
[MP, R]	**0.744**	**Alta**	**0.981**	**Muy alta**	**0.942**	**Muy alta**

Una vez han sido presentados los resultados del CCI obtenidos por cada una de las duplas se procede con la extracción de las conclusiones. En primer lugar, se comienza con los comentarios sobre los resultados de la clasificación de las heces líquidas:

1. El CCI obtenido por ambos especialistas (dupla [E1, E2]) en la clasificación de las heces líquidas es de 0.653, por lo que el tipo de correlación existente entre ellos es media. Mediante este resultado se confirma que no existe una gran analogía entre ellos en la clasificación de este tipo de heces.

2. El CCI obtenido en la clasificación de las heces líquidas por la pareja formada por el especialista 1 y el método propuesto (dupla [E1, MP]) es de 0.26. Esta correlación es muy baja, por lo que existe poca reciprocidad entre las valoraciones de ambos grupos.

3. El CCI obtenido en la clasificación de las heces líquidas por la pareja formada por el especialista 1 y la realidad (dupla [E1, R]) es de 0.388. Esta correlación es baja, de forma que no se ha realizado una clasificación de gran concordancia respecto a la realidad.

4. El CCI obtenido en la clasificación de las heces líquidas por la pareja formada por el especialista 2 y el método propuesto (dupla [E2, MP]) es de 0.297. Este resultado indica que, al igual que en la pareja formada por el especialista 1 y el método propuesto, ambos muestran una correlación muy baja respecto al método propuesto, siendo menor en el caso del especialista 1 (CCI = 0.26 para la dupla [E1, MP]).

5. El CCI obtenido en la clasificación de las heces líquidas por la pareja formada por el especialista 2 y la realidad (dupla [E2, R]) es de 0.305. Este resultado indica una correlación baja respecto a la realidad, además de confirmar que los porcentajes de heces líquidas proporcionados por el especialista 2 son menos análogos a la realidad que los del especialista 1 (CCI = 0.388 para la dupla [E1, R]).

6. El CCI obtenido en la clasificación de las heces líquidas por la pareja formada por el método propuesto y la realidad (dupla [MP, R]) es de 0.744. Este valor sugiere una alta correspondencia, superando la conseguida por ambos especialistas (CCI = 0.388 y CCI = 0.305 para las duplas [E1, R] y [E2, R]).

En segundo lugar se procede a describir las conclusiones obtenidas sobre la clasificación de las heces tintadas:

1. El CCI obtenido por ambos especialistas (dupla [E1, E2]) en la clasificación de las heces tintadas es de 0.342, por lo que el tipo de correlación existente entre ellos es baja. Mediante este resultado se confirma la poca reciprocidad en la clasificación de este tipo de heces, siendo en este caso menor que en las heces líquidas (CCI = 0.653 para la dupla [E1, E2]).

2. El CCI obtenido en la clasificación de las heces tintadas por la pareja formada por el especialista 1 y el método propuesto (dupla [E1, MP]) es de 0.372. Esta correlación es baja, por lo que existe una disparidad de criterios entre las valoraciones de ambos grupos. Por otra parte, en comparación al resultado obtenido por esta dupla en el caso de las heces líquidas (CCI = 0.26 para la dupla [E1, MP]), el índice ha sido más alto para el caso de las heces tintadas.

3. El CCI obtenido en la clasificación de las heces tintadas por la pareja formada por el especialista 1 y la realidad (dupla [E1, R]) es de 0.382. Esta correlación es baja, de forma que no se ha obtenido una buena analogía respecto a la realidad. En cuanto a los resultados obtenidos por esta dupla en el caso de las heces líquidas (CCI = 0.388 para la dupla [E1, R]), estos han sido peores que en el caso de las heces tintadas.

4. El CCI obtenido en la clasificación de las heces tintadas por la pareja formada por el especialista 2 y el método propuesto (dupla [E2, MP]) es de 0.349. Este resultado indica que, al igual que en la dupla especialista 1 y método propuesto (CCI = 0.372, para la dupla [E1, MP]), ambos grupos muestran una correlación baja respecto al método propuesto, siendo mayor en el caso del especialista 1. En comparación con el resultado obtenido por esta dupla en el caso de las heces líquidas (CCI = 0.297 para la dupla [E2, MP]), los resultados han sido más altos en el caso de las heces tintadas.

5. El CCI obtenido en la clasificación de las heces tintadas por la pareja formada por el especialista 2 y la realidad (dupla [E2, R]) es de 0.313. Este resultado indica una correlación baja respecto a la realidad, además de confirmar que los porcentajes de heces tintadas proporcionados por el especialista 1 tienen más analogía respecto a la realidad que los del especialista 2 (CCI = 0.382 para la dupla [E1, R]). En cuanto a los resultados ofrecidos por esta dupla

en las heces líquidas (CCI = 0.305 para la dupla [E2, R]), los resultados han sido más altos en el caso de las tintadas.

6. El CCI obtenido en la clasificación de las heces tintadas por la pareja formada por el método propuesto y la realidad (dupla [MP, R]) es de 0.981. Esta puntuación indica una correlación muy alta con la realidad que supera la conseguida por ambos especialistas (CCI = 0.382 y CCI = 0.313 para las duplas [E1, R] y [E2, R]). Centrándonos en la comparativa con los resultados obtenidos por esta dupla en las heces líquidas (CCI = 0.744 para la dupla [MP, R]), los resultados han sido más altos en el caso de las heces tintadas.

Para finalizar, en tercer lugar se procede a detallar las conclusiones extraídas de la clasificación de las heces sólidas:

1. El CCI obtenido por ambos especialistas (dupla [E1, E2]) en la clasificación de las heces sólidas es de 0.435, por lo que el tipo de correlación existente entre ellos es baja. Este resultado indica cierto grado de concordancia en las valoraciones de los porcentajes de heces sólidas proporcionados por ellos. En comparación a los resultados obtenidos por esta dupla en las heces líquidas y tintadas (CCI = 0.653 y CCI = 0.342 para la dupla [E1, E2]), las heces sólidas han obtenido un valor intermedio a ellos.

2. El CCI obtenido en la clasificación de las heces sólidas por la pareja formada por el especialista 1 y el método propuesto (dupla [E1, MP]) es de 0.639. Esta correlación es media, por lo que existe cierta unidad de criterios entre las valoraciones de ambos grupos. Respecto al CCI obtenido por esta dupla en los diferentes tipos de heces, el grado de correlación ha sido mayor que en el caso de las heces líquidas y tintadas (CCI = 0.26 y CCI = 0.372 para la dupla [E1, MP]).

3. El CCI obtenido en la clasificación de las heces sólidas por la pareja formada por el especialista 1 y la realidad (dupla [E1, R]) es de 0.598. Esta correlación es media, de forma que ha obtenido cierta analogía con la realidad, siendo ésta más alta que en el caso de las heces líquidas y tintadas (CCI = 0.388 y CCI = 0.382 para la dupla [E1, R]).

4. El CCI obtenido en la clasificación de las heces sólidas por la pareja formada por el especialista 2 y el método propuesto (dupla [E2, MP]) es de 0.416 lo que se corresponde con una baja correlación. Este resultado indica que el especialista 2 ha obtenido una menor analogía respecto al método propuesto que la conseguida por el especialista 1 (CCI = 0.639 para la dupla [E1, MP]). Comparando los resultados de este tipo de heces con los demás tipos, el grado de correlación ha sido más alto que en el caso de las heces líquidas y tintadas (CCI = 0.297 y CCI = 0.349 para la dupla [E2, MP]).

5. El CCI obtenido en la clasificación de las heces sólidas por la pareja formada por el especialista 2 y la realidad (dupla [E2, R]) es de 0.338. Este resultado indica una correlación baja respecto a la realidad, además de confirmar que los porcentajes de heces tintadas proporcionados por el especialista 1 (CCI = 0.598 para la dupla [E1, R]) están más alineados con la realidad que los del especialista 2. Por otra parte, los resultados del CCI de esta dupla han sido mayores que en el caso de las heces líquidas y tintadas (CCI = 0.305 y CCI = 0.313 para la dupla [E2, R]).

6. El CCI obtenido en la clasificación de las heces sólidas por la pareja formada por el método propuesto y la realidad (dupla [MP, R]) es de 0.942. Esta puntuación indica una correlación muy alta lo que supone una alta concordancia que supera a la conseguida por ambos especialistas (CCI = 0.598 y CCI = 0.338 para las duplas [E1, R] y [E2, R]). Respecto a los resultados del CCI de esta dupla en los diferentes tipos de heces, se ha conseguido un valor intermedio a las heces líquidas y tintadas (CCI = 0.744 y CCI = 0.981 para la dupla [MP, R]).

A modo general, las conclusiones globales que se pueden extraer de este último análisis vuelven a confirmar la baja concordancia entre los porcentajes de los diferentes tipos de heces proporcionados por ambos especialistas ($CCI_{Líquidas}$ = 0.653, $CCI_{Tintadas}$ = 0.342 y $CCI_{Sólidas}$ = 0.435 para la dupla [E1, E2]), existiendo correlaciones medias y bajas entre ambos. Además, se corrobora la validez del sistema de clasificación diseñado, el cual ha obtenido en todos los casos unos valores del CCI altos o muy altos respecto a la realidad ($CCI_{Líquidas}$ = 0.744, $CCI_{Tintadas}$ = 0.981 y

$CCI_{Sólidas}$ = 0.942 para la dupla [MP, R]), superando los resultados obtenidos por los especialistas.

Análisis de las tasas de error en los porcentajes de cada tipo de heces detectados

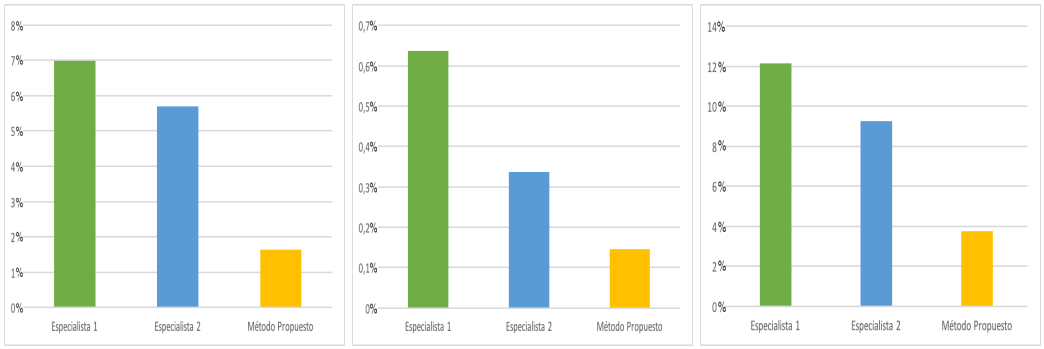
Como último análisis del sistema de clasificación de heces diseñado se procede a realizar un estudio de los errores cometidos en la determinación de los diferentes porcentajes de heces. Mediante este proceso se proporcionarán datos numéricos que ayudarán en la interpretación de los resultados. Al igual que en los casos anteriores el error es determinado por la ecuación 4.8 e indica la desviación sufrida por cada evaluador respecto al porcentaje real de cada tipo de heces. Para comenzar, en la tabla 5.8 se muestran los resultados del análisis del error en la clasificación de las heces líquidas.

Tabla 5.8: Resultados obtenidos en el análisis de los errores cometidos por los especialistas y el método propuesto en la determinación de las heces líquidas.

	EAM $\mathbf{H_{Líquidas}}$	$\mathbf{M_e}$ $\mathbf{H_{Líquidas}}$	σ $\mathbf{H_{Líquidas}}$
E1	6.97 %	0.64 %	12.14 %
E2	5.71 %	0.34 %	9.26 %
MP	**1.64 %**	**0.14 %**	**3.75 %**

Para mostrar de forma gráfica la representación de los resultados del error de la detección de las heces liquidas se proporciona la figura 5.4. Ésta muestra unos diagramas de barras comparando el EAM, mediana y desviación típica del error obtenido por el especialista 1, el especialista 2 y el método propuesto.

Los resultados cosechados para el análisis de los errores en la clasificación de las heces líquidas por parte de los especialistas y el método propuesto indican la alta precisión conseguida por este último. Centrándonos en el EAM, los especialistas 1 y 2 han obtenido unos valores de un 6.97 % y de un 5.71 % de forma respectiva, siendo de un 1.64 % para el método que se propone. Esto supone una reducción del EAM que se corresponde con una diferencia de un 5.33 % respecto al especialista



(a) (b) (c)

Figura 5.4: Análisis de los errores de los porcentajes de heces líquidas determinados por los especialistas y el método propuesto.

1 y de un 4.07 % respecto al especialista 2. Pasando a examinar la mediana del error, los especialistas 1 y 2 han obtenido unas valoraciones de un 0.64 % y de un 0.34 %, siendo de un 0.14 % para el diseño llevado a cabo. Esto indica una reducción de la mediana del error que se traduce en una diferencia de un 0.5 % respecto al especialista 1 y de un 0.2 % respecto al especialista 2. Para finalizar, la desviación típica del error para los especialistas 1 y 2 se sitúa en un 12.14 % y en un 9.26 % de forma respectiva, obteniéndose un valor de un 3.75 % para el método propuesto. Esto supone una reducción de este índice, correspondiéndose con una diferencia de un 8.39 % respecto al especialista 1 y de un 5.51 % respecto al especialista 2. Gracias a estos resultados se demuestra que los algoritmos diseñados para la clasificación de las heces líquidas son más eficaces que los especialistas. Esto puede verse en el EAM, la mediana del error y la desviación típica del error, quienes han sido menores que en el caso de los especialistas, lo que es deseable.

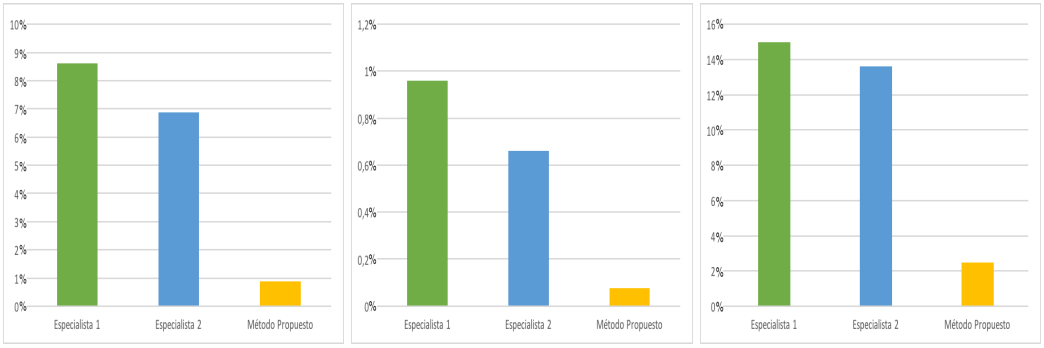
Continuando con el análisis del error de la clasificación de las heces tintadas, en la tabla 5.9 se muestran los resultados obtenidos.

Para exponer de forma gráfica la representación de los resultados del error en la detección de las heces tintadas se proporciona la figura 5.5 que muestra unos diagramas de barras comparando el EAM, mediana y desviación típica del error obtenidos por el especialista 1, el especialista 2 y el método propuesto.

Los resultados logrados para el análisis de los errores cometidos en la clasificación de las heces tintadas por parte de los especialistas y el método propuesto

Tabla 5.9: Resultados obtenidos en el análisis de los errores cometidos por los especialistas y el método propuesto en la determinación de las heces tintadas.

	EAM $\mathbf{H_{Tintadas}}$	$\mathbf{M_e}$ $\mathbf{H_{Tintadas}}$	σ $\mathbf{H_{Tintadas}}$
E1	8.62 %	0.96 %	14.99 %
E2	6.89 %	0.66 %	13.62 %
MP	**0.87 %**	**0.08 %**	**2.49 %**



(a) (b) (c)

Figura 5.5: Análisis de los errores de los porcentajes de heces tintadas determinados por los especialistas y el método propuesto.

indican, al igual que en el caso de las heces líquidas, la alta precisión del sistema diseñado. Comenzando por el EAM, los especialistas 1 y 2 han obtenido unos valores de un 8.62 % y de un 6.89 % de forma respectiva, siendo de un 0.87 % para el método que se propone. Esto supone una reducción del EAM que se traduce en una diferencia de un 7.75 % respecto al especialista 1 y de un 6.02 % respecto al especialista 2. Continuando con la mediana del error, los especialistas 1 y 2 han obtenido unas valoraciones de un 0.96 % y de un 0.66 %, siendo de un 0.08 % para el diseño llevado a cabo. De esta forma se presenta una reducción que se traduce en una diferencia de un 0.88 % y un 0.58 % respecto a los especialistas 1 y 2. Por último, la desviación típica del error para los especialistas 1 y 2 se sitúa en un 14.99 % y en un 13.62 % de forma respectiva, obteniéndose un valor de un 2.49 % para el método propuesto. Esto supone una reducción que se corresponde con una

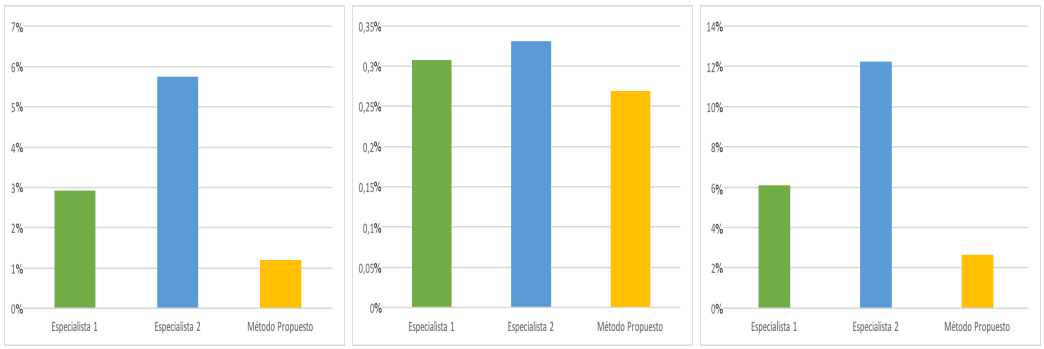
diferencia de un 12.5 % respecto al especialista 1 y de un 11.13 % respecto al especialista 2. Estos resultados evidencian la efectividad de la clasificación de las heces tintadas llevada a cabo, que además de obtener un error menor, su desviación típica también lo es.

Para finalizar, se procede con el análisis del error de la clasificación de las heces sólidas. En la tabla 5.10 se muestran los resultados obtenidos.

Tabla 5.10: Resultados obtenidos en el análisis de los errores cometidos por los especialistas y el método propuesto en la determinación de las heces sólidas.

	EAM $\mathbf{H_{Sólidas}}$	$\mathbf{M_e}$ $\mathbf{H_{Sólidas}}$	σ $\mathbf{H_{Sólidas}}$
E1	2.93 %	0.31 %	6.09 %
E2	5.75 %	0.33 %	12.25 %
MP	**1.19 %**	**0.27 %**	**2.64 %**

Para mostrar de forma gráfica la representación de los resultados del análisis del error en la detección de las heces sólidas se proporciona la figura 5.6 que contiene, al igual que en los casos anteriores, unos diagramas de barras comparando el EAM, mediana y desviación típica del error obtenido por el especialista 1, el especialista 2 y el método propuesto.



(a) (b) (c)

Figura 5.6: Análisis de los errores de los porcentajes de heces sólidas determinados por los especialistas y el método propuesto.

En lo referente a los resultados obtenidos en el análisis de los errores de la clasificación de las heces sólidas, se confirma al igual que en el caso de las heces líquidas y tintadas la alta precisión del sistema diseñado. En primer lugar, analizando el EAM, los especialistas 1 y 2 han obtenido unos valores de un 2.93 % y de un 5.75 % de forma respectiva, siendo de un 1.19 % para el método que se propone. En ambos casos esto supone una reducción del EAM que se corresponde con una diferencia de un 1.74 % respecto al especialista 1 y de un 4.56 % respecto al especialista 2. En segundo lugar, en lo referente a la mediana del error, los especialistas 1 y 2 han obtenido unas valoraciones de un 0.31 % y de un 0.33 %, siendo de un 0.27 % para el diseño llevado a cabo. Esto se traduce en una reducción de este indicador que se corresponde con unas diferencias de un 0.04 % y de un 0.06 % respecto a los especialistas 1 y 2. Por último y en tercer lugar, la desviación típica del error para los especialistas 1 y 2 se sitúa en un 6.09 % y en un 12.25 % de forma respectiva, obteniéndose un valor de un 2.64 % para el método propuesto. Esto supone una reducción de la desviación típica del error que se corresponde con una diferencia de un 3.45 % respecto al especialista 1 y de un 9.61 % respecto al especialista 2. Estos resultados confirman la efectividad de la clasificación de las heces sólidas diseñada, que obtiene un menor EAM, mediana y desviación del error que los especialistas.

Como conclusión global, se confirma que el sistema de clasificación de heces propuesto es eficaz. Muestra de ello es el EAM, mediana y desviación típica del error obtenido en todos y cada uno de los tipos de heces. De esta forma se pretende validar la clasificación de las heces propuesta, que es la base para el cálculo de la ELCB. Gracias a las verificaciones realizadas sobre los algoritmos de detección y clasificación de las heces se puede afrontar el cálculo de la misma con garantías.

5.2.1.3 **Análisis de resultados de la precisión del cálculo de la ELCB diseñado (R3)**

La evaluación de la precisión del cálculo de la ELCB es el último bloque correspondiente a la extracción de resultados del sistema de evaluación de la calidad de preparación del colon. El buen funcionamiento y buenos resultados del mismo vienen determinados por la detección y clasificación de heces diseñada, las cuales ya han sido analizadas alcanzando resultados satisfactorios. En la actualidad no existe

sistema alguno que realice un cálculo automático de la ELCB, por lo que el planteamiento de un sistema de evaluación es complicado. Gracias a la colaboración de expertos endoscopistas se ha creado un protocolo para el cálculo de la ELCB, el cual se mostraba en la figura 4.44. A partir de la valoración obtenida se han definido conjuntamente unos rangos que determinarán la puntuación de la ELCB, estos se muestran en la tabla 5.11.

Tabla 5.11: Rangos de las valoraciones definidas para el cálculo de la ELCB.

Rango de valoración	**Puntuación ELCB**
0 <= Valoración <= 7	3
8 <= Valoración <= 30	2
31 <= Valoración <= 65	1
66 <= Valoración <= 100	0

Hay que tener en cuenta que al no existir método alguno con el que contrastar la veracidad de las valoraciones de la ELCB generadas, se tomará como valoración real aquella conseguida mediante la ecuación representada en la figura 4.44, haciendo uso de los porcentajes de cada tipo de heces segmentados manualmente (considerados reales y validados por los especialistas) para cada una de las imágenes. Por lo tanto, para el presente análisis se dispone de los siguientes datos:

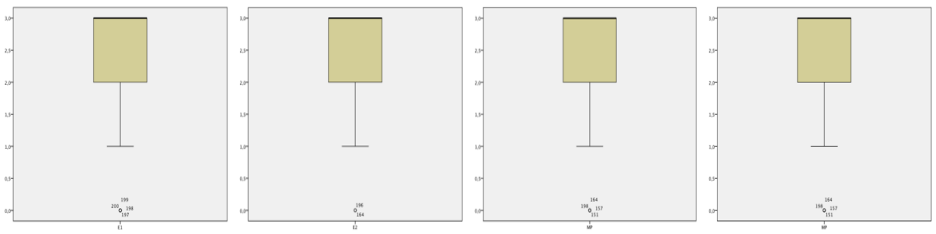
- Valoración de la ELCB determinada por el especialista 1 para cada una de las 200 imágenes a evaluar.
- Valoración de la ELCB determinada por el especialista 2 para cada una de las 200 imágenes a evaluar.
- Valoración de la ELCB determinada por el sistema diseñado para cada una de las 200 imágenes a evaluar.
- Valoración de la ELCB calculada mediante el método propuesto haciendo uso de las segmentaciones manuales de cada tipo de heces en las 200 imágenes a evaluar.

En el siguiente apartado se comienza con el análisis de la normalidad del conjunto de datos, el cual nos determinará el tipo de distribución de los mismos, así como el tipo de métodos estadísticos a utilizar.

Determinación de la normalidad del conjunto de datos

La evaluación del sistema de cálculo de la ELCB diseñado comienza con la determinación del tipo de distribución que siguen los datos a tratar. Para ello se ha usado el test de normalidad de Kolmogorov-Smirnov.

Se han obtenido unos valores de significancia $p = 0$ para todos los grupos, por lo que presentan una distribución no normal. Por este motivo se aplicará el test no paramétrico de la suma de rangos por parejas de Wilcoxon para evaluar las diferencias significativas de cada una de las duplas formadas entre el especialista 1, el especialista 2, el método propuesto y la realidad. Para ver de una forma gráfica la representación de los datos se añade la figura 5.7.



(a) (b) (c) (d)

Figura 5.7: Distribución de las valoraciones de la ELCB a analizar. a) Datos del especialista 1. b) Datos del especialista 2. c) Datos del método propuesto. d) Datos de las valoraciones reales.

Los valores del estadístico Kolmogorov-Smirnov y las significancias obtenidas por los diferentes grupos pueden verse en la tabla 5.12.

Tras haber realizado el análisis de la normalidad de los datos se procede a abordar el análisis estadístico entre grupos. Éste se presenta en el siguiente apartado.

Tabla 5.12: Valores y significancia del test de Kolmogorov-Smirnov.

	K-S	*p*
E1	0.413	0
E2	0.337	0
Mp	0.366	0
R	0.345	0

Análisis estadístico por parejas de las puntuaciones de la ELCB obtenidas

Teniendo en cuenta que la evaluación de la calidad de preparación del colon mediante la ELCB es subjetiva, se ha decidido diseñar un sistema para su cálculo. Éste se basa en parámetros objetivos y cuantificables, de forma que permite la estandarización de la escala. Para poder validar los algoritmos desarrollados se hará uso del test de la suma de rangos por parejas de Wilcoxon. De esta forma se podrá determinar si las puntuaciones de la ELCB proporcionadas por los especialistas, el método propuesto y la valoración real pertenecen a una misma distribución y en qué grado. El análisis ha sido realizado, al igual que en análisis anteriores, mediante la aplicación del test a todo el conjunto de duplas posibles entre grupos disponibles. Los resultados obtenidos se muestran en la tabla 5.13

Tabla 5.13: Resultados del test de la suma de rangos por parejas de Wilcoxon para las puntuaciones de la ELCB obtenidas.

Dupla	*p*
[E1, E2]	0
[E1, MP]	0.021
[E1, R]	0
[E2, MP]	0
[E2, R]	0.01
[MP, R]	**0.086**

En base a los resultados obtenidos se extraen una serie de conclusiones sobre la metodología empleada para el cálculo de la ELCB por parte de los especialistas y el método propuesto. Éstas se describen a continuación:

1. Las valoraciones de la ELCB proporcionadas por los especialistas 1 y 2 (dupla [E1, E2]) han obtenido una significancia $p = 0$, por lo que existen diferencias significativas entre ellas. De esta forma se confirma la subjetividad de la ELCB que está sujeta a la interpretación del especialista.

2. Las valoraciones de la ELCB proporcionadas por el especialista 1 y el método propuesto (dupla [E1, MP]) han obtenido una significancia $p = 0.021$, por lo que existe una diferencia significativa entre ellos.

3. Las valoraciones de la ELCB proporcionadas por el especialista 1 y las reales (dupla [E1, R]) han obtenido una significancia $p = 0$, por lo que existen diferencias significativas entre ambos grupos. Este resultado confirma la gran disconformidad entre las valoraciones observadas por el especialista y aquellas supuestas como reales.

4. Las valoraciones de la ELCB proporcionadas por el especialista 2 y el método propuesto (dupla [E2, MP]) han obtenido una significancia $p = 0$ por lo que, al igual que en el caso del especialista 1 existen diferencias significativas entre ellas. Esto es un indicador de la disimilitud existente entre el modo de calculo de la ELCB por parte del especialista 2 y el método propuesto. Por otra parte, se determina que las puntuaciones obtenidas por el método propuesto son más cercanas a las del especialista 1 ($p = 0.021$ para la dupla [E1, MP]) que a las del especialista 2.

5. Las valoraciones de la ELCB proporcionadas por el especialista 2 y las reales (dupla [E2, R]) han obtenido una significancia $p = 0.01$. De igual forma que en el caso del especialista 1, existen diferencias significativas con la ELCB real. A partir de la significancia obtenida se puede determinar que el especialista 2 ha obtenido mejores resultados que el especialista 1 ($p = 0$ para la dupla [E1, R]).

6. Las valoraciones de la ELCB proporcionadas por el método propuesto y las reales (dupla [MP, R]) han obtenido una significancia $p = 0.086$. Esto indica que no existen diferencias significativas entre ellas. Como puede verse, es el único de los casos en el que se ha conseguido una $p > 0.05$, lo que indica

unos mejores resultados que en el caso de los especialistas ($p = 0$ y $p = 0.01$ para las duplas [E1, R] y [E2, R]).

A partir de los resultados obtenidos del test de la suma de rangos por parejas de Wilcoxon para las valoraciones de la ELCB, se ha confirmado la baja concordancia entre las valoraciones proporcionadas por los especialistas ($p = 0$ para la dupla [E1, E2]). Además, se ha demostrado que el método propuesto ha obtenido unos mejores resultados ($p = 0.086$ para la dupla [MP, R]) que ambos especialistas ($p = 0$ y $p = 0.01$ para las duplas [E1, R] y [E2, R]) ya que su significancia respecto a la realidad ha sido mayor. Esto es probablemente debido a que se basa en el sistema de rangos propuesto en la tabla 5.11, los cuales han sido definidos por los especialistas, pero que no son utilizados mentalmente por ellos en la realización de las evaluaciones ya que se basan en su experiencia.

Análisis del CCI para las puntuaciones de la ELCB obtenidas

Siguiendo con el protocolo de evaluación establecido, tras comprobar las diferencias significativas entre las valoraciones de la ELCB proporcionadas por los especialistas y el método propuesto, se procede a realizar el análisis del CCI. Al igual que en los anteriores análisis, se pretende valorar el grado de correlación existente entre los grupos. En la tabla 5.14 se muestran los resultados obtenidos por el CCI para las diferentes parejas de grupos disponibles.

Tabla 5.14: Resultados obtenidos por el CCI para las valoraciones de la ELCB de todas las duplas de grupos disponibles.

Dupla	CCI	Grado
[E1, E2]	0.758	Alta
[E1, MP]	0.653	Media
[E1, R]	0.648	Media
[E2, MP]	0.701	Alta
[E2, R]	0.719	Alta
[MP, R]	**0.921**	**Muy alta**

Una vez presentados los resultados obtenidos por el CCI se lleva a cabo una descripción de las conclusiones extraídas:

1. El CCI obtenido por ambos especialistas (dupla [E1, E2]) es de 0.758. Este valor indica una alta correlación, a pesar de existir diferencias significativas entre ambos ($p = 0$ para la dupla [E1, E2]). Esto indica una homogeneidad a la hora de realizar el cálculo de la ELCB, a pesar de que su significancia a la hora de determinar los porcentajes de heces en las imágenes haya sido muy baja ($p = 0$ en las heces líquidas, $p = 0.531$ en las heces tintadas y $p = 0.03$ en las heces sólidas para la dupla [E1, E2]). Estos resultados refuerzan la hipótesis de que los especialistas no siguen un sistema de reglas como el que se ha planteado en este trabajo (figura 4.44) y es lo que ha conseguido una buena correlación entre ambos.

2. El CCI obtenido por la pareja formada por el especialista 1 y el método propuesto (dupla [E1, MP]) es de 0.653. Esto indica una correlación media entre las valoraciones obtenidas por ambos grupos.

3. El CCI obtenido por la pareja formada por el especialista 1 y la realidad (dupla [E1, R]) es de 0.648. Se trata de una correlación media con los resultados de la ELCB tomados como reales, por lo que existe cierta concordancia entre ambos grupos.

4. El CCI obtenido por la pareja formada por el especialista 2 y el método propuesto (dupla [E2, MP]) es de 0.701. Este resultado supone una alta correlación entre las valoraciones de la ELCB de ambos grupos, la cual es superior a la obtenida por el especialista 1 (CCI = 0.653 para la dupla [E1, MP]).

5. El CCI obtenido por la pareja formada por el especialista 2 y la realidad (dupla [E2, R]) es de 0.719. Esta correlación es alta por lo que existe una gran armonía entre las valoraciones reales de la ELCB y las proporcionadas por el especialista 2. Es preciso destacar que han obtenido unos resultados con una mayor correlación que en el caso del especialista 1 (CCI = 0.648 para la dupla [E1, R]).

6. El CCI obtenido por la pareja formada por el método propuesto y la realidad (dupla [MP, R]) es de 0.921. Esta puntuación indica una correlación muy alta, superior a la de los especialistas (CCI = 0.648 y CCI = 0.719 para las duplas [E1, R] y [E2, R]), demostrando la mayor analogía con las valoraciones reales de la ELCB.

A modo de conclusiones finales, en primer lugar, la correlación obtenida entre los especialistas es alta (CCI = 0.758 para la dupla [E1, E2]) por lo que siguen una serie de criterios comunes a la hora de realizar las valoraciones. En segundo lugar, se confirma que a pesar de la disparidad de criterios a la hora de detectar los diferentes tipos de heces por parte de los especialistas, estos han conseguido una correlación media (CCI = 0.648 para la dupla [E1, R]) y alta (CCI = 0.719 para la dupla [E2, R]) de forma respectiva con la ELCB real. Esto es un indicativo de que han realizado unas buenas valoraciones y que éstas pueden ser utilizadas para el análisis. En tercer lugar, se ha demostrado la existencia de una mayor correlación del método propuesto con el especialista 2 (CCI = 0.701 para la dupla [E2, MP]), quien además también ha sido el especialista que ha conseguido una mayor correlación con los valores reales de la ELCB (CCI = 0.719 para la dupla [E2, R]). Por último y en cuarto lugar, de igual forma que en la detección y clasificación de heces, el sistema diseñado ha vuelto a demostrar una mayor eficacia logrando el valor más alto respecto a las valoraciones reales (CCI = 0.921 para la dupla [MP, R]).

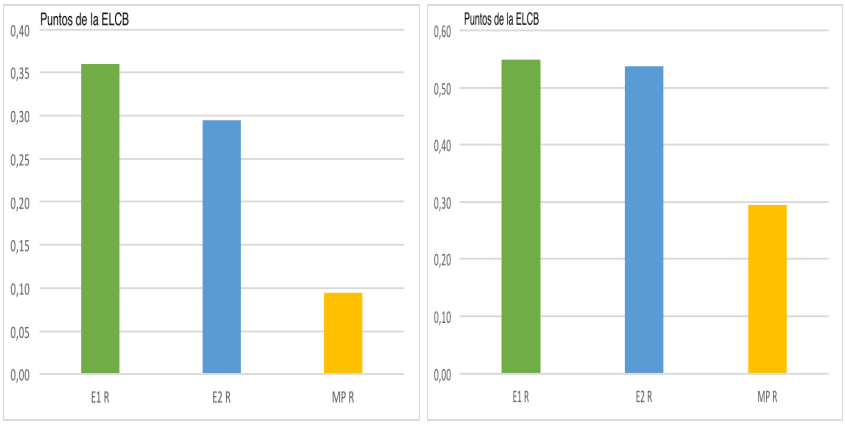
Análisis de las tasas de error en las puntuaciones de la ELCB obtenidas

En el presente análisis de las tasas de error se evaluarán las diferencias de ambos especialistas y el método propuesto con la considerada ELCB real. Mediante este proceso se pretende aportar datos cuantitativos que ayuden a una mejor interpretación de los resultados, haciendo a estos más intuitivos. De la misma forma que en ocasiones anteriores, el error es determinado por la ecuación 4.8 e indica la desviación sufrida por cada evaluador respecto a la puntuación real de la ELCB para cada una de las 200 imágenes evaluadas. Se proporciona el EAM y la desviación típica del error cometido por ambos especialistas y el método propuesto respecto a la ELCB real. Los resultados obtenidos son mostrados en la tabla 5.15.

Tabla 5.15: Resultados obtenidos para el análisis del error en las puntuaciones de la ELCB obtenidas por los especialistas y el método propuesto.

Dupla	**EAM**	σ
[E1,R]	0.36 puntos	0.55 puntos
[E2, R]	0.3 puntos	0.54 puntos
[MP, R]	**0.1** puntos	**0.29** puntos

Con el objetivo de mostrar de una forma más gráfica la representación de los resultados del error del cálculo de la ELCB, se proporciona la figura 5.8 que muestra unos diagramas de barras comparando el EAM y la desviación típica del error obtenidos por el especialista 1, el especialista 2 y el método propuesto respecto a la realidad.



(a) (b)

Figura 5.8: Análisis de los errores de las valoraciones de la ELCB proporcionadas por los especialistas y el método propuesto. a) Las gráficas verde, azul y amarillo corresponden al EAM del especialista 1, especialista 2 y el método propuesto respecto a la valoración real de la ELCB. b) Siguiendo la misma nomenclatura que el apartado a) se muestran las desviaciones típicas de los errores. La unidad de medida de ambas gráficas es representada en puntos de la ELCB.

En cuanto a los resultados obtenidos en el análisis de los errores de las puntuaciones de la ELCB, se verifica que el método propuesto es más preciso que ambos

especialistas. Por un lado, el EAM obtenido por los especialistas 1 y 2 se sitúa en 0.36 y 0.3 puntos (duplas [E1,R] y [E2, R]), siendo de 0.1 puntos para el método propuesto (dupla [MP, R]). Estos resultados se traducen en una mejora del EAM que se corresponde con una diferencia de 0.26 puntos respecto al especialista 1 y de 0.2 puntos respecto al especialista 2. Por otro lado, centrándonos en la desviación típica, los especialistas han obtenido unos valores de $\sigma = 0.55$ y de $\sigma = 0.54$ puntos (duplas [E1, R] y [E2, R]), siendo de $\sigma = 0.29$ puntos para el método propuesto (dupla [MP, R]). Estos resultados indican unas mejoras en la desviación típica del error que se corresponden con unas diferencias de 0.26 y 0.25 puntos respecto a los especialistas 1 y 2. Asimismo, se ha podido comprobar que el especialista 2 ha sido más fiel a las valoraciones reales que el especialista 1, ya que su EAM y desviación típica ha sido menor.

Una vez finalizado el análisis de las tasas de error en las puntuaciones de la ELCB obtenidas se puede dar por concluida la validación del sistema de evaluación de la calidad de preparación del colon. Habiéndose realizado un exhaustivo análisis de la precisión de la detección de heces diseñada, así como de su clasificación y del posterior cálculo de la ELCB, se ha dotado de validez al trabajo realizado. Mediante los resultados se ha probado una de las necesidades de las unidades de endoscopia, contar con herramientas capaces de evaluar la calidad de preparación del colon del paciente basándose en parámetros objetivos. Esto es debido a que se ha demostrado la subjetividad de las escalas utilizadas ($p = 0$ y CCI = 0.758 para la dupla [E1, E2]). A la vista de los resultados obtenidos en la detección de las heces, su clasificación y el calculo de la ELCB, se ha acreditado la eficacia del desarrollo llevado a cabo ($p = 0.086$ y CCI = 0.921 para la dupla [MP, R]), cumpliendo parte de la hipótesis planteada en la presente tesis doctoral. Ésta era la siguiente: “Es posible diseñar algoritmos de PDI que ayuden a la detección y segmentación automática de pólipos en imágenes colonoscópicas tras la verificación y evaluación de la calidad de preparación del colon del paciente.”

Para continuar, en el siguiente apartado se comparará el sistema diseñado con la única alternativa existente en el estado del arte.

5.2.1.4 **Comparativa del método de evaluación de la calidad del colon propuesto respecto a estudios del estado del arte**

Para finalizar el análisis de los resultados del sistema de evaluación de la calidad de preparación del colon propuesto se procede a realizar una comparativa con el único estudio existente en la literatura que trata una temática similar [MOT+12]. Esta publicación realiza un cálculo automático de la ELCB, aunque no tiene en cuenta una de las principales características de la escala, la clasificación de las heces. Como bien es sabido, el efecto que supone la presencia de las heces a la hora de evaluar la calidad de preparación del colon no es el mismo si se trata de heces líquidas, tintadas o sólidas. Por este motivo, en la presente investigación se ha diseñado junto a expertos endoscopistas un protocolo para la valoración automática de las heces, el cual puede verse en la figura 4.44. Además, para poder abordar la clasificación de las heces se ha diseñado un sistema de extracción y reducción de características, así como un sistema de clasificación. Mediante este desarrollo se ha hecho posible un cálculo más certero y fiel a la definición de la ELCB que la alternativa existente en la literatura.

Al margen de la baja fidelidad a la ELCB de la publicación mencionada, ésta a obtenido unos resultados con una menor precisión que el método propuesto en la presente tesis doctoral. Prueba de ello son los resultados obtenidos para el CCI, EAM y desviación típica del error respecto a las valoraciones de la ELCB reales. En la tabla 5.16 puede verse una comparativa de los resultados obtenidos por ambos sistemas.

Tabla 5.16: Comparativa de los resultados obtenidos por el sistema propuesto para el cálculo de la ELCB respecto a la alternativa existente en el estado del arte.

	[MOT+12]	**Método propuesto**
CCI	0.771	**0.921**
EAM	0.27 puntos	**0.1** puntos
σ	0.45 puntos	**0.29** puntos

En la comparativa puede observarse en primer lugar las diferencias existentes en el CCI, donde el método propuesto ha conseguido una correlación de grado muy

alto respecto a los valores reales (CCI = 0.921), mientras que el método ya existente obtiene una de grado alto (CCI = 0.771). Esto indica un incremento del CCI que se corresponde con una diferencia de 0.15 puntos respecto al método existente en la literatura, por lo que la eficacia del sistema diseñado queda demostrada para este índice. Continuando con el EAM, el sistema diseñado ha obtenido un valor de 0.1 puntos, mientras que su alternativa 0.27 puntos, por lo que la diferencia es apreciable. La reducción del EAM conseguida respecto a la publicación tratada se corresponde con una diferencia de 0.17 puntos, confirmando la eficacia mostrada por el CCI. Para finalizar, haciendo referencia a la desviación típica del error, el método propuesto ha obtenido un valor de 0.29 puntos, siendo de 0.45 puntos para su alternativa. Esto indica una reducción del mismo suponiendo una diferencia de 0.16 puntos respecto a dicho trabajo.

Gracias a la presente comparativa se demuestra la precisión del sistema de evaluación de la calidad de preparación del colon mediante la ELCB diseñado. En esta ocasión la comparativa ha sido respecto a la única alternativa existente en la literatura, obteniéndose unos resultados satisfactorios.

Siguiendo con el análisis de resultados, en los siguientes apartados se tratará de demostrar la eficacia del sistema de detección automática de pólipos diseñado, de forma que se pueda validar de forma completa la hipótesis de partida.

5.2.2 Análisis de la precisión del sistema de detección de pólipos diseñado

Debido a que uno de los principales objetivos de la presente tesis doctoral es el diseño y desarrollo de un sistema de detección automática de pólipos, es necesario evaluar la precisión del mismo. Para dotar de mayor robustez a este procedimiento se ha desarrollado un enfoque combinado, el cual analiza diversas propiedades de los bordes así como la textura de las imágenes. A partir de la combinación de ambos enfoques se consigue una alta efectividad. Para validar el desarrollo llevado a cabo se han propuesto los siguientes apartados: 5.2.2.1 ≪Análisis de la precisión de la clasificación mediante características de los bordes (R4)≫, 5.2.2.2 ≪Análisis de la precisión del área del pólipo detectada mediante el análisis de bordes (R5)≫, 5.2.2.3 ≪Análisis de la precisión de la detección de pólipos mediante el análisis de bordes

(R6)», 5.2.2.4 «Análisis de la precisión de la clasificación de las características de la textura (R7)», 5.2.2.5 «Análisis de la precisión del área del pólipo detectada mediante el análisis de la textura (R8)», 5.2.2.6 «Análisis de la eficacia de la detección de pólipos mediante el análisis de la textura (R9)», 5.2.2.7 «Análisis de la precisión del área del pólipo detectada mediante el análisis combinado (R10)», 5.2.2.8 «Análisis de la eficacia de la detección de pólipos mediante el análisis combinado (R11)» y 5.2.2.9 «Comparativa del método de detección automática de pólipos propuesto respecto a estudios del estado del arte».

5.2.2.1 **Análisis de la precisión de la clasificación mediante características de los bordes (R4)**

El primero de los enfoques utilizados para la detección de pólipos es el análisis de las propiedades de los bordes. Los pólipos generan unos contornos con unas cualidades únicas y diferentes al resto de los que aparecen en una imagen colonoscópica. Por este motivo, es de sentido común la detección de pólipos mediante este tipo de descriptores. Para poder demostrar la efectividad de las propiedades de los bordes extraídas se realiza el presente análisis. Para ello ha sido seleccionado un conjunto de 16 clasificadores diferentes mediante los cuales se ha efectuado una clasificación de las propiedades de los bordes extraídas de la base de datos *CVC Colon Database*. Las correspondencias entre los diminutivos y los nombres completos de los clasificadores mostrados en las tablas 5.18, 5.19, 5.20, 5.21, 5.22 y 5.23, pueden verse en la tabla 5.17.

La eficacia de la extracción de características y su clasificación dependerá de diversos factores, como por ejemplo: el poder discriminante de los descriptores, el clasificador utilizado y la dimensionalidad del conjunto de datos. Por este motivo se ha implementado un sistema de reducción de características, el cual se mostraba en la figura 4.38. Para poder medir, tanto la efectividad de las características extraídas de los bordes, como la eficacia del sistema de reducción de características diseñado, se plantea esta evaluación que cuenta con los siguientes datos:

- Conjunto de características extraídas de los bordes de las imágenes pertenecientes a la base de datos *CVC Colon Database*. Este conjunto de datos será denominado como conjunto original.

Tabla 5.17: Correspondencia de los diminutivos con los nombres de los clasificadores en las tablas de resultados.

Diminutivo	Nombre completo	Diminutivo	Nombre completo
Bayesnet	*Red bayesiana*	N. Bayes C.	*Naive Bayes complement*
N. Bayes	*Naive Bayes*	N. Bayes S.	*Naive Bayes simple*
N. Bayes U.	*Naive Bayes update*	Adab. M1	*Adaboost M1*
END	*END*	Filt. Class.	*Filtered classifier*
Multib. AB	*Multiboost AB*	One R	*One R*
Decision S.	*Decision stump*	J48	*J48*
J48 graft	*J48 graft*	Random F.	*Random forest*
Random T.	*Random tree*	Rep. Tree	*Repeated tree*

- Conjunto de características original reducido mediante la técnica ESME.
- Conjunto de características original reducido mediante la técnica ESAC.
- Conjunto de características original reducido mediante la técnica PCA.
- Conjunto de características original reducido mediante la combinación propuesta.

Tras describir el conjunto de datos que se manejará en el análisis se procede a clasificar cada uno de ellos mediante los 16 clasificadores elegidos. Para ello se ha hecho uso de una validación cruzada de 10 iteraciones. Se comenzará con la clasificación del conjunto de datos original, cuyos resultados se muestran en la tabla 5.18.

Los resultados extraídos de la clasificación del conjunto de datos original demuestran una alta efectividad, ya que varios de los clasificadores utilizados han obtenido unas tasas de acierto muy elevadas. Un ejemplo de ello son los métodos de tipo *bayesnet*, *END*, *filtered classifier*, *one R*, *J48*, *J48 graft*, *random forest*, *random tree* y *repeated tree* que han conseguido todos ellos unas tasas de acierto mayores a un 98 %. De entre ellos hay que destacar el método *random forest*, el cual ha conseguido la tasa de acierto más alta con un valor de un 99.2 %. Por otra

Tabla 5.18: Clasificación del conjunto original de las características extraídas de los bordes. De aquí en adelante las filas corresponderán a los diferentes clasificadores utilizados y las columnas a las diferentes métricas de evaluación de la clasificación, siendo Prec. la precisión, Sens. la sensibilidad, V-F el valor-F, ROC el área ROC, % el porcentaje de acierto, K el valor del estadístico Kappa y EAM el error absoluto medio.

Clasificador	Prec.	Sens.	V-F	ROC	%	K	EAM
Bayesnet	99 %	99 %	0.99	1	99.01 %	0.9778	0.0099
N. Bayes C.	57.1 %	46.8 %	0.47	0.52	46.82 %	0.0238	0.5318
N. Bayes	78.7 %	77.5 %	0.75	0.73	77.53 %	0.4198	0.225
N. Bayes S.	77 %	75.8 %	0.73	0.72	75.84 %	0.3643	0.2418
N. Bayes U.	78.7 %	77.5 %	0.75	0.73	77.53 %	0.4198	0.225
Adab. M1	82.7 %	81.7 %	0.8	0.86	81.73 %	0.5436	0.2564
END	98.7 %	98.7 %	0.99	0.99	98.67 %	0.9699	0.0173
Filt. Class.	98.6 %	98.6 %	0.99	1	98.6 %	0.9683	0.0155
Mutib. AB	82.6 %	81.7 %	0.8	0.86	81.73 %	0.5436	0.1817
One R	98.7 %	98.7 %	0.99	0.98	98.66 %	0.9697	0.0134
Decision S.	82.7 %	81.7 %	0.8	0.74	81.73 %	0.5436	0.297
J48	98.3 %	98.3 %	0.98	0.99	98.29 %	0.9611	0.024
J48 graft	98.1 %	98.1 %	0.98	0.99	98.08 %	0.9563	0.0261
Random F.	**99.2 %**	**99.2 %**	**0.99**	**1**	**99.2 %**	**0.9819**	**0.0116**
Random T.	99 %	99 %	0.99	0.99	99.01 %	0.9777	0.0094
Rep. Tree	98.5 %	98.5 %	0.99	0.99	98.49 %	0.9659	0.0209
Media	89.23 %	88.18 %	0.87	0.88	88.18 %	0.7242	0.1317

parte, el porcentaje de acierto medio se sitúa en un 88.18 %. A pesar de haber conseguido unos muy buenos resultados, es imprescindible abordar una reducción de las características, ya que será más sencillo el manejo de los datos, más rápido el entrenamiento de los clasificadores y más eficaz la clasificación. Por este motivo se han utilizado diversas técnicas de reducción, cada una de ellas con sus ventajas e inconvenientes, con la intención de mejorar el proceso de clasificación.

Comenzando con los métodos de reducción de características, en primer lugar se ha hecho uso del método ESME. Éste utiliza internamente un clasificador

para conseguir el conjunto de características más óptimo para él. En este caso ha sido aplicado dicho método utilizando internamente cada uno de los clasificadores usados en las clasificaciones. Tras realizar la reducción se han conseguido los resultados mostrados por la tabla 5.19.

Tabla 5.19: Clasificación del conjunto de las características de los bordes reducidas mediante la técnica ESME.

Clasificador	Prec.	Sens.	V-F	ROC	%	K	EAM
Bayesnet	99.2 %	99.2 %	0.99	1	99.17 %	0.9814	0.0083
N. Bayes C.	76.7 %	77.1 %	0.76	0.7	77.09 %	0.4328	0.2291
N. Bayes	81.5 %	81.5 %	0.81	0.87	81.5 %	0.551	0.1929
N. Bayes S.	81.5 %	81.5 %	0.81	0.87	81.5 %	0.551	0.1929
N. Bayes U.	81.5 %	81.5 %	0.81	0.87	81.5 %	0.551	0.1929
Adab. M1	82.8 %	81.9 %	0.81	0.9	81.89 %	0.5482	0.2347
END	98.3 %	98.3 %	0.98	0.99	98.29 %	0.9611	0.024
Filt. Class.	98.7 %	98.7 %	0.99	1	98.67 %	0.9701	0.0161
Multib. AB	82.7 %	81.7 %	0.8	0.76	81.74 %	0.5438	0.1838
One R	98.7 %	98.7 %	0.99	0.98	98.67 %	0.9699	0.0133
Decision S.	82.7 %	81.7 %	0.8	0.74	81.73 %	0.5436	0.297
J48	98.7 %	98.7 %	0.99	0.99	98.67 %	0.9699	0.0173
J48 graft	98.3 %	98.3 %	0.98	0.99	98.32 %	0.9618	0.02
Random F.	**99.3 %**	**99.3 %**	**0.99**	**1**	**99.31 %**	**0.9844**	**0.0108**
Random T.	99 %	99 %	0.99	0.99	99.04 %	0.9782	0.0092
Rep. Tree	98.6 %	98.6 %	0.99	0.99	98.59 %	0.968	0.0194
MEDIA	91.14 %	90.98 %	0.9	0.91	90.98 %	0.7791	0.1039

Los resultados arrojados por la clasificación del conjunto de datos reducido mediante la técnica ESME han sido satisfactorios, ya que los clasificadores *bayesnet*, *END*, *filtered classifier*, *one R*, *J48*, *J48 graft*, *random forest*, *random tree* y *repeated tree* han conseguido tasas de acierto superiores a un 98 %. Entrando más en detalle, el clasificador *random forest* ha sido quien ha conseguido una mayor tasa de acierto, fijándola en un 99.31 %.

Comparando los resultados obtenidos por esta técnica con la clasificación del

conjunto original, puede verse el aumento en el porcentaje de acierto medio que sube desde un 88.18 % a un 90.98 %. La diferencia de un 2.8 % puede parecer baja, pero hay que tener en cuenta que es común que una imagen colonoscópica disponga de más de 50 contornos, por lo que cualquier incremento en la precisión es indispensable. De igual forma que en el caso anterior se demuestra el poder descriptivo de las características obtenidas mediante la reducción basada en la técnica ESME.

Continuando con los métodos de reducción de características aplicados se procede a mostrar los resultados obtenidos mediante la reducción de características haciendo uso del método ESAC. Éste evalúa individualmente los descriptores eligiendo aquellos más discriminantes y con menos correlación con los demás. Los resultados obtenidos por este método pueden verse en la tabla 5.20.

La reducción de características realizada por este método es, de igual forma que en el caso de la técnica ESME, efectiva. En este caso los clasificadores *bayesnet*, *END*, *filtered classifier*, *one R*, *J48*, *J48 graft*, *random forest*, *random tree* y *repeated tree* han obtenido unas tasas de acierto superiores a un 98.5 %. En cuanto al método de clasificación más efectivo *bayesnet* ha sido el más preciso con una tasa de acierto de un 99.45 %. En comparación a la clasificación del conjunto original de datos se ha conseguido incrementar la tasa de acierto media desde un 88.18 % a un 91.29 %, lo que corresponde a una diferencia de un 3.11 %. Respecto a la reducción llevada a cabo mediante el método ESME, las diferencias son mínimas ya que la tasa de acierto media de éste se situaba en un 90.98 %, lo que se corresponde con una diferencia de un 0.31 %. Los resultados obtenidos aseguran la utilidad del conjunto de características obtenidas mediante esta reducción, asegurando una correcta detección de los contornos pertenecientes a los pólipos.

La última técnica de selección de características aplicada al conjunto de datos manejado es PCA. Se trata de una técnica estadística que realiza una reducción de la dimensionalidad perdiendo el mínimo de información posible. Los resultados obtenidos por esta técnica se muestran en la tabla 5.21.

La reducción de características realizada por PCA ha sido fructífera al igual que en casos anteriores. Los clasificadores *bayesnet*, *END*, *filtered Classifier*, *one R*, *J48*, *J48 graft*, *random forest*, *random tree* y *repeated tree* han obtenido unas tasas de acierto superiores a un 98.5 %. Para este método de reducción el clasificador

Tabla 5.20: Clasificación del conjunto de las características de los bordes reducidas mediante la técnica ESAC.

Clasificador	Prec.	Sens.	V-F	ROC	%	K	EAM
Bayesnet	**99.5 %**	**99.5 %**	**1**	**1**	**99.45 %**	**0.9878**	**0.0055**
N. Bayes C.	82.6 %	81.1 %	0.82	0.81	81.09 %	0.5953	0.1891
N. Bayes	81.7 %	81.5 %	0.81	0.88	81.54 %	0.5482	0.1846
N. Bayes S.	81.7 %	81.6 %	0.81	0.89	81.59 %	0.5509	0.1848
N. Bayes U.	81.7 %	81.6 %	0.81	0.89	81.59 %	0.5509	0.1848
Adab. M1	82.8 %	81.9 %	0.81	0.9	81.92 %	0.549	0.2349
END	98.7 %	98.6 %	0.99	0.99	98.63 %	0.9688	0.0179
Filt. Class.	98.6 %	98.6 %	0.99	0.99	98.61 %	0.9685	0.0159
Multib. AB	82.7 %	81.8 %	0.8	0.87	81.81 %	0.5458	0.1814
One R	98.7 %	98.7 %	0.99	0.98	98.67 %	0.9699	0.0133
Decision S.	82.7 %	81.7 %	0.8	0.74	81.73 %	0.5436	0.297
J48	98.7 %	98.6 %	0.99	0.99	98.63 %	0.9688	0.0179
J48 graft	98.6 %	98.5 %	0.99	0.99	98.53 %	0.9664	0.019
Random F.	99.3 %	99.3 %	0.99	1	99.29 %	0.9839	0.0109
Random T.	99.1 %	99 %	0.99	0.99	99.05 %	0.9785	0.009
Rep. Tree	98.6 %	98.6 %	0.99	0.99	98.59 %	0.9681	0.0194
Media	91.61 %	91.29 %	0.91	0.93	91.29 %	0.7903	0.0991

más eficaz ha sido *bayesnet* con una tasa de acierto de un 99.45 %. Centrándonos en la media de la tasa de acierto de todos los clasificadores, ésta se sitúa en un 91.25 %, siendo superior a la conseguida por el conjunto original (88.18 %), correspondiéndose con una diferencia de un 3.07 %. Respecto a la técnica ESAC (91.29 %) ha conseguido una diferencia negativa (menor precisión) de un 0.04 %. Por último, PCA ha mejorando los resultados del método ESME (90.98 %) consiguiendo una diferencia de un 0.27 %. De forma idéntica a los casos anteriores, el conjunto de características obtenido mediante esta técnica es válido para ser utilizado en la detección de pólipos.

Habiéndose demostrado la eficacia de las técnicas de reducción de características individuales, es momento de pasar a evaluar el sistema combinado propuesto

Tabla 5.21: Clasificación del conjunto de las características de los bordes reducidas mediante la técnica PCA.

Clasificador	Prec.	Sens.	V-F	ROC	%	K	EAM
Bayesnet	**99.5 %**	**99.5 %**	**1**	**1**	**99.45 %**	**0.9877**	**0.0055**
N. Bayes C.	82.2 %	80.6 %	0.81	0.81	80.61 %	0.5859	0.1939
N. Bayes	81.7 %	81.4 %	0.8	0.88	81.41 %	0.5421	0.188
N. Bayes S.	81.7 %	81.4 %	0.8	0.88	81.41 %	0.5421	0.188
N. Bayes U.	81.7 %	81.4 %	0.8	0.88	81.41 %	0.5421	0.188
Adab. M1	82.8 %	81.9 %	0.81	0.9	81.89 %	0.5482	0.2347
END	98.8 %	98.8 %	0.99	0.99	98.76 %	0.9717	0.0161
Filt. Class.	98.6 %	98.6 %	0.99	1	98.64 %	0.9692	0.0152
Multib. AB	82.6 %	81.7 %	0.8	0.86	81.73 %	0.5436	0.1817
One R	98.7 %	98.7 %	0.99	0.98	98.66 %	0.9697	0.0134
Decision S.	82.7 %	81.7 %	0.8	0.74	81.73 %	0.5436	0.297
J48	98.8 %	98.8 %	0.99	0.99	98.76 %	0.9717	0.0161
J48 graft	98.6 %	98.6 %	0.99	0.99	98.56 %	0.9672	0.0184
Random F.	99.3 %	99.3 %	0.99	1	99.29 %	0.984	0.0107
Random T.	99.1 %	99 %	0.99	0.99	99.05 %	0.9785	0.009
Rep. Tree	98.6 %	98.6 %	0.99	0.99	98.63 %	0.969	0.0184
Media	91.59 %	91.25 %	0.91	0.93	91.25 %	0.7885	0.0996

en el presente trabajo. En la tabla 5.22 se presentan los resultados obtenidos por dicho sistema.

Los resultados obtenidos mediante el sistema de reducción de características diseñado muestran una mayor eficacia que los métodos individuales. Esto puede comprobarse mediante los clasificadores *bayesnet*, *END*, *filtered classifier*, *one R*, *J48*, *J48 graft*, *random forest*, *random tree* y *repeated tree* los cuales han conseguido tasas de acierto mayores a un 98.5 %. En este caso, el clasificador *bayesnet* ha sido quien ha obtenido una mayor tasa de acierto, situándola en un 99.46 %.

Fijándonos en las tasas de acierto medias, en este caso se sitúa en un 91.82 %, consiguiendo el valor más alto de todos los casos. Se ha logrado mejorar los resultados del conjunto original (88.18 %), consiguiendo una diferencia de un 3.64 %.

Tabla 5.22: Clasificación del conjunto de las características de los bordes reducidas mediante la combinación propuesta.

Clasificador	Prec.	Sens.	V-F	ROC	%	K	EAM
Bayesnet	**99.5 %**	**99.5 %**	**1**	**1**	**99.46 %**	**0.9879**	**0.0055**
N. Bayes C.	85.7 %	85.9 %	0.86	0.83	85.85 %	0.6733	0.1415
N. Bayes	81.7 %	81.6 %	0.81	0.89	81.59 %	0.5509	0.1848
N. Bayes S.	81.7 %	81.5 %	0.81	0.88	82.54 %	0.5482	0.1846
N. Bayes U.	81.7 %	81.5 %	0.81	0.88	83.54 %	0.5482	0.1846
Adab. M1	82.8 %	81.9 %	0.81	0.9	81.92 %	0.549	0.2349
END	98.8 %	98.8 %	0.99	0.99	98.77 %	0.972	0.0156
Filt. Class.	98.7 %	98.7 %	0.99	0.99	98.68 %	0.9701	0.0172
Multib. AB	82.7 %	81.8 %	0.8	0.87	81.81 %	0.5458	0.1814
One R	98.7 %	98.7 %	0.99	0.98	98.67 %	0.9699	0.0133
Decision S.	82.7 %	81.7 %	0.8	0.74	81.73 %	0.5436	0.297
J48	98.8 %	98.8 %	0.99	0.99	98.77 %	0.972	0.0156
J48 graft	98.7 %	98.6 %	0.99	0.99	98.63 %	0.9689	0.0173
Random F.	99.4 %	99.4 %	0.99	1	99.4 %	0.9864	0.0112
Random T.	99.1 %	99.1 %	0.99	0.99	99.06 %	0.9788	0.0089
Rep. Tree	98.7 %	98.7 %	0.99	0.99	98.7 %	0.9707	0.017
Media	91.84 %	91.64 %	0.91	0.93	91.82 %	0.796	0.0957

Siguiendo la comparativa, se mejoran los resultados proporcionados por la técnica ESME (90.98 %) obteniendo una diferencia de un 0.84 %. En cuanto a la técnica ESAC (91.29 %), se han vuelto a mejorar los resultados, traduciéndose en una diferencia de un 0.53 %. Por último, centrándonos en la técnica PCA (91.25 %), se mejoran una vez más los resultados obteniéndose una diferencia de un 0.57 %. De esta manera queda demostrada la eficacia del sistema de reducción de características diseñado, además de la capacidad discriminante del conjunto de características reducido obtenido a partir de él.

Para facilitar la comparación de los resultados se proporciona la tabla 5.23. En ella se comparan las tasas de acierto conseguidas por los clasificadores utilizados haciendo uso de los diferentes conjuntos de datos.

Tabla 5.23: Comparativa de los porcentajes de acierto obtenidos en las clasificaciones de los diferentes conjuntos de características. De aquí en adelante Comb. representará la combinación diseñada.

Clasificador	Original	ESME	ESAC	PCA	Comb
Bayesnet	99.01 %	99.17 %	**99.45 %**	**99.45 %**	**99.46 %**
N. Bayes C.	46.82 %	77.09 %	81.09 %	80.61 %	85.85 %
N. Bayes	77.53 %	81.5 %	81.54 %	81.41 %	81.59 %
N. Bayes S.	75.84 %	81.5 %	81.59 %	81.41 %	82.54 %
N. Bayes U.	77.53 %	81.5 %	81.59 %	81.41 %	83.54 %
Adab. M1	81.73 %	81.89 %	81.92 %	81.89 %	81.92 %
END	98.67 %	98.29 %	98.63 %	98.76 %	98.77 %
Filt. Class.	98.6 %	98.67 %	98.61 %	98.64 %	98.68 %
Multib. AB	81.73 %	81.74 %	81.81 %	81.73 %	81.81 %
One R	98.66 %	98.67 %	98.67 %	98.66 %	98.67 %
Decision S.	81.73 %	81.73 %	81.73 %	81.73 %	81.73 %
J48	98.29 %	98.67 %	98.63 %	98.76 %	98.77 %
J48 graft	98.08 %	98.32 %	98.53 %	98.56 %	98.63 %
Random F.	**99.2 %**	**99.31 %**	99.29 %	99.29 %	99.4 %
Random T.	99.01 %	99.04 %	99.05 %	99.05 %	99.06 %
Rep. Tree	98.49 %	98.59 %	98.59 %	98.63 %	98.7 %
Media	88.18 %	90.98 %	91.29 %	91.25 %	91.82 %

Gracias al presente análisis se demuestra que es posible realizar una detección de pólipos haciendo uso de las características de los bordes. Para ello sería necesario seleccionar un método de clasificación eficaz, que como ha quedado probado existen varios capaces de abordar dicha tarea. De entre ellos es preciso destacar el buen rendimiento del clasificador *bayesnet*, que ha obtenido una tasa de acierto de un 99.46 % en la reducción combinada propuesta. Por otra parte, queda probada la necesidad de contar con un sistema de reducción de características y además, se ha mostrado la efectividad del sistema propuesto para tal propósito.

A continuación se evalúa la calidad de la segmentación proporcionada por la detección de pólipos mediante el análisis de las propiedades de los bordes.

5.2.2.2 **Análisis de la precisión del área del pólipo detectada mediante el análisis de bordes (R5)**

La evaluación de la precisión del área del pólipo detectada pretende analizar la calidad de las segmentaciones obtenidas haciendo uso de propiedades de los bordes. No es suficiente con probar la efectividad de las características extraídas, ya que en muchos casos la extensión de los pólipos puede ser dudosa, por lo que es necesario abarcar el máximo área posible de los mismos. Los indicadores que se han utilizado para esta evaluación son los siguientes: CAA, DC, exactitud, precisión, sensibilidad y especificidad. Los resultados obtenidos por las segmentaciones de los pólipos en las imágenes pertenecientes a la base de datos *CVC Colon Database* se muestran en la tabla 5.24.

Tabla 5.24: Indicadores de calidad de la segmentación realizada por el análisis de los bordes.

CAA	DC	Exactitud	Precisión	Sensibilidad	Especificidad
76.29 %	71.57 %	97.46 %	73.02 %	76.29 %	98.82 %

Los cálculos han sido realizados sobre las imágenes de la base de datos en las que el sistema propuesto ha sido capaz de detectar pólipos, mostrándose la media de los indicadores. Los valores obtenidos para los índices CAA y DC han sido altos teniendo en cuenta la complejidad que supone la detección automática de pólipos. El difícil entorno en el que se capturan las imágenes colonoscópicas, junto con la multitud de pliegues y recovecos existentes, hace que en muchas ocasiones no sea posible obtener un contorno completo del pólipo, por lo que es una ardua tarea el conseguir unos valores de un 76.29 % y de un 71.57 % para ellos. En cuanto a la exactitud y la especificidad conseguida por las segmentaciones, éstas han sido muy altas, obteniéndose unos valores de un 97.46 % y de un 98.82 % de forma respectiva, por lo que los resultados en este aspecto han sido satisfactorios. Por último, atendiendo a la precisión y la sensibilidad conseguidas, éstas se sitúan en un 73.02 % y en un 76.29 % por lo que ambos resultados son de igual manera positivos.

Con el objetivo de facilitar la interpretación de los resultados se proporciona la figura 5.9, que contiene los valores de los indicadores CAA y DC a lo largo de la base de datos.

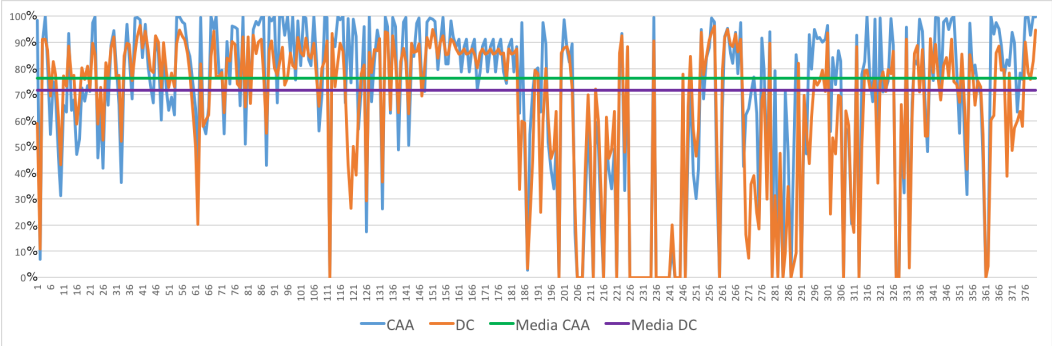


Figura 5.9: Distribución de los valores de CAA y CD a lo largo de las imágenes de la base de datos para el análisis de los bordes. El eje de ordenadas representa los valores de CAA y CD. El de abscisas representa las imágenes de la base de datos.

Mediante este sistema de análisis se ha medido la calidad de las segmentaciones obtenidas haciendo uso de la detección de pólipos basada en las propiedades extraídas de los bordes. Los resultados han sido extraordinarios obteniendo una alta eficacia.

Para finalizar la evaluación del presente sistema se procede a analizar su precisión general. Este análisis se lleva a cabo en el siguiente apartado.

5.2.2.3 **Análisis de la precisión de la detección de pólipos mediante el análisis de bordes (R6)**

El sistema de evaluación de la eficacia de la detección de pólipos mediante el análisis de los bordes tiene como único objetivo ver la capacidad de detección de pólipos del mismo. Este es el análisis más importante dentro del sistema de detección automática realizado, ya que será quien determinará el número de lesiones detectadas, siendo el indicador por excelencia.

Para el presente estudio se ha utilizado la base de datos *CV Colon Database*. Haciendo uso de este método se han conseguido detectar los pólipos presentes en 344 de las 380 imágenes, por lo que su precisión se sitúa en un 90.53 %.

Como ha podido comprobarse, los resultados obtenidos por esta técnica han sido muy precisos por lo que se puede concluir que se trata de un método válido para la detección automática de pólipos.

5.2.2.4 **Análisis de la precisión de la clasificación de las características de la textura (R7)**

El segundo enfoque utilizado para la detección de pólipos es el análisis de la textura de las imágenes colonoscópicas. Los pólipos tienen unas propiedades diferenciadas en cuanto a su textura, lo que permite distinguirlos del resto de los elementos presentes en el colon. Haciendo uso de esta particularidad se han diseñado algoritmos para la detección automática de pólipos.

Con el ánimo de demostrar la validez de este planteamiento se procede a evaluar los resultados obtenidos por el mismo. Se comienza, al igual que en el caso del análisis de las propiedades de los bordes, determinando la eficacia de las propiedades de la textura extraídas. Se han seleccionado 15 métodos de clasificación diferentes, mediante los cuales se ha procedido a clasificar los descriptores de textura extraídos de las imágenes pertenecientes a la base de datos *CVC Colon Database*. Las correspondencias entre los diminutivos y los nombres completos de los clasificadores mostrados en las tablas 5.26, 5.27, 5.28, 5.29, 5.30 y 5.31 pueden verse en la tabla 5.25.

Tabla 5.25: Correspondencia de los diminutivos con los nombres de los clasificadores en las tablas de resultados.

Diminutivo	**Nombre completo**	**Diminutivo**	**Nombre completo**
Bayesnet	*Red bayesiana*	Logistic	*Regresión logística*
Lazy IBK	*Lazy IBK*	Attr. Sel. C.	*Attribute selected classifier*
Bagging	*Bagging*	Class. Via R.	*Classification via regression*
END	*END*	Filt. Class.	*Filtered classifier*
Mult. Class.	*Multiclass classifier*	One R	*One R*
J48	*J48*	J48 graft	*J48 graft*
Random F.	*Random forest*	Rep. Tree	*Repeated tree*
Simple chart	*Simple chart*		

En el apartado 5.2.2.1 ≪Análisis de la precisión de la clasificación mediante características de los bordes (R4)≫ se han utilizado 16 clasificadores. La diferencia entre ambos casos es debida a los tiempos de ejecución de los métodos. En el primero de ellos se han encontrado 16 métodos con un tiempo de ejecución razonable, siendo uno menos en este último.

Como ya es sabido, la eficacia de la clasificación de las características depende de factores como la dimensionalidad del conjunto de datos y los clasificadores utilizados. Por este motivo se hará uso del sistema de reducción diseñado, mediante el cual se obtendrán diferentes subconjuntos de datos que serán clasificados por los métodos seleccionados. Los datos disponibles para el presente análisis son los siguientes:

- Conjunto de características extraídas de la textura de las imágenes pertenecientes a la base de datos *CVC Colon Database*. Este conjunto de datos será denominado como conjunto original.

- Conjunto de características original reducido mediante la técnica ESME.

- Conjunto de características original reducido mediante la técnica ESAC.

- Conjunto de características original reducido mediante la técnica PCA.

- Conjunto de características original reducido mediante la combinación propuesta.

Una vez descrito el conjunto de datos que se utilizará, se comienza con la extracción de los resultados de las clasificaciones realizadas por los métodos elegidos. Las clasificaciones han sido realizadas mediante una validación cruzada de 10 iteraciones para asegurar la fiabilidad de los resultados.

En primer lugar, se examinan los resultados obtenidos por la clasificación del conjunto original de características. La información sobre este aspecto está disponible en la tabla 5.26.

Tabla 5.26: Clasificación del conjunto original de las características extraídas de la textura.

Clasificador	Prec.	Sens.	V-F	ROC	%	K	EAM
Bayesnet	80.7 %	68.9 %	0.66	0.88	68.89 %	0.38	0.3105
Logistic	69.5 %	69.5 %	0.7	0.77	69.5 %	0.39	0.392
Lazy IBK	96.5 %	96.2 %	0.96	0.95	96.22 %	0.92	0.0379
Attr. Sel. C.	95.9 %	95.5 %	0.96	0.96	95.52 %	0.91	0.0481
Bagging	97.3 %	97.1 %	0.97	1	97.13 %	0.94	0.0879
Class. Via R.	94.6 %	94 %	0.94	0.96	94.04 %	0.88	0.1493
END	96.2 %	95.8 %	0.96	0.96	95.84 %	0.92	0.0444
Filt. Class.	93.9 %	93.1 %	0.93	0.97	93.13 %	0.86	0.0766
Mult. Class.	69.5 %	69.5 %	0.7	0.77	69.5 %	0.39	0.392
One R	92.7 %	91.5 %	0.91	0.92	91.47 %	0.83	0.0853
J48	96.2 %	95.8 %	0.96	0.96	95.84 %	0.92	0.0444
J48 graft	95.6 %	95.2 %	0.95	0.96	95.16 %	0.9	0.0511
Random F.	**98.1 %**	**98 %**	**0.98**	**1**	**98.05 %**	**0.96**	**0.0517**
Rep. Tree	94.4 %	93.7 %	0.94	0.95	93.73 %	0.87	0.0838
Simple chart	95.3 %	94.9 %	0.95	0.95	94.87 %	0.9	0.0676
Media	91.09 %	89.91 %	0.9	0.93	89.93 %	0.8	0.1282

Los resultados conseguidos en la clasificación del conjunto original de características de la textura han sido muy precisos. Muestra de ello es que los clasificadores *lazzy IBK*, *attribute selected classifier*, *bagging*, *END*, *J48*, *J48 graft* y *random forest* han obtenido una tasa de acierto mayor a un 95 %. De entre ellos destaca *random forest*, el cual ha alcanzado una tasa de acierto de un 98.05 %. En cuanto a la tasa de acierto media, ésta queda situada en un 89.93 %. Esto indica que es posible una detección automática de pólipos mediante el análisis de la textura diseñado. A pesar de haber obtenido unos buenos resultados, es esencial llevar a cabo una reducción de la dimensionalidad de los datos haciendo uso del sistema propuesto para ello.

El sistema de selección de características comienza con la aplicación del método ESME. Al igual que en casos anteriores, este método hará uso de un clasificador

interno para efectuar la selección de los descriptores, por lo tanto, cada uno de los clasificadores usados para la extracción de resultados es usado internamente en el envoltorio. El conjunto de datos reducido mediante esta técnica ha obtenido los resultados proporcionados por la tabla 5.27.

Tabla 5.27: Clasificación del conjunto de las características de la textura reducidas mediante la técnica ESME.

Clasificador	Prec.	Sens.	V-F	ROC	%	K	EAM
Bayesnet	81.1 %	70.3 %	0.67	0.88	70.26 %	0.41	0.2969
Logistic	74.5 %	73.9 %	0.74	0.81	73.9 %	0.48	0.3465
Lazy IBK	96.6 %	96.4 %	0.96	0.95	96.4 %	0.93	0.036
Attr. Sel. C.	96.2 %	95.9 %	0.96	0.96	95.87 %	0.92	0.0469
Bagging	97.3 %	97.1 %	0.97	1	97.14 %	0.94	0.0877
Class. Via R.	94.7 %	94.2 %	0.94	0.96	94.23 %	0.88	0.1429
END	96.2 %	95.9 %	0.96	0.96	95.87 %	0.92	0.0442
Filt. Class.	94.1 %	93.5 %	0.93	0.97	93.46 %	0.87	0.0735
Mult. Class.	74.5 %	73.9 %	0.74	0.81	73.9 %	0.48	0.3465
One R	92.7 %	91.5 %	0.91	0.92	91.47 %	0.83	0.0853
J48	96.2 %	95.9 %	0.96	0.96	95.87 %	0.92	0.0442
J48 graft	95.6 %	95.2 %	0.95	0.96	95.16 %	0.9	0.051
Random F.	**98.7 %**	**98.7 %**	**0.99**	**1**	**98.69 %**	**0.97**	**0.0532**
Rep. Tree	94.8 %	94.3 %	0.94	0.95	94.25 %	0.89	0.0789
Simple chart	95.4 %	94.9 %	0.95	0.95	94.88 %	0.9	0.0665
Media	91.91 %	90.77 %	0.91	0.94	90.76 %	0.82	0.12

A la vista de los resultados se observa una gran precisión. Los clasificadores *lazzy IBK*, *attribute selected classifier*, *bagging*, *END*, *J48*, *J48 graft* y *random forest* han conseguido unas tasas de acierto superiores a un 95 %, por lo que, al igual que ocurría en el conjunto original, éste también es válido para la detección automática de pólipos. A la hora de seleccionar un clasificador, *random forest* sigue siendo el más preciso con una tasa de acierto de un 98.69 %. En comparación con el conjunto original de datos se ha dado un aumento en la tasa de acierto media. Este último conseguía un 89.93 % de acierto, siendo de un 90.76 % para este nuevo con-

junto. La diferencia obtenida es de un 0.83 %, lo que puede parecer insignificante en cuanto a precisión, pero es indispensable para el manejo de datos y eficiencia computacional.

Continuando con la reducción de características, el próximo método a utilizar es ESAC. El conjunto de datos obtenido mediante su aplicación ha mostrado una alta eficacia como puede verse en la tabla 5.28.

Tabla 5.28: Clasificación del conjunto de las características de la textura reducidas mediante la técnica ESAC.

Clasificador	Prec.	Sens.	V-F	ROC	%	K	EAM
Bayesnet	79.7 %	77.7 %	0.77	0.87	77.66 %	0.55	0.2247
Logistic	74.2 %	73.6 %	0.73	0.81	73.6 %	0.81	0.3740
Lazy IBK	96.6 %	96.4 %	0.96	0.95	96.4 %	0.93	0.036
Attr. Sel. C.	96.2 %	95.9 %	0.96	0.96	95.87 %	0.92	0.0469
Bagging	97.3 %	97.1 %	0.97	1	97.14 %	0.94	0.0877
Class. Via R.	94.7 %	94.2 %	0.94	0.96	94.23 %	0.88	0.1429
END	96.2 %	95.9 %	0.96	0.96	95.89 %	0.92	0.0443
Filt. Class.	94 %	93.3 %	0.93	0.97	93.28 %	0.87	0.0776
Mult. Class.	74.4 %	73.8 %	0.74	0.81	73.77 %	0.48	0.3467
One R	92.7 %	91.5 %	0.91	0.92	91.47 %	0.83	0.0853
J48	96.2 %	95.9 %	0.96	0.96	95.89 %	0.92	0.0443
J48 graft	95.7 %	95.3 %	0.95	0.95	95.29 %	0.91	0.0501
Random F.	**98.7 %**	**98.6 %**	**0.99**	**1**	**98.65 %**	**0.97**	**0.0529**
Rep. Tree	94.6 %	94 %	0.94	0.95	94 %	0.88	0.0831
Simple chart	95.4 %	94.9 %	0.95	0.95	94.88 %	0.9	0.0665
Media	91.77 %	91.21 %	0.91	0.93	91.2 %	0.85	0.1175

El método ESAC ha obtenido unos buenos resultados en las clasificaciones, muestra de ello es la tasa de acierto mostrada por los clasificadores *lazzy IBK*, *attribute selected classifier*, *bagging*, *END*, *J48*, *J48 graft* y *random forest* que se sitúa por encima de un 95 %. Una vez más, *random forest* se muestra como el clasificador más eficaz alcanzando una tasa de acierto de un 98.65 %.

Centrándonos en la tasa de acierto media, esta técnica ha obtenido una valoración de un 91.2 %. En comparación con el conjunto original de características, que conseguía una tasa de un 89.93 % y del reducido mediante la técnica ESME que alcanzó un 90.76 %, se ha conseguido mejorar los resultados de ambos, obteniéndose una diferencia de un 1.27 % respecto al primero y de un 0.44 % respecto al segundo. De la misma forma que en el resto de conjuntos de datos, éste también es apto para la detección automática de pólipos.

El último sistema de reducción de características utilizado, previo a la combinación de los mismos es PCA. Los resultados conseguidos por él pueden verse en la tabla 5.29.

Tabla 5.29: Clasificación del conjunto de las características de la textura reducidas mediante la técnica PCA.

Clasificador	Prec.	Sens.	V-F	ROC	%	K	EAM
Bayesnet	82.4 %	75.2 %	0.74	0.88	75.2 %	0.5	0.2482
Logistic	74.4 %	73.8 %	0.74	0.81	73.77 %	0.48	0.3467
Lazy IBK	96.6 %	96.4 %	0.96	0.95	96.39 %	0.93	0.0361
Attr. Sel. C.	96.2 %	95.9 %	0.96	0.96	95.87 %	0.92	0.0469
Bagging	97.3 %	97.1 %	0.97	1	97.14 %	0.94	0.0877
Class. Via R.	94.7 %	94.2	0.94	0.96	94.23 %	0.88	0.1429
END	96.3 %	95.9 %	0.96	0.96	95.95 %	0.92	0.0435
Filt. Class.	94.1 %	93.4 %	0.93	0.97	93.44 %	0.87	0.0736
Mult. Class.	74.6 %	74 %	0.74	0.81	74.02 %	0.48	0.3466
One R	92.7 %	91.5 %	0.91	0.92	91.47 %	0.83	0.0853
J48	96.3 %	95.9 %	0.96	0.96	95.95 %	0.92	0.0435
J48 graft	95.6 %	95.2 %	0.95	0.96	95.17 %	0.9	0.0511
Random F.	**98.7 %**	**98.7 %**	**0.99**	**1**	**98.67 %**	**0.97**	**0.0531**
Rep. Tree	94.8 %	94.2 %	0.94	0.95	94.24 %	0.88	0.079
Simple chart	95.4 %	94.9 %	0.95	0.95	94.88 %	0.9	0.0666
Media	92.01 %	91.09 %	0.91	0.94	91.09 %	0.82	0.1167

El método PCA ha obtenido unas tasas de acierto para los clasificadores *lazzy IBK*, *attribute selected classifier*, *bagging*, *END*, *J48*, *J48 graft* y *random forest* su-

periores a un 95 %. *Random forest* se muestra impasible una vez más, consiguiendo la eficacia más alta, lo que se traduce en un 98.67 % de tasa de acierto.

Respecto a la tasa de acierto media, este método ha alcanzado una valoración de un 91.09 %, lo que en comparación con el conjunto original de datos que conseguía un 89.93 % se advierte una ligera mejora que se traduce en una diferencia de un 1.16 %. En cuanto al método ESME que conseguía una tasa de acierto media de un 90.76 %, ha obtenido un aumento en la precisión, traduciéndose en una diferencia de un 0.33 %. Respecto a la técnica ESAC que obtenía una tasa de acierto media de un 91.2 %, se ha registrando una pérdida de precisión, lo que indica una diferencia negativa de un 0.11 %. Como muestran los resultados, se sigue mejorando lo mostrado por el conjunto original y además, se confirma la utilidad de este conjunto de datos para la detección de pólipos.

Para finalizar la evaluación de la precisión de la clasificación de las características de la textura, se procede a analizar la eficacia del sistema de reducción de características combinado diseñado sobre el conjunto original de datos. Los resultados conseguidos se muestran en la tabla 5.30.

Una vez expuestos los resultados, se valida la efectividad del sistema de reducción de características combinado diseñado. Prueba de ello son los clasificadores *lazzy IBK*, *attribute selected classifier*, *bagging*, *END*, *J48*, *J48 graft* y *random forest* que han obtenido unas tasas de acierto superiores a un 95 %. Para este último caso, el clasificador más preciso ha sido una vez más *random forest* que llega a un 98.69 % de tasa de acierto.

En comparación con el conjunto original y el resto de técnicas de reducción, la combinación llevada a cabo obtiene una tasa de acierto media de un 92.75 %, lo que mejora los resultados ofrecidos por estos. Respecto al conjunto original que alcanzaba una tasa de acierto media de un 89.93 % se ha conseguido una diferencia de un 2.82 %. Centrándonos en la técnica ESME que ha conseguido una tasa de acierto media de un 90.76 %, se ha conseguido una diferencia de un 1.99 %, situándose en un 1.55 % para la técnica ESAC que proporcionaba una tasa de acierto media de un 91.2 %. Por último, respecto a PCA, la cual ha conseguido una tasa de acierto media de un 91.09 %, se ha conseguido una diferencia de un 1.66 %.

Para facilitar la comparación de los resultados se proporciona la tabla 5.31 que compara las tasas de acierto conseguidas por los clasificadores utilizados haciendo

Tabla 5.30: Clasificación del conjunto de las características de la textura reducidas mediante la combinación diseñada.

Clasificador	Prec.	Sens.	V-F	ROC	%	K	EAM
Bayesnet	83 %	78.6 %	0.78	0.88	78.6 %	0.57	0.2165
Logistic	74.6 %	74 %	0.74	0.81	74.02 %	0.48	0.3466
Lazy IBK	96.7 %	96.5 %	0.97	0.95	96.46 %	0.93	0.0355
Attr. Sel. C.	96.2 %	95.9 %	0.96	0.96	95.9 %	0.92	0.0465
Bagging	97.4 %	97.3 %	0.97	1	97.3 %	0.95	0.0933
Class. Via R.	94.9 %	94.3 %	0.94	0.96	94.34 %	0.89	0.1458
END	96.3 %	96.1 %	0.96	0.96	96.05 %	0.92	0.0432
Filt. Class.	94.2 %	93.5 %	0.94	0.97	93.49 %	0.87	0.0733
Mult. Class.	94.9 %	94.3 %	0.94	0.96	94.34 %	0.89	0.1458
One R	92.7 %	91.5 %	0.91	0.92	91.47 %	0.83	0.0853
J48	96.3 %	96.1 %	0.96	0.96	96.05 %	0.92	0.0432
J48 graft	95.8 %	95.4 %	0.95	0.96	95.38 %	0.91	0.0497
Random F.	**98.7 %**	**98.7 %**	**0.99**	**1**	**98.69 %**	**0.97**	**0.0541**
Rep. Tree	94.8 %	94.3 %	0.94	0.95	94.25 %	0.89	0.0789
Simple chart	95.4 %	94.9 %	0.95	0.95	94.92 %	0.9	0.0655
Media	93.46 %	92.76 %	0.93	0.95	92.75 %	0.86	0.1015

uso de los diferentes conjuntos de datos.

Por el presente análisis se argumenta que es posible realizar una detección automática de pólipos haciendo uso del sistema de extracción de características de la textura diseñado. Para ello es necesario seleccionar un método de clasificación eficaz, que como ha quedado probado existen varios capaces de ello. Es necesario destacar los buenos resultados obtenidos por el clasificador *random forest* que ha sido capaz de alcanzar una tasa de acierto de un 98.69 % en el sistema de reducción de características combinado diseñado. Asimismo, se ratifica al igual que en el caso del análisis de las propiedades de los bordes, la necesidad de contar con un sistema de reducción de características.

Para finalizar este análisis, a modo de conclusión general, es indispensable indicar la importancia de seleccionar el método de clasificación que más se ajuste al

Tabla 5.31: Comparativa de los porcentajes de acierto obtenidos en las clasificaciones utilizando los diferentes conjuntos de características.

Clasificador	Original	ESME	ESAC	PCA	Comb
Bayesnet	68.69	70.26	77.66	75.2	78.6
Logistic	69.5	73.9	73.6	73.77	74.02
Lazy IBK	96.22	96.4	96.4	96.39	96.46
Attr. Sel. C.	95.52	95.87	95.87	95.87	95.9
Bagging	97.13	97.14	97.14	97.14	97.3
Class. Via R.	94.04	94.23	94.23	94.23	94.34
END	95.84	95.87	95.89	95.95	96.05
Filt. Class.	93.13	93.46	93.28	93.44	93.49
Mult. Class.	69.5	73.9	73.77	74.02	94.34
One R	91.47	91.47	91.47	91.47	91.47
J48	95.84	95.87	95.89	95.95	96.05
J48 graft	95.16	95.16	95.29	95.17	95.38
Random F.	**98.05**	**98.69**	**98.65**	**98.67**	**98.69**
Rep. Tree	93.73	94.25	94	94.24	94.25
Simple chart	94.87	94.88	94.88	94.88	94.92
Media	89.93	90.76	91.2	91.09	92.75

problema tratado. Esto se ha visto en las tasas de aciertos mostradas por cada uno de ellos para los diferentes conjuntos de datos.

De forma similar, es imprescindible seleccionar las técnicas de reducción de características que ofrezcan mejores resultados, de manera que permitan generar un conjunto reducido a la par que discriminante.

Por otra parte, se ha visto que la metodología diseñada para combinar los métodos de reducción es válida, ya que ha obtenido mejores resultados que las técnicas individuales en todos los casos.

Tras realizar el presente análisis se procede a evaluar la calidad de las segmentaciones proporcionadas por la detección de pólipos mediante el análisis de la textura.

5.2.2.5 **Análisis de la precisión del área del pólipo detectada mediante el análisis de la textura (R8)**

Siguiendo el procedimiento diseñado para el análisis del sistema de detección de pólipos, una vez validada la extracción, reducción y clasificación de características, se continúa con la evaluación de la precisión del área del pólipo detectada. Los indicadores utilizados vuelven a ser los siguientes: CAA, DC, exactitud, precisión, sensibilidad y especificidad, de manera que se permita realizar una comparación entre los diferentes enfoques.

Los resultados obtenidos por las segmentaciones obtenidas por el análisis de la textura pueden verse en la tabla 5.32.

Tabla 5.32: Indicadores de la calidad de la segmentación realizada por el análisis de la textura.

CAA	DC	Exactitud	Precisión	Sensibilidad	Especificidad
93.9 %	87.31 %	98.48 %	83.05 %	93.9 %	99.11 %

Es necesario aclarar que los cálculos han sido realizados sobre las imágenes de la base de datos en las que el sistema propuesto ha sido capaz de detectar pólipos. Comenzando con la interpretación de los resultados, los valores obtenidos para los índices CAA y DC han sido muy elevados, 93.9 % y 87.31 % de forma respectiva. Esto verifica la precisión alcanzada por el sistema, a pesar de la dificultad del entorno en el que son capturadas las imágenes colonoscópicas. Centrándonos en los parámetros de exactitud y especificidad, ambos han conseguido valores muy altos, siendo de un 98.48 % y de un 99.11 % de forma respectiva, por lo que pueden considerarse unos valores excelentes. En último lugar, en cuanto a la precisión y sensibilidad conseguidas, éstas se sitúan en un 83.05 % y en un 93.9 % por lo que ambos resultados son de igual forma positivos.

Para facilitar la interpretación de los resultados se incluye la figura 5.10 que contiene los valores de los indicadores CAA y DC a lo largo de la base de datos.

Haciendo uso de este sistema de análisis se ha medido la calidad de las segmentaciones obtenidas mediante la detección de pólipos basada en el análisis de la textura. Los resultados han sido extraordinarios obteniéndose una alta efectividad.

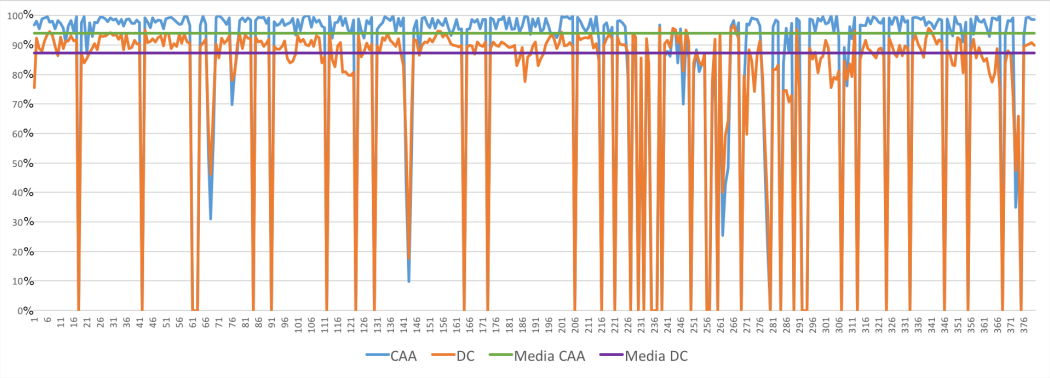


Figura 5.10: Distribución de los valores de CAA y CD a lo largo de las imágenes de la base de datos para el análisis de la textura. El eje de ordenadas representa los valores de CAA y CD. El de abscisas representa las imágenes de la base de datos.

Para finalizar con las evaluaciones del sistema de detección de pólipos mediante el análisis de textura se continúa estudiando su capacidad global de detección de pólipos. Este análisis se lleva a cabo en el siguiente apartado.

5.2.2.6 **Análisis de la precisión de la detección de pólipos mediante el análisis de la textura (R9)**

El sistema de evaluación de la eficacia de la detección de pólipos mediante el análisis de la textura diseñado tiene como único objetivo ver la capacidad de detección de pólipos del mismo. Siguiendo el protocolo establecido, se han utilizado las imágenes de la base de datos *CVC Colon Database*. Es preciso aclarar que éste es el análisis más importante a realizar en un sistema de detección automática de pólipos ya que determina el porcentaje de lesiones detectadas.

Mediante el presente sistema se han conseguido detectar los pólipos presentes en 339 de las 380 imágenes, por lo que su precisión se sitúa en un 89.21 %. Los resultados obtenidos por este enfoque han sido satisfactorios, de forma que se puede validar su eficacia en la detección automática de pólipos.

Una vez finalizados los análisis de ambos enfoques de detección de pólipos, se procede a evaluar los resultados obtenidos por la combinación de ellos. Este proceso se describe en los siguientes apartados.

5.2.2.7 **Análisis de la precisión del área del pólipo detectada mediante el análisis combinado (R10)**

Asegurada la validez de la detección automática de pólipos mediante el análisis de las propiedades de los bordes y de la textura, se efectúa la evaluación de la precisión del área del pólipo definida por la combinación diseñada. Los indicadores utilizados, al igual que en los casos anteriores serán CAA, DC, exactitud, precisión, sensibilidad y especificidad. En la tabla 5.33 se muestran los resultados obtenidos.

Tabla 5.33: Indicadores de la calidad de la segmentación realizada por la combinación propuesta del análisis de los bordes y de la textura.

CAA	DC	Exactitud	Precisión	Sensibilidad	Especificidad
95.83 %	80.47 %	97.94 %	73.19 %	95.83 %	98.3 %

Todos los cálculos mostrados han sido realizados sobre las imágenes de la base de datos en las que ha sido posible determinar la existencia de pólipos. En cuanto al análisis de los resultados estos han sido muy buenos. Prueba de ello son las valoraciones obtenidas por los índices CAA y DC, que muestran unos valores de un 95.83 % y un 80.47 % de forma respectiva. En comparación con el análisis de los bordes y de la textura, el CAA obtenido por la combinación ha sido superior a los enfoques individuales (CAA = 76.29 % y CAA = 93.9 % para el análisis de los bordes y de la textura), correspondiéndose con una diferencia de un 19.54 % respecto al primero y de un 1.93 % sobre el segundo, lo que es muestra del buen diseño realizado. En cuanto al índice DC, la combinación ha conseguido un valor de un 80.47 %. Esto supone una mejora respecto al análisis de los bordes (DC = 71.57 %) que se corresponde con una diferencia de un 8.9 %. En cambio, respecto al análisis de la textura (DC = 87.31 %), se ha percibido una menor efectividad obteniéndose una diferencia negativa de un 6.84 %. En este caso concreto se ha observado una menor precisión que en el análisis de la textura, pero en muchas ocasiones es el precio a pagar para poder aumentar la tasa de detección de pólipos general. Respecto a la exactitud y precisión alcanzadas, éstas se sitúan en un 97.94 % y en un 73.19 %. La primera de ellas consigue un aumento de la eficacia que se traduce en una diferencia de un 0.48 % respecto al análisis de los bordes

(exactitud = 97.46 %), obteniendo una menor eficacia que el análisis de la textura (exactitud = 98.48 %), con el que se ha conseguido una diferencia negativa de un 0.54 %. Lo mismo ocurre en el caso de la precisión, ya que aumenta su eficacia respecto al análisis de los bordes (precisión = 73.02 %), traduciéndose en una diferencia de un 0.17 % y empeora sus resultados respecto al análisis de la textura (precisión = 83.05 %), con la que se ha conseguido una diferencia negativa de un 9.86 %. Para finalizar, los valores de sensibilidad y especificidad alcanzados han sido de un 95.83 % y de un 98.3 %. Las diferencias observadas para el caso de la sensibilidad indican una mayor efectividad que los enfoques individuales. Esto se traduce en unas diferencias de un 19.54 % respecto al análisis de los bordes (sensibilidad = 76.29 %) y de un 1.93 % con el análisis de la textura (sensibilidad = 93.9 %). Si nos centramos en la especificidad, se ha obtenido una menor efectividad. Estos resultados se corresponden con unas diferencias negativas de un 0.52 % respecto al análisis de los bordes (especificidad = 98.82 %) y de un 0.81 % respecto al análisis de la textura (especificidad = 99.11 %).

Como puede observarse, el análisis combinado a proporcionado una mejora respecto a los métodos individuales en los índices CAA y sensibilidad. Ha mejorado los índices DC, exactitud y precisión respecto al análisis de los bordes, empeorando los resultados del análisis de la textura. Por último, en cuanto a la especificidad, el análisis de los bordes y de la textura han conseguido superar a la combinación.

A la vista de los resultados se comprueba que la combinación propuesta es efectiva. Con el ánimo de facilitar la interpretación de los resultados obtenidos, se muestra la figura 5.11 que contiene los valores de CAA y DC para todas las imágenes de la base de datos.

Mediante este sistema de evaluación se ha medido la calidad de las segmentaciones conseguidas por la combinación propuesta. Los resultados han sido en muchos casos superiores a los ofrecidos por los enfoques individuales, a pesar de que los cálculos han sido realizados sobre las imágenes en las que se han detectado pólipos, siendo para el caso del análisis combinado un número mayor, lo que dificulta el incremento en los valores de los indicadores.

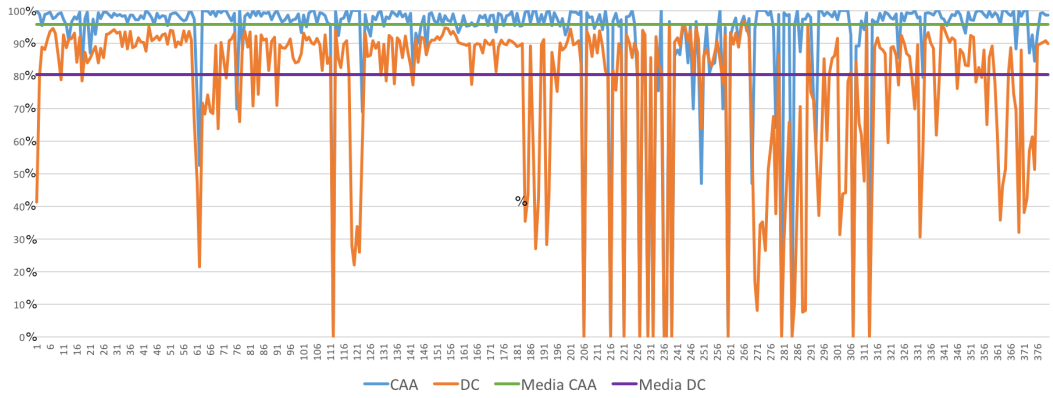


Figura 5.11: Distribución de los valores de CAA y CD a lo largo de las imágenes de la base de datos para el análisis combinado. El eje de ordenadas representa los valores de CAA y CD. El de abscisas representa las imágenes de la base de datos.

5.2.2.8 **Análisis de la precisión de la detección de pólipos mediante el análisis combinado (R11)**

La evaluación de la eficacia del sistema combinado de detección de pólipos diseñado es el colofón final del análisis. Gracias a él se comprueba que el diseño planteado es efectivo y que armoniza los puntos fuertes de ambos enfoques, proporcionando unos resultados superiores a los enfoques individuales.

Del total de imágenes disponibles en la base de datos *CVC Colon Database*, el método combinado ha conseguido detectar pólipos en 365 de las 380 disponibles, suponiendo una tasa de detección de un 96.05 %. La tabla 5.34 resume las tasas de detección conseguidas por los enfoques individuales y el combinado, haciendo más sencilla la comprensión de los resultados.

Tabla 5.34: Comparativa de las tasas de detección de pólipos alcanzadas por los análisis de bordes, textura y su combinación.

	Análisis de bordes	**Análisis de textura**	**Análisis combinado**
% detección	90.53 %	89.21 %	**96.05 %**

Los resultados conseguidos por la combinación (96.05 %) indican un aumento en la efectividad respecto al análisis de los bordes (90.53 %) y de la textura (89.21 %). Estos se corresponden con unas diferencias de un 5.52 % respecto al

primero y de un 6.84 % respecto al segundo. El incremento conseguido es alto, a pesar de contar con métodos de base que conseguían unas buenas tasas de detección.

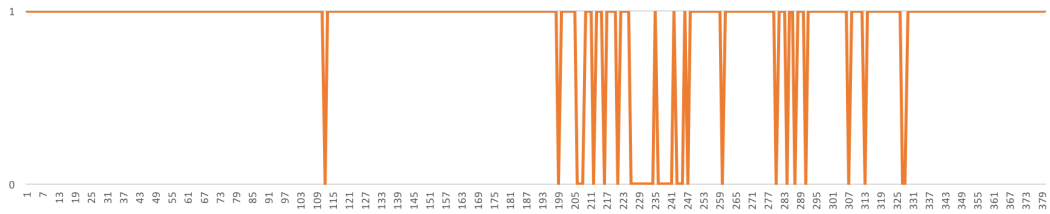
El motivo principal que ha determinado el éxito de la combinación es la complementariedad de los enfoques utilizados. Por un lado, el análisis de los bordes ha permitido detectar aquellos pólipos que se encontraban a una larga o media distancia y de los cuales se observa todo su contorno, por otro lado, la textura ha sido capaz de detectar aquellos pólipos cercanos a la cámara, donde los patrones de textura son más visibles.

Para poder observar de una forma gráfica la detección de pólipos efectuada por cada uno de los enfoques a lo largo de la base de datos se proporciona la figura 5.12. Gracias a ella se puede observar la complementariedad de ambos enfoques y la efectividad del sistema combinado diseñado.

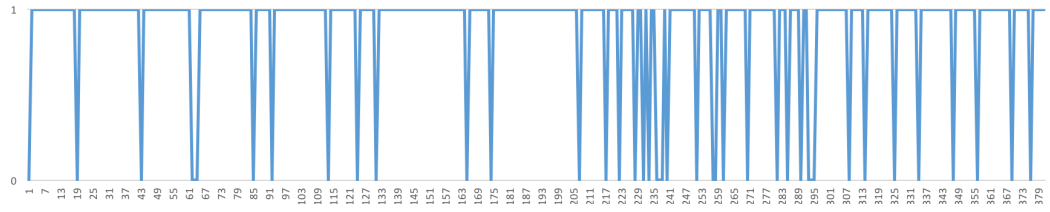
A la vista de los resultados obtenidos en la detección automática de pólipos propuesta se avala la eficacia del desarrollo llevado a cabo. De esta forma se cumple en su totalidad la hipótesis planteada en la presente tesis doctoral, la cual era la siguiente: “Es posible diseñar algoritmos de PDI que ayuden a la detección y segmentación automática de pólipos en imágenes colonoscópicas tras la verificación y evaluación de la calidad de preparación del colon del paciente”. Para continuar, en el siguiente apartado se compara el método de detección automática de pólipos propuesto respecto a los estudios existentes en el estado del arte.

5.2.2.9 **Comparativa del método de detección automática de pólipos propuesto respecto a estudios del estado del arte**

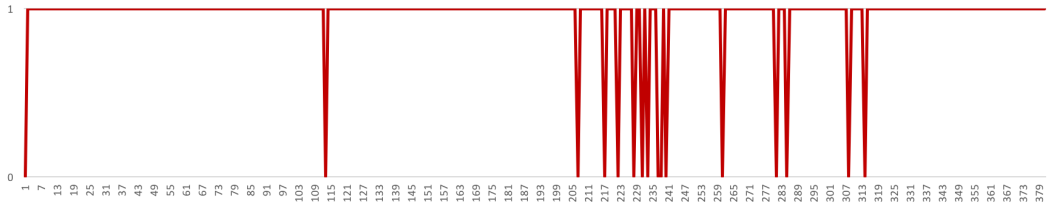
Habiéndose finalizado el análisis de los resultados del sistema de detección de pólipos diseñado, se procede a realizar una comparativa con las diferentes alternativas existentes en el estado del arte. Para ello, en primer lugar se compara la extracción y reducción de características diseñada, en segundo lugar, se compara la calidad de las segmentaciones obtenidas y por último, en tercer lugar, se compara la tasa de detección global alcanzada.



(a)



(b)



(c)

Figura 5.12: Distribución de la detección de pólipos. Los valores "1" y "0" indican la detección y fallo en la detección de pólipos de forma respectiva, correspondiéndose el eje de abscisas con las imágenes de la base de datos. a) Representa la detección de pólipos realizada por el análisis de propiedades de los bordes. b) Representa la detección de pólipos realizada por el análisis de textura. c) Representa la detección de pólipos realizada por el análisis combinado.

Comparativa de la eficacia en la clasificación de las características extraídas respecto al estado del arte

La extracción y clasificación de las propiedades de los bordes y de la textura propuesta ha demostrado una alta eficacia. En este momento es hora de realizar una comparativa con diversos estudios pertenecientes al estado del arte. Para ello se han utilizado los siguientes indicadores: precisión, sensibilidad, tasa de instancias clasificadas correctamente y área ROC. Los datos de la comparativa pueden verse en la tabla 5.35.

Tabla 5.35: Comparativa de la efectividad de las características de los bordes y de la textura extraídas respecto a los estudios existentes en la literatura.

Trabajo	**Prec.**	**Sens.**	**%**	**ROC**
[PLK15]	65.75 %	82.76 %	-	-
[ISH+13]	-	95.4 %	96.8 %	-
[MWTH13]	-	-	95.47 %	-
[CBD12]	74.04-79.59 %	88.64-92.31 %	-	-
[GYS12]	-	62-71 $\pm$ 0.29 %	88-90 $\pm$ 0.1 %	-
[BSV12a]	89.52-89.59 %	88.33-89 %	89-97.53 %	0.77-0.96
[BSV12b]	88-89 %	89 %	89-97 %	-
[LM12]	-	85.4 %	80.9 %	-
[BVS11]	-	89 %	-	0.76
[AWP+09]	-	-	-	0.92
[ANC+08]	-	76.8 %	71.3 %	-
[ACN07]	-	-	-	0.9316
[DHHM06]	-	96 %	-	-
[IMK06]	-	-	-	0.945
[KIM+03]	-	93.6 %	-	-
[TK03]	-	97.72 %	-	-
Análisis bordes	**99.5 %**	**99.5 %**	**99.46 %**	**1**
Análisis textura	**98.7 %**	**98.7 %**	**98.69 %**	**1**

Como puede apreciarse, no todas las publicaciones proporcionan los mismos indicadores, por lo que se han recopilado aquellos disponibles. Además, muchas de ellas utilizan diferentes parametrizaciones que hacen variar dichos índices, por lo que algunos de ellos son mostrados como rangos de valores. Para iniciar el proceso de comparación, se analiza en primer lugar la precisión de la clasificación.

Los resultados conseguidos tanto para la clasificación de las propiedades de los bordes como de la textura haciendo uso del sistema de reducción de dimensionalidad combinado propuesto han sido de un 99.5 % (clasificador *bayesnet*) y de un 98.7 % (clasificador *random forest*) de forma respectiva. Esto supera en gran medida lo existente en la literatura como puede verse en las valoraciones obtenidas

por [BSV12a] y [BSV12b]. Estos trabajos han conseguido las mejores valoraciones para este indicador, situándolo en los rangos [89.52-89.59 %] y [88-89 %] de forma respectiva. Los resultados conseguidos por el método propuesto suponen un incremento en la precisión. Esto se confirma mediante las diferencias conseguidas respecto a ambos trabajos, habiéndose obtenido unas diferencias de un 9.91 % y de un 9.11 % respecto al primero de los trabajos por parte de los análisis de los bordes y de la textura. En cuanto al segundo de los trabajos, las diferencias de los análisis de los bordes y de la textura se sitúan en un 10.5 % y un 9.7 % de forma respectiva.

En cuanto a la sensibilidad, tanto el análisis de los bordes como el de la textura han obtenido valores de un 99.5 % (clasificador *bayesnet*) y de un 98.7 % (clasificador *random Forest*) de forma respectiva haciendo uso del sistema de reducción combinado propuesto superando lo visto en el estado del arte. Los trabajos que mejor puntuación han obtenido para este indicador han sido [TK03] y [DHHM06] con unos valores de un 97.72 % y de un 96 % de forma respectiva. En cuanto a la mejora conseguida con el primero de estos trabajos, ésta se traduce en una diferencia de un 1.78 % respecto al análisis de los bordes y de un 0.98 % respecto al análisis de la textura. Respecto al segundo de los trabajos, la mejora se corresponde con unas diferencias de un 3.5 % y de un 2.7 % respecto a los análisis de los bordes y de la textura de forma respectiva.

Centrándonos en el porcentaje de instancias clasificadas correctamente, el análisis de los bordes ha conseguido un valor de un 99.46 % (clasificador *bayesnet*), siendo de un 98.69 % (clasificador *random forest*) para el caso del análisis de la textura haciendo uso en ambos casos del sistema de reducción de características combinado diseñado. Dentro del estado del arte, los trabajos [BSV12a] y [BSV12b] son los referentes para tal indicador. Estos han conseguido valores en los rangos [89-97.53 %] y [89-97 %], siendo ambos inferiores a los logrados por el diseño realizado. Esto supone un incremento de la eficacia que se traduce en unas diferencias de un 1.93 % y de un 1.16 % por parte de los análisis de los bordes y de la textura respecto al primero de los trabajos. En cuanto al segundo de los trabajos, las mejoras de los análisis de los bordes y de la textura se corresponden con unas diferencias de un 2.46 % y de un 1.69 % de forma respectiva.

Para finalizar, el área ROC obtenido por el análisis de los bordes y de la textura haciendo uso del sistema de reducción de características combinado diseñado

es de 1 (clasificadores *bayesnet* y *random forest*) superando a las investigaciones [IMK06], [ACN07] y [BSV12a] que han declarado unos valores de 0.945, 0.9316 y [0.77-0.96] de forma respectiva, siendo los referentes para el presente indicador. Esto supone una mejora respecto al primero de los trabajos que se corresponde con una diferencia de 0.055 puntos para el análisis de los bordes y de la textura. En cuanto al segundo de los trabajos, de la misma forma se ha conseguido una mejoría. Ésta se traduce en una diferencia de 0.068 puntos a favor de los análisis de los bordes y de la textura. En último lugar, se han mejorado los resultados del tercero de los trabajos, consiguiéndose una diferencia de 0.04 puntos por parte de los análisis de los bordes y de la textura.

Como conclusión de la comparativa, ha de destacarse el gran poder discriminante del sistema de clasificación desarrollado, el cual ha superado en todos los indicadores a las alternativas existentes en el estado del arte.

Comparativa de la calidad de la segmentación realizada respecto al estado del arte

Expuestos los resultados conseguidos en el análisis de la precisión de las áreas detectadas de los pólipos, se realiza una comparativa con diversas publicaciones de la literatura. Los indicadores utilizados han sido CAA y DC, ya que son los más comunes, aunque no son muchos los trabajos que muestran información relativa a la calidad de las segmentaciones conseguidas. Los datos de la comparativa son mostrados en la tabla 5.36.

Para comenzar se realiza la comparativa del indicador CAA. El diseño realizado ha conseguido unos valores de un 76.29 % para el análisis de los bordes, de un 93.9 % para el análisis de la textura y de un 95.83 % para la combinación de ambos. Dentro de la literatura los trabajos que han obtenido unos mejores resultados para el índice CAA han sido [BVS11] y [BSV11b] quienes declaran unos valores que oscilan en el rango de [61.91-75.79 %] y [60.71-75.79 %] de forma respectiva. Puede observarse que tanto los enfoques individuales como la combinación de ambos han conseguido superar dichos resultados. El análisis de los bordes y el de la textura junto con su combinación han conseguido unas diferencias de un 0.5 %,

Tabla 5.36: Comparativa de la calidad de segmentación conseguida por el método propuesto respecto a los estudios existentes en la literatura.

Trabajo	**CAA**	**DC**
[GYS12]	44-49 $\pm$ 0.22 %	-
[WCLS12]	52-53 $\pm$ 0.22 %	-
[BVS11]	61.91-75.79 %	36.44-55.33 %
[BSV11b]	60.71-75.79 %	45.01-55.68 %
Análisis de bordes	76.29 %	71.57 %
Análisis de textura	93.9 %	**87.31 %**
Combinación	**95.83 %**	80.47 %

un 18.11 % y un 20.04 % respecto a ambos estudios, demostrándose de esta forma la efectividad de los mismos.

Siguiendo con el índice DC, el análisis de los bordes y de la textura han obtenido unos valores de un 71.57 % y de un 87.31 % de forma respectiva, siendo de un 80.47 % para la combinación de uno y otro. Dentro de la bibliografía, al igual que en el indicador CAA, los trabajos [BVS11] y [BSV11b] han obtenido los mejores resultados, estando estos en los rangos [36.44-55.33 %] y [45.01-55.68 %] de forma respectiva. Esto supone unas diferencias de un 16.24 %, un 31.98 % y un 25.14 % por parte del análisis de los bordes y de la textura junto con su combinación respecto al primero de los trabajos y de un 15.89 %, un 31.63 % y un 24.79 % respecto al segundo. Al igual que en el caso anterior, se ha conseguido superar los resultados existentes en la literatura.

A la vista de los resultados de la comparativa, se vuelve a confirmar la mayor calidad de segmentación del método propuesto. Esto no es ninguna novedad, ya que tras la comparativa realizada sobre la eficacia en la clasificación de las características extraídas, se demostró la superioridad del presente trabajo y esta comparativa no es más que una consecuencia de ella.

Comparativa de la tasa de detección total alcanzada por el sistema propuesto respecto al estado del arte

Para concluir el proceso de comparación del trabajo realizado respecto al estado del arte se evalúa la tasa de detección global alcanzada, es decir, la cantidad de imágenes sobre las que se han detectado pólipos. Los resultados de la comparativa se muestran en la tabla 5.37.

Tabla 5.37: Comparativa de la tasa global de detección de pólipos conseguida por el método propuesto respecto a los estudios existentes en la literatura.

Trabajo	**%**	**Trabajo**	**%**	**Trabajo**	**%**
[BSFE$^+$15]	72.33 %	[BY15]	70.6 %	[HOT$^+$07]	96 %
[TGL15]	88 %	[BNSV14]	67.66 %	[TCGL14]	89 %
[WTW$^+$14]	34 %	[ZBG$^+$14]	90.77 %	[BSV13]	67.6 %
[TGL13]	73.3 %	[AWP$^+$09]	56 %	[PSS$^+$12]	82.6 %
[BSV12a]	55.44 %	[BSV12b]	61.66 %	[BSV11a]	46 %
[KB11]	74 %	[AGAL10]	81.44 %		
Análisis bordes	90.53 %	Análisis textura	89.21 %	Combinación	**96.05 %**

Las tasas de detección global de pólipos del análisis de los bordes y de la textura diseñados son de un 90.53 % y de un 89.21 % de forma respectiva, siendo de un 96.05 % para la combinación efectuada. De entre los estudios de referencia del estado del arte, los autores de [HOT$^+$07] son quienes han conseguido mejores resultados mostrando una precisión de un 96 %, aunque hay que aclarar que han utilizado una cantidad de imágenes menor. De esta forma es más sencillo conseguir tasas altas, aún así el método propuesto ha sido capaz de superarlo, aunque por un estrecho margen que se traduce en una diferencia de un 0.05 %. En cuanto al resto de los trabajos analizados, el único capaz de superar las tasas de los enfoques individuales ha sido [ZBG$^+$14] con una tasa de un 90.77 %. Esto supone unas diferencias negativas de un 0.24 % y un 1.56 % con los resultados del análisis de los bordes y de la textura de forma respectiva, siendo una diferencia positiva de un 5.28 % respecto a la combinación propuesta. Todo esto indica la robustez del sistema de detección automática de pólipos llevado a cabo.

A modo de argumentación final, cabría destacar la alta precisión del sistema de detección de pólipos diseñado en todos sus aspectos. Tanto en la extracción de características como en la calidad de la segmentación ha demostrado su eficacia y en esta última comparativa, su precisión de detección global ha quedado contrastada, por lo que se garantiza la validez del sistema desarrollado.

5.3 Sumario

En este capítulo se han mostrado los resultados obtenidos a partir del diseño descrito en el capítulo anterior. Por un lado, se ha evaluado la eficacia del sistema diseñado para la evaluación de la calidad de preparación del colon mediante la ELCB. Para ello ha sido necesario analizar los diferentes bloques que lo componen, describiéndose los resultados en los siguientes apartados: 5.2.1.1 ≪Análisis de resultados de la precisión de la detección de heces diseñada (R1)≫, 5.2.1.2 ≪Análisis de resultados de la precisión de la clasificación de heces diseñada (R2)≫, 5.2.1.3 ≪Análisis de resultados de la precisión del cálculo de la ELCB diseñado (R3)≫ y 5.2.1.4 ≪Comparativa del método de evaluación de la calidad del colon propuesto respecto a estudios del estado del arte≫.

Por otro lado, se ha evaluado la eficacia del sistema de detección automática de pólipos. Este sistema utiliza diferentes enfoques para su funcionamiento, por lo que se han evaluado los resultados de todos y cada uno de ellos, resumiéndose a continuación el proceso realizado.

Para la evaluación de la detección de pólipos mediante el análisis de los bordes se han propuesto los siguientes apartados: 5.2.2.1 ≪Análisis de la precisión de la clasificación mediante características de los bordes (R4)≫, 5.2.2.2 ≪Análisis de la precisión del área del pólipo detectada mediante el análisis de bordes (R5)≫ y 5.2.2.3 ≪Análisis de la precisión de la detección de pólipos mediante el análisis de bordes (R6)≫.

Continuando con la detección de pólipos mediante el análisis de la textura se han abordado diferentes pruebas para valorar su eficacia. Éstas se han propuesto en los siguientes apartados: 5.2.2.4 ≪Análisis de la precisión de la clasificación de las características de la textura (R7)≫, 5.2.2.5 ≪Análisis de la precisión del área del

pólipo detectada mediante el análisis de la textura (R8)» y 5.2.2.6 «Análisis de la eficacia de la detección de pólipos mediante el análisis de la textura (R9)».

Centrándonos en la valoración de la eficacia del sistema combinado de detección de pólipos se han desarrollado los siguientes apartados: 5.2.2.7 «Análisis de la precisión del área del pólipo detectada mediante el análisis combinado (R10)», 5.2.2.8 «Análisis de la eficacia de la detección de pólipos mediante el análisis combinado (R11)» y 5.2.2.9 «Comparativa del método de detección automática de pólipos propuesto respecto a estudios del estado del arte».

Para finalizar, se ha verificado el cumplimiento de los subobjetivos 3 y 5 definidos para la presente investigación (véase apartado 1.3 «Objetivos»). Estos decían de forma respectiva: "Validar la eficacia del método diseñado para la evaluación automática de la calidad de preparación del colon del paciente basada en la ELCB" y "Validar la eficacia del método diseñado para la detección y segmentación automática de pólipos en imágenes colonoscópicas".

"A conclusion is the place where you got tired thinking."

Martin H. Fischer

CAPÍTULO

6

Conclusiones

Este capítulo final muestra al lector las conclusiones derivadas del desarrollo de los algoritmos propuestos en esta tesis doctoral. En primer lugar, se hará una valoración de la hipótesis de partida definida para esta investigación, pasando a valorar el objetivo principal y los secundarios. En segundo lugar, se evaluarán tanto las conclusiones técnicas como médicas de la tesis. En tercer lugar, se describirá el impacto científico del trabajo realizado. Por último, en cuarto lugar, se realizará un trabajo valorativo acerca de las posibles líneas de actuación futuras, las cuales tendrán como punto de partida el trabajo desarrollado hasta este día, planteando aquellas mejoras o actuaciones a realizar para ampliar las funcionalidades de los métodos desarrollados.

6.1 Revisión de los objetivos propuestos

Para realizar una revisión del cumplimiento de los objetivos de la investigación llevada a cabo, se analizarán los resultados obtenidos teniendo en cuenta tanto la hipótesis de partida como el objetivo principal y sus subobjetivos. La hipótesis de partida de esta tesis doctoral era la siguiente:

"Es posible diseñar algoritmos de PDI que ayuden a la detección y segmentación automática de pólipos en imágenes colonoscópicas tras la verificación y evaluación de la calidad de preparación del colon del paciente."

Esta ha sido la hipótesis que ha dirigido este trabajo durante el tiempo empleado para su consecución, el cual acaba en este capítulo de conclusiones. A lo largo de los diferentes capítulos se ha ido validando la hipótesis, teniendo especial importancia los capítulos 4 ≪Diseño≫ y 5 ≪Resultados≫, los cuales contienen el diseño de los bloques necesarios para la validación de la hipótesis, así como los resultados finales que se obtuvieron en su demostración. Así, se puede afirmar que la hipótesis de partida ha sido validada, lo que conlleva a decir que el desarrollo de algoritmos de PDI permite la evaluación de la calidad de preparación del colon del paciente, además de la detección y segmentación automática de pólipos de una forma correcta y efectiva.

Junto con la hipótesis de partida, se definió un objetivo principal, que a su vez se compone de 5 subobjetivos. En primer lugar se comenzará con el objetivo principal que es el siguiente:

"Diseñar y validar algoritmos de PDI para la verificación y evaluación de la calidad de preparación del colon basada en parámetros objetivos y detección automática de pólipos en imágenes colonoscópicas."

El objetivo principal de este trabajo es el diseño y validación de algoritmos de PDI para la verificación y evaluación de la calidad de preparación del colon basada en parámetros objetivos y la detección automática de pólipos en imágenes colonoscópicas. En este sentido, se han desarrollado múltiples algoritmos, siempre bajo las directrices de los diferentes endoscopistas participantes en la investigación, que permiten por un lado, la valoración automatizada de la preparación del colon del paciente mediante la ELCB y por otro lado, la detección y segmentación automatizada de pólipos. Los algoritmos desarrollados servirán de apoyo al diagnóstico médico aportando datos basados en parámetros objetivos. En cuanto a la evaluación automatizada de la preparación del colon del paciente, el desarrollo realizado permitirá la estandarización y automatización mediante parámetros objetivos de la

ELCB, que es utilizada en los informes de endoscopia que redactan tras cada colonoscopia. Hasta este momento la evaluación era dependiente del especialista lo que generaba los siguientes inconvenientes:

- La eficacia de las métricas de valoración de la calidad de preparación del colon quedaba reducida, ya que una misma colonoscopia podía obtener una valoración diferente dependiendo del especialista que la valore.
- Imposibilidad de comparar las valoraciones obtenidas por diferentes centros de salud.
- Imposibilidad de evaluar la eficacia de los protocolos de preparación del colon del paciente para la realización de la colonoscopia.

Centrándonos en la detección y segmentación automatizada de pólipos, dada la estructura interna del colon, con múltiples pliegues y recovecos, es una ardua tarea para el endoscopista la detección y extirpación de pólipos. La principal problemática a la que hay que enfrentarse son los **pólipos perdidos**, es decir, aquellos no detectados en la colonoscopia y que pueden derivar en CCR. Mediante los algoritmos desarrollados en esta tesis se permite la evaluación de las imágenes colonoscópicas detectando los pólipos presentes. Esto es de gran utilidad para los especialistas, ya que se reducirá la tasa de pólipos perdidos y con ello disminuirán los cánceres de intervalo.

Como se ha comentado con anterioridad, el objetivo principal se ha dividido en 5 subobjetivos, los cuales se comentarán a continuación:

Subobjetivo 1: *"Crear una base de datos de vídeos e imágenes colonoscópicas."*

Durante el proceso de desarrollo de la tesis doctoral que se presenta se ha realizado una recopilación de vídeos e imágenes colonoscópicas. Como ya se ha presentado en el apartado 3.4 ≪Tamaño muestral≫ del capítulo 3 ≪Base de datos≫, se han recogido 145 vídeos y 700 imágenes colonoscópicas de diferente tipología: sin lesiones, con lesiones y con mala preparación. La base de datos creada ha sido

utilizada en el diseño y desarrollo de los algoritmos presentados en este trabajo, siendo de vital importancia en el proceso.

Por otra parte, en las líneas futuras de la investigación, las cuales se presentan en el apartado 6.5 ≪Líneas futuras≫ del presente capítulo, se seguirá utilizando el contenido de la base de datos generada.

Subobjetivo 2: *"Diseñar un método para la evaluación automática de la calidad de preparación del colon del paciente basado en la ELCB.*

La primera de las contribuciones de la presente tesis doctoral es el diseño de un método para la evaluación automática de la preparación del colon del paciente basado en la ELCB. Como confirman los apartados 4.1.2 y 4.2.2 ≪Evaluación de la calidad de preparación del colon mediante la ELCB (B)≫ del capítulo 4 ≪Diseño≫, se ha logrado la consecución de este objetivo. Para ello se ha realizado una segmentación automática de las heces presentes en las imágenes colonoscópicas, además de realizar una clasificación entre diferentes tipos de heces, así como propone la propia escala utilizada. Además, se ha diseñado una metodología para automatizar el cálculo de la ELCB. Gracias a este desarrollo se consigue una estandarización de la evaluación de la calidad de preparación del colon de los pacientes, una necesidad vital hasta la fecha.

Subobjetivo 3: *"Validar la eficacia del método diseñado para la evaluación automática de la calidad de preparación del colon del paciente basado en la ELCB."*

Tras realizar el diseño de un método para la evaluación automática de la calidad de preparación del colon del paciente basado en la ELCB es necesaria su validación. Para ello se ha contado con la colaboración de diferentes endoscopistas procedentes de diversos centros de salud del País Vasco quienes han realizado una valoración de los resultados obtenidos por el método desarrollado. Los endoscopistas han proporcionado un conjunto de imágenes, de las cuales han proporcionado la valoración de la ELCB y el porcentaje de heces líquidas, sólidas y tintadas presentes, siendo cotejadas con los resultados obtenidos por el método diseñado. Toda la

información sobre este subobjetivo ha sido presentada en el apartado 5.2.1 ≪Análisis de resultados del sistema de evaluación de la calidad de preparación del colon mediante la ELCB≫ del capítulo 5 ≪Resultados≫.

Subobjetivo 4: *"Diseñar un método para la detección y segmentación automática de pólipos en imágenes colonoscópicas."*

La segunda de las contribuciones del presente trabajo es el diseño de un método para la detección y segmentación automática de pólipos en imágenes colonoscópicas. Para ello se ha diseñado un sistema que combina el análisis de los bordes presentes en las imágenes y el análisis de la textura de las mismas. De esta forma se hace posible el análisis automático de imágenes colonoscópicas, dando de esta forma un apoyo al especialista, que en muchos casos se ve desbordado por la carga de trabajo. Con este desarrollo se pretende reducir la tasa de pólipos perdidos que pueden derivar en un cáncer de intervalo, ya que es el principal riesgo existente en la colonoscopia. Todo esto ha sido mostrado en los apartados 4.1.3 y 4.2.3 ≪Detección automática de pólipos (C)≫ del capítulo 4 ≪Diseño≫.

Subobjetivo 5: *"Validar la eficacia del método diseñado para la detección y segmentación automática de pólipos en imágenes colonoscópicas."*

Una vez finalizado el diseño del método propuesto para la detección y segmentación automática de pólipos en imágenes colonoscópicas es necesaria su validación. Para ello se ha contado con la base de datos *CVC Colon Database*, la cual ha sido utilizada en múltiples investigaciones enfocadas a la detección automática de pólipos. Se ha realizado una comparativa entre los resultados obtenidos por el método propuesto y aquellos existentes en la literatura, mejorando lo existente en múltiples aspectos. Toda la información sobre este subobjetivo ha sido proporcionada en el apartado 5.2.2 ≪Análisis de la precisión del sistema de detección de pólipos diseñado≫ del capítulo 5 ≪Resultados≫.

6.2 Conclusiones técnicas

Comenzando con las conclusiones técnicas de esta tesis, se ha contribuido con la realización de un nuevo método para la evaluación automática de la preparación del colon del paciente basado en la ELCB, que realiza una segmentación automática de las heces, además de clasificar a éstas en los diferentes tipos descritos por la escala: líquidas, sólidas y tintadas. Asimismo, también se ha realizado una contribución mediante el desarrollo de un nuevo método para la detección y segmentación automática de pólipos colorrectales basado en la combinación del análisis de los bordes y de la textura de las imágenes.

Gracias a los desarrollos realizados en la investigación presentada, se proporciona a la comunidad científica alternativas para continuar con la línea de trabajo llevada a cabo.

6.3 Conclusiones médicas

Gracias a los algoritmos diseñados en la presente tesis doctoral, las unidades de endoscopia contarán con una herramienta de ayuda al diagnóstico que aportará las siguientes funcionalidades:

- Evaluación automática de la preparación del colon basada en la ELCB: las unidades de endoscopia contarán con una herramienta que estandariza el cálculo de la ELCB, superando así su principal limitación, la subjetividad del evaluador. De esta forma, se podrán realizar comparativas entre las valoraciones obtenidas por diferentes centros de salud y así mejorar la calidad del proceso de realización de las pruebas.

- Detección y segmentación automática de pólipos: los endoscopistas contarán con una herramienta que permitirá reducir el número de pólipos perdidos y cánceres de intervalo, repercutiendo de manera favorable en la salud de los pacientes.

6.4 Impacto científico

En las siguientes líneas se enumera todo aquello generado en relación al trabajo de investigación realizado durante los años de desarrollo del mismo. Se compone de: artículos en revistas científicas, artículos en congresos y conferencias internacionales, capítulos de libro y proyectos que han hecho posible, mediante financiación pública, la consecución de esta tesis doctoral.

6.4.1 Artículos en revistas científicas

En las tablas 6.1, 6.2 y 6.3 se muestran los artículos publicados y enviados a revistas científicas internacionales en la fecha de presentación de esta tesis.

Tabla 6.1: Publicación 1.

Título	Color and texture based stool detection and classification in Colonoscopy for the automatized calculation of Boston Bowel Preparation Scale
Autores	Alain Sánchez-González, Begonya Garcia-Zapirain
Revista	Journal of Medical Imaging and Health Informatics. vol 6, Nº 7
IF (2015)	0.877 (Q4)
Fecha	2016
DOI	10.1166/jmihi.2016.1877
Enlace	http://www.aspbs.com/jmihi.html

6.4.2 Artículos en congresos y conferencias internacionales

Junto a los artículos en revistas internacionales con impacto, la investigación ha sido presentada en un congreso internacional y una conferencia web. Toda esta información se describe en las tablas 6.4 y 6.5.

Tabla 6.2: Publicación 2 (en revisión).

Título	Novel algorithm for polyp detection in colonoscopy images using combined edge and texture analysis
Autores	Alain Sánchez-González, Begonya Garcia-Zapirain
Revista	IEEE Transactions on Medical Imaging
IF (2015)	3.76 (Q1)

Tabla 6.3: Publicación 3 (en revisión).

Título	Automatized colon polyp segmentation via contour region analysis
Autores	Alain Sánchez-González, Begonya Garcia-Zapirain
Revista	Medical Image Analysis
IF (2015)	4.565 (Q1)

Tabla 6.4: Contribución en congreso.

Título	Color and texture based stool detection and classification in Colonoscopy for the automatized calculation of Boston Bowel Preparation Scale
Autores	Alain Sánchez-González, Begonya Garcia-Zapirain
Congreso	International Conference on Biomedical Engineering and Biotechnology (ICBEB)
Fecha	1-4 de agosto de 2016
Enlace	http://www.icbeb.org

6.4.3 Capítulos de libros

Además de las publicaciones científicas y las contribuciones en congresos y conferencias realizadas, se ha escrito un capítulo de libro que describe el sistema de preprocesado diseñado. La información del mismo se muestra en la tabla 6.6.

Tabla 6.5: Contribución en conferencia web.

Título	Case study of preprocessing techniques applied to colonoscopy images for a Computer Aided Diagnosis
Autores	Alain Sánchez-González, Begonya Garcia-Zapirain
Congreso	Educating Students in Engineering and Medicine (ESEM)
Fecha	2 de diciembre de 2016
Enlace	http://esem.eu/web-conf-1/

Tabla 6.6: Capítulo de libro (en revisión).

Título	Colonoscopy image preprocessing for the development of computer aided diagnosis tools
Autores	Alain Sánchez-González, Begonya Garcia-Zapirain
Libro	Surgical Robotics
Editorial	INTECH
Enlace	http://www.intechopen.com

6.4.4 Proyectos relacionados

La investigación realizada no se hubiese podido poner en marcha sin la financiación de la convocatoria "Ayudas a proyectos de investigación en salud" del Gobierno Vasco, que apostó por el proyecto "Solución tecnológica para el seguimiento y adecuación de la calidad de la colonoscopia en el cribado de cáncer colorrectal", base de esta tesis doctoral. Todos los datos de esta ayuda son mostrados en la tabla 6.7.

6.5 Líneas futuras

La investigación abierta en este trabajo supone un gran avance en el diseño de algoritmos para la evaluación automática de la preparación del colon así como para la detección y segmentación automática de pólipos. Los resultados obtenidos han

Tabla 6.7: Proyecto relacionado con la tesis doctoral que se presenta.

Título	Solución tecnológica para el seguimiento y adecuación de la calidad de la colonoscopia en el cribado de cáncer colorrectal
Ayuda	Ayudas a proyectos de investigación en salud
Presupuesto	47.000 €
Duración	diciembre 2014 - noviembre 2017
Enlace	http://evida.deusto.es/support_platform/colonograma/login

sido prometedores, aunque esto no significa que no existan ciertas áreas de mejora y futuras funcionalidades, tema que se abordará en el presente apartado.

En primer lugar, se ha detectado un área de mejora de los algoritmos diseñados para el preprocesado de las imágenes. Más en concreto, a la hora de tratar los reflejos especulares presentes en las imágenes colonoscópicas se ha optado por realizar una reconstrucción. Esta técnica realiza una sustitución de los valores de los píxeles especulares por el de los valores medios de los píxeles vecinos no especulares, por lo que es necesario aplicar un suavizado sobre estas zonas para evitar cambios abruptos entre las intensidades de los nuevos píxeles y sus vecinos. Los algoritmos desarrollados aplican un mismo suavizado, utilizando la misma parametrización a todos los reflejos especulares. Por este motivo, una posible mejora radica en la realización de un suavizado adaptativo en función del tamaño del reflejo especular. De esta manera, cuanto mayor área tenga el reflejo especular, mayor suavizado se realizará. Esta mejora realizaría un suavizado más eficiente afectando en menor grado a los píxeles que puedan contener información relevante.

En segundo lugar, otro de los principales problemas en la detección automática de pólipos son los bordes generados por los vasos sanguíneos. La detección y segmentación automática de pólipos propuesta en esta tesis doctoral no se ha visto afectada de forma directa por la presencia de estos, ya que para el análisis de la textura han sido imperceptibles y para el análisis de los bordes, los contornos de los vasos y pólipos tienen propiedades diferentes. La problemática radica en la necesidad de realizar el cómputo de las operaciones necesarias para el análisis de los bordes generados por ellos. Por este motivo, se cree que la aplicación de métodos

para mitigar sus efectos repercutiría de manera beneficiosa en la eficiencia de los algoritmos, reduciendo el tiempo de cómputo.

En tercer lugar, la tesis doctoral presentada se centra en el diseño de algoritmos sobre imágenes colonoscópicas. Si bien, es una realidad que las pruebas médicas como la colonoscopia son registradas mediante vídeos, aunque estos no dejan de ser una secuencia de imágenes mostradas de forma consecutiva, por lo que la base algorítmica es la misma. Para poder adaptar el funcionamiento de los métodos diseñados a su uso sobre vídeos, la principal funcionalidad a diseñar es el análisis frecuencial de las imágenes. De esta forma se podrán descartar aquellas que contengan poca información debido al ruido o mal enfoque.

Por último y en cuarto lugar, teniendo la intención de incorporar los métodos desarrollados en una herramienta para su uso diario en las unidades de endoscopia, es posible mejorar la eficiencia computacional del código. El diseño realizado tiene una arquitectura paralela, en la que la evaluación de la calidad de preparación del colon se realiza de forma simultánea con la detección y segmentación automática de pólipos. Sin embargo, es posible aumentar la velocidad de ejecución mediante el uso de operaciones concurrentes, siendo un claro ejemplo de ello los bucles *for* que en ciertos casos pueden ser sustituidos o modificados para la utilización de su alternativa paralela *parfor*. Otra posibilidad para mejorar la velocidad de ejecución es la utilización de tarjetas gráficas especializadas en cálculos de coma flotante. Éstas poseen una arquitectura especialmente diseñada para agilizar estos cálculos siendo mucho más rápidas que los procesadores convencionales.

Por lo tanto, y a modo de resumen, se puede afirmar que existen diversas líneas futuras para la investigación que se presenta. Éstas abren la posibilidad de realizar nuevos proyectos de investigación/aplicación que serán innovadores y que tendrán un gran impacto en la comunidad científica.

Bibliografía

[AAGL11] Mirko Arnold, Stefan Ameling, Anarta Ghosh, and Gerard Lacey. Quality improvement of endoscopy videos. In *Proceedings of the 8th IASTED International Conference on Biomedical Engineering, Insbruck, Austria*, 2011. 51, 54

[ACN07] Luís A Alexandre, Joao Casteleiro, and Nuno Nobreinst. Polyp detection in endoscopic video using svms. In *European Conference on Principles of Data Mining and Knowledge Discovery*, pages 358–365. Springer, 2007. 99, 107, 312, 314

[AEC] Asociación Española Contra el Cáncer. `https://www.aecc.es`. @ONLINE. Fecha de acceso: 12-12-2016. 2

[AGAL10] Mirko Arnold, Anarta Ghosh, Stefan Ameling, and Gerard Lacey. Automatic segmentation and inpainting of specular highlights for endoscopic imaging. *Journal on Image and Video Processing*, 2010:9, 2010. 316

[ANC+08] Luis Alexandre, Nuno Nobre, João Casteleiro, et al. Color and position versus texture features for endoscopic polyp detection. In *BioMedical Engineering and Informatics, 2008. BMEI 2008. International Conference on*, volume 2, pages 38–42. IEEE, 2008. 312

[ARGF+12] L. Angulo-Rodrguez, Xuexin Gao, Dobromir Filip, Christopher N. Andrews, and Martin P. Mintchev. Automated system

for quantifying the level of preparation in colonoscopy. *ITHEA Journal*, 1:226–235, 2012. 35, 39, 46, 89

[Aro04] Craig A. Aronchick. Bowel preparation scale. *Gastrointestinal endoscopy*, 60(6):1037–1038, 2004. 33

[ASG] American Society for Gastrointestinal Endoscopy. `http://www.asge.org`. @ONLINE. Fecha de acceso: 22-11-2016. 30

[AWP+09] Stefan Ameling, Stephan Wirth, Dietrich Paulus, Gerard Lacey, and Fernando Vilarino. Texture-based polyp detection in colonoscopy. In *Bildverarbeitung für die Medizin 2009*, pages 346–350. Springer, 2009. 101, 107, 312, 316

[BNSV14] Jorge Bernal, Joan Manel Núñez, F Javier Sánchez, and Fernando Vilariño. Polyp segmentation method in colonoscopy videos by means of msa-dova energy maps calculation. In *Clinical Image-Based Procedures. Translational Research in Medical Imaging*, pages 41–49. Springer, 2014. 94, 107, 316

[BS87] David S. Bright and Eric B. Steel. Two-dimensional top hat filter for extracting spots and spheres from digital images. *Journal of Microscopy*, 146(2):191–200, May 1987. 52

[BSFE+15] Jorge Bernal, F Javier Sánchez, Gloria Fernández-Esparrach, Debora Gil, Cristina Rodríguez, and Fernando Vilariño. Wm-dova maps for accurate polyp highlighting in colonoscopy: Validation vs. saliency maps from physicians. *Computerized Medical Imaging and Graphics*, 43:99–111, 2015. 95, 107, 316

[BSV11a] Jorge Bernal, F. Javier Sánchez, and Fernando Vilariño. Depth of Valleys Accumulation Algorithm for Object Detection. In *CCIA*, pages 71–80, 2011. 72, 92, 107, 316

[BSV11b] Jorge Bernal, Javier Sánchez, and Fernando Vilarino. A region segmentation method for colonoscopy images using a model of polyp appearance. In *Pattern Recognition and Image Analysis*, pages 134–142. Springer, 2011. 51, 314, 315

[BSV12a] Jorge Bernal, Javier Sánchez, and Fernando Vilarino. Integration of valley orientation distribution for polyp region identification in colonoscopy. In *Abdominal Imaging. Computational and Clinical Applications*, pages 76–83. Springer, 2012. 94, 107, 312, 313, 314, 316

[BSV12b] Jorge Bernal, Javier Sánchez, and Fernando Vilarino. Towards automatic polyp detection with a polyp appearance model. *Pattern Recognition*, 45(9):3166–3182, 2012. 51, 93, 107, 115, 312, 313, 316

[BSV13] Jorge Bernal, Javier Sánchez, and Fernando Vilarino. Impact of image preprocessing methods on polyp localization in colonoscopy frames. In *Engineering in Medicine and Biology Society (EMBC), 2013 35th Annual International Conference of the IEEE*, pages 7350–7354. IEEE, 2013. 49, 52, 54, 139, 146, 316

[BUM] Boston University Medical Campus. `http://www.bumc.bu.edu`. @ONLINE. Fecha de acceso: 14-12-2016. 36

[BVS11] Jorge Bernal, Fernando Vilariño, and F. Javier Sanchez. *Towards Intelligent Systems for Colonoscopy*, volume 1. Intech, 2011. 312, 314, 315

[BY15] Seung-Hwan Bae and Kuk-Jin Yoon. Polyp detection via imbalanced learning and discriminative feature learning. *IEEE transactions on medical imaging*, 34(11):2379–2393, 2015. 100, 107, 316

[Can86] John Canny. A computational approach to edge detection. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, (6):679–698, 1986. 68

[CBD12] Filipe Condessa and Jose Bioucas-Dias. Segmentation and detection of colorectal polyps using local polynomial approximation. In *International Conference Image Analysis and Recognition*, pages 188–197. Springer, 2012. 90, 312

[CC06] Miguel T. Coimbra and JP Silva Cunha. MPEG-7 visual descriptors—contributions for automated feature extraction in capsule endoscopy. *Circuits and Systems for Video Technology, IEEE Transactions on*, 16(5):628–637, 2006. 106, 107

[Cox72] David R Cox. Regression models and life-tables. *Journal of the Royal Statistical Society. Series B (Methodological)*, pages 187–220, 1972. 87

[CTS+15] Audrey H Calderwood, Katherine D Thompson, Paul C Schroy, David A Lieberman, and Brian C Jacobson. Good is better than excellent: bowel preparation quality and adenoma detection rates. *Gastrointestinal endoscopy*, 81(3):691–699, 2015. 87, 89

[CV95] Corinna Cortes and Vladimir Vapnik. Support-vector networks. *Machine learning*, 20(3):273–297, 1995. 88

[DH72] Richard O. Duda and Peter E. Hart. Use of the Hough transformation to detect lines and curves in pictures. *Communications of the ACM*, 15(1):11–15, 1972. 50

[DHHM06] B. V. Dhandra, Ravindra Hegadi, Mallikarjun Hangarge, and V. S. Malemath. Analysis of abnormality in endoscopic images using combined HSI color space and watershed segmentation. In *Pattern Recognition, 2006. ICPR 2006. 18th International Conference on*, volume 4, pages 695–698. IEEE, 2006. 45, 312, 313

[DM77] D. W. Day and B. C. Morson. The adenoma-carcinoma sequence. *Major problems in pathology*, 10:58–71, 1977. 18

[dNPF10] J. Bernal del Nozal, J. Sánchez Pujadas, and F. Vilariño Freire. Reduction of pattern search area in colonoscopy images by merging non-informative regions. 2010. 51

[DV05] Minh N Do and Martin Vetterli. The contourlet transform: an efficient directional multiresolution image representation. *Image Processing, IEEE Transactions on*, 14(12):2091–2106, 2005. 104

[DVL08] Rozenn Dahyot, Fernando Vilariño, and Gerard Lacey. Improving the quality of color colonoscopy videos. *Journal on Image and Video Processing*, 2008:15, 2008. 50

[ESG] European Society of Gastrointestinal Endoscopy. `http://www.esge.com`. @ONLINE. Fecha de acceso: 23-11-2016. 30

[F+77] Werner Frei et al. Fast boundary detection: A generalization and a new algorithm. *IEEE Transactions on Computers*, (10):988–998, 1977. 64, 67

[FDA] U.S. Food and Drug Administration. `http://www.fda.gov/AboutFDA/EnEspanol/`. @ONLINE. Fecha de acceso: 13-12-2016. 29

[FPTF10] Isabel N Figueiredo, Surya Prasath, Yen-Hsi R Tsai, and Pedro N Figueiredo. Automatic detection and segmentation of colonic polyps in wireless capsule images. *ICES REPORT*, 10:36, 2010. 90

[Gev03] Theo Gevers. Reflectance-based classification of color edges. In *Computer Vision, 2003. Proceedings. Ninth IEEE International Conference on*, pages 856–861. IEEE, 2003. 53

[GHFH10] Lladó F. González-Huix, Francesch M. Figa, and Nadal C. Huertas. [Essential quality criteria in the indication and performance

of colonoscopy]. *Gastroenterologia y hepatologia*, 33(1):33–42, 2010. 33

[GPT+12] Sebastian Gross, Stephan Palm, Jens JW Tischendorf, Alexander Behrens, Christian Trautwein, and Til Aach. Automated classification of colon polyps in endoscopic image data. In *SPIE Medical Imaging*, pages 83150W–83150W. International Society for Optics and Photonics, 2012. 47, 52, 55

[GYS12] M. Ganz, Xiaoyun Yang, and G. Slabaugh. Automatic Segmentation of Polyps in Colonoscopic Narrow-Band Imaging Data. *IEEE Transactions on Biomedical Engineering*, 59(8):2144–2151, August 2012. 47, 53, 312, 315

[GZZ10] Zhenhua Guo, Lei Zhang, and David Zhang. A completed modeling of local binary pattern operator for texture classification. *Image Processing, IEEE Transactions on*, 19(6):1657–1663, 2010. 103, 107

[HOL+05] Sae Hwang, JungHwan Oh, JeongKyu Lee, Yu Cao, Wallapak Tavanapong, Danyu Liu, Johnny Wong, and Piet C. de Groen. Automatic measurement of quality metrics for colonoscopy videos. In *Proceedings of the 13th annual ACM international conference on Multimedia*, pages 912–921. ACM, 2005. 84, 89

[HOT+07] Sae Hwang, JungHwan Oh, Wallapak Tavanapong, Johnny Wong, and Piet C. de Groen. Polyp detection in colonoscopy video using elliptical shape feature. In *Image Processing, 2007. ICIP 2007. IEEE International Conference on*, volume 2, pages II–465. IEEE, 2007. 92, 107, 316

[HOT+08] Sae Hwang, JungHwan Oh, Wallapak Tavanapong, Johnny Wong, and Piet C. de Groen. Stool detection in colonoscopy videos. In *Engineering in Medicine and Biology Society, 2008. EMBS 2008. 30th Annual International Conference of the IEEE*, pages 3004–3007. IEEE, 2008. 87

[HS85] Robert M Haralick and Linda G Shapiro. Image segmentation techniques. *Computer vision, graphics, and image processing*, 29(1):100–132, 1985. 76

[HS99] Mark A Hall and Lloyd A Smith. Feature selection for machine learning: Comparing a correlation-based filter approach to the wrapper. In *FLAIRS conference*, volume 1999, pages 235–239, 1999. 181

[HSH05] Adam Huang, Ronald M Summers, and Amy K Hara. Surface curvature estimation for automatic colonic polyp detection. In *Medical Imaging*, pages 393–402. International Society for Optics and Photonics, 2005. 90, 107

[IHKM12] Noor A. Ibraheem, Mokhtar M. Hasan, Rafiqul Z. Khan, and Pramod K. Mishra. Understanding color models: a review. *ARPN Journal of Science and Technology*, 2(3):265–75, 2012. 43

[IKK+03] H. Inoue, H. Kashida, S. Kudo, M. Sasako, T. Shimoda, H. Watanabe, S. Yoshida, M. Guelrud, C. J. Lightdale, K. Wang, and others. The Paris endoscopic classification of superficial neoplastic lesions: esophagus, stomach, and colon: November 30 to December 1, 2002. *Gastrointest Endosc*, 58(6 Suppl):S3–S43, 2003. 22

[Ima] ImageJ imagej (s.f.). `http://imagej.net/Welcome`. Fecha de acceso: 14-08-2016. 42

[IMK06] Dimitris K Iakovidis, Dimitris E Maroulis, and Stavros A Karkanis. An intelligent system for automatic detection of gastrointestinal adenomas in video endoscopy. *Computers in Biology and Medicine*, 36(10):1084–1103, 2006. 312, 314

[ISH+13] Yuji Iwahori, Takayuki Shinohara, Akira Hattori, Robert J Woodham, Shinji Fukui, MK Bhuyan, and Kunio Kasugai. Automatic polyp detection in endoscope images using a hessian filter. *Proceedings of MVA*, pages 21–24, 2013. 100, 312

[JHA+12] R. Jover, M. Herraiz, O. Alarcon, E. Brullet, L. Bujanda, M. Bustamante, R. Campo, R. Carreño, A. Castells, J. Cubiella, and others. Clinical practice guidelines: quality of colonoscopy in colorectal cancer screening. *Endoscopy*, 44(4):444, 2012. 33

[JLC+06] Anna Jerebko, Sarang Lakare, Pascal Cathier, Senthil Periaswamy, and Luca Bogoni. Symmetric curvature patterns for colonic polyp detection. In *Medical Image Computing and Computer-Assisted Intervention–MICCAI 2006*, pages 169–176. Springer, 2006. 90, 107

[JM51] R. J. Jackman and Charles W. Mayo. The adenoma-carcinoma sequence in cancer of the colon. *Surgery, gynecology & obstetrics*, 93(3):327–330, 1951. 18

[KB11] Alexandros Karargyris and Nikolaos Bourbakis. Detection of small bowel polyps and ulcers in wireless capsule endoscopy videos. *Biomedical Engineering, IEEE Transactions on*, 58(10):2777–2786, 2011. 316

[KD03] J. Kang and R. Doraiswami. Real-time image processing system for endoscopic applications. In *Electrical and Computer Engineering, 2003. IEEE CCECE 2003. Canadian Conference on*, volume 3, pages 1469–1472. IEEE, 2003. 91, 107

[KHN+94] S. Kudo, S. Hirota, T. Nakajima, S. Hosobe, H. Kusaka, T. Kobayashi, M. Himori, and A. Yagyuu. Colorectal tumours and pit pattern. *Journal of Clinical Pathology*, 47(10):880–885, 1994. 23

[KIM+03] Stavros A. Karkanis, Dimitrios K. Iakovidis, Dimitrios E. Maroulis, Dimitris A. Karras, and M. Tzivras. Computer-aided tumor detection in endoscopic video using color wavelet features. *Information Technology in Biomedicine, IEEE Transactions on*, 7(3):141–152, 2003. 101, 102, 107, 312

[Kir71] Russell A. Kirsch. Computer determination of the constituent structure of biological images. *Computers and Biomedical Research*, 4(3):315 – 328, 1971. 64, 66

[KJ97] Ron Kohavi and George H John. Wrappers for feature subset selection. *Artificial intelligence*, 97(1):273–324, 1997. 180

[KRK+10] Michal F. Kaminski, Jaroslaw Regula, Ewa Kraszewska, Marcin Polkowski, Urszula Wojciechowska, Joanna Didkowska, Maria Zwierko, Maciej Rupinski, Marek P. Nowacki, and Eugeniusz Butruk. Quality indicators for colonoscopy and the risk of interval cancer. *New England Journal of Medicine*, 362(19):1795–1803, 2010. 87, 89

[KYC+98] S. M. Krishnan, X. Yang, K. L. Chan, S. Kumar, and P. M. Y. Goh. Intestinal abnormality detection from endoscopic images. In *Engineering in Medicine and Biology Society, 1998. Proceedings of the 20th Annual International Conference of the IEEE*, volume 2, pages 895–898. IEEE, 1998. 90, 107

[L+92] Kurt Lewin et al. La investigación-acción y los problemas de las minorías. *La investigación-acción participativa: Inicios y desarrollos*, pages 13–25, 1992. 6

[Lat03] Antonio Latorre. *Investigación acción*. Graó, 2003. 6

[LCD+09] Edwin J. Lai, Audrey H. Calderwood, Gheorghe Doros, Oren K. Fix, and Brian C. Jacobson. The Boston bowel preparation scale: a valid and reliable instrument for colonoscopy-oriented research. *Gastrointestinal endoscopy*, 69(3):620–625, 2009. 5, 11, 33

[Lil67] Hubert W Lilliefors. On the kolmogorov-smirnov test for normality with mean and variance unknown. *Journal of the American Statistical Association*, 62(318):399–402, 1967. 163

[LM09] Baopu Li and Max Q-H Meng. Texture analysis for ulcer detection in capsule endoscopy images. *Image and Vision computing*, 27(9):1336–1342, 2009. 104, 107

[LM12] Bao-Pu Li and Max Qing-Hu Meng. Comparison of several texture features for tumor detection in ce images. *Journal of medical systems*, 36(4):2463–2469, 2012. 103, 107, 312

[LMH12] Baopu Li, M.Q.-H. Meng, and Chao Hu. A comparative study of endoscopic polyp detection by textural features. In *2012 10th World Congress on Intelligent Control and Automation (WCICA)*, pages 4671–4675, July 2012. 44

[Mat] MathWorks mathworks (s.f.). `http://es.mathworks.com`. Fecha de acceso: 14-07-2016. 41

[MH80] David Marr and Ellen Hildreth. Theory of edge detection. *Proceedings of the Royal Society of London B: Biological Sciences*, 207(1167):187–217, 1980. 71

[MIKK03] Dimitrios E. Maroulis, Dimitrios K. Iakovidis, Stavros A. Karkanis, and Dimitris A. Karras. CoLD: a versatile detection system for colorectal lesions in endoscopy video-frames. *Computer Methods and Programs in Biomedicine*, 70(2):151–166, 2003. 101, 107

[MOT+12] Jayantha Muthukudage, JungHwan Oh, Wallapak Tavanapong, Johnny Wong, and Piet C. de Groen. Color based stool region detection in colonoscopy videos for quality measurements. In *Advances in Image and Video Technology*, pages 61–72. Springer, 2012. 37, 39, 45, 89, 283

[MTE+09] Sánchez S. Morán, E. Torrella, Delgado P. Esteban, Madrid R. Baños, A. Garcia, A. Ono, Cuadrado E. Pérez, P. Parra, Quevedo J. Cruzado, Riquelme F. Pérez, and others. Colonoscopy quality assessment. *Revista española de enfermedades digestivas:*

Órgano oficial de la Sociedad Española de Patología Digestiva, 101(2):107–12, 2009. 33

[MWTH13] Siyamalan Manivannan, Ruixuan Wang, Emanuele Trucco, and Adrian Hood. Automatic normal-abnormal video frame classification for colonoscopy. In *2013 IEEE 10th International Symposium on Biomedical Imaging*, pages 644–647. IEEE, 2013. 85, 89, 312

[OHC+09] JungHwan Oh, Sae Hwang, Yu Cao, Wallapak Tavanapong, Danyu Liu, Johnny Wong, and Piet C. de Groen. Measuring objective quality of colonoscopy. *Biomedical Engineering, IEEE Transactions on*, 56(9):2190–2196, 2009. 84, 89

[OMS] Organización Mudial de la Salud. `http://www.who.int/es/`. @ONLINE. Fecha de acceso: 10-09-2016. 19

[Ope] OpenCV open source computer vision (s.f.). `http://opencv.org`. Fecha de acceso: 16-07-2016. 42

[OPH96] Timo Ojala, Matti Pietikäinen, and David Harwood. A comparative study of texture measures with classification based on featured distributions. *Pattern recognition*, 29(1):51–59, 1996. 103, 107

[OPM02] Timo Ojala, Matti Pietikainen, and Topi Maenpaa. Multiresolution gray-scale and rotation invariant texture classification with local binary patterns. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 24(7):971–987, 2002. 103, 107

[Ots75] Nobuyuki Otsu. A threshold selection method from gray-level histograms. *Automatica*, 11(285-296):23–27, 1975. 75

[Pea84] Judea Pearl. Heuristics: intelligent search strategies for computer problem solving. 1984. 181

[PLC98] Luis PRIETO, Rosa LAMARCA, and Alfonso CASADO. La evaluación de la fiabilidad en las observaciones clínicas: el coeficiente de correlación intraclase. *Medicina clínica*, 110(4):142–145, 1998. 165

[PLK15] Sungheon Park, Myunggi Lee, and Nojun Kwak. Polyp detection in colonoscopy videos using deeply-learned hierarchical features. *Seoul National University*, 2015. 69, 107, 312

[Pre70] Judith MS Prewitt. Object enhancement and extraction. *Picture processing and Psychopictorics*, 10(1):15–19, 1970. 64, 65

[PSS+12] Sun Young Park, D. Sargent, I. Spofford, K.G. Vosburgh, and Y. A-Rahim. A Colon Video Analysis Framework for Polyp Detection. *IEEE Transactions on Biomedical Engineering*, 59(5):1408–1418, May 2012. 52, 316

[RAMSHR+07] Edgar A. Rivas Araiza, Jorge D. Mendiola Santibañez, Gilberto Herrera Ruiz, Carlos A. González Gutiérrez, Mario Trejo Perea, and G. J. Ríos Moreno. Mejora de Contraste y Compensación en Cambios de la Iluminación. *Computación y Sistemas*, 10(4), 2007. 54

[RHR+12] B. Rembacken, CESARE Hassan, J. F. Riemann, A. Chilton, M. Rutter, J. M. Dumonceau, M. Omar, and T. Ponchon. Quality in screening colonoscopy: position statement of the European Society of Gastrointestinal Endoscopy (ESGE). *Endoscopy*, 44(10):957, 2012. 30

[RJ04] Alaa Rostom and Emilie Jolicoeur. Validation of a new scale for the assessment of bowel preparation quality. *Gastrointestinal endoscopy*, 59(4):482–486, 2004. 33

[RNC+03] Stuart Jonathan Russell, Peter Norvig, John F Canny, Jitendra M Malik, and Douglas D Edwards. *Artificial intelligence: a modern approach*, volume 2. Prentice hall Upper Saddle River, 2003. 181

[Rob63] Lawrence Gilman Roberts. *Machine perception of three-dimensional soups*. PhD thesis, Massachusetts Institute of Technology, 1963. 64, 66

[SAG+09] Thomas Stehle, Roland Auer, Sebastian Gross, Alexander Behrens, Jonas Wulff, Til Aach, Ron Winograd, Christian Trautwein, and Jens Tischendorf. Classification of colon polyps in NBI endoscopy using vascularization features. In *SPIE Medical Imaging*, pages 72602S–72602S. International Society for Optics and Photonics, 2009. 45, 53, 55

[Sci] ScientificPython scientificpython (s.f.). `http://scipy.org`. Fecha de acceso: 14-07-2016. 41

[Set99] James A Sethian. Fast marching methods. *SIAM review*, 41(2):199–235, 1999. 79

[SPvK+10] Nereo Segnan, Julietta Patnick, Lawrence von Karsa, International Agency for Research on Cancer, World Health Organization, et al. *European guidelines for quality assurance in colorectal cancer screening and diagnosis*. Publications Office of the European Union, 2010. 24

[SRK+00] R. J. Schlemper, R. H. Riddell, Y. e al Kato, F. Borchard, H. S. Cooper, S. M. Dawsey, M. F. Dixon, C. M. Fenoglio-Preiser, J. F. Flejou, Karel Geboes, and others. The Vienna classification of gastrointestinal epithelial neoplasia. *Gut*, 47(2):251–255, 2000. 23

[T+04] Mario Tamayo et al. *El proceso de la investigación científica*. Editorial Limusa, 2004. 120

[TCGL14] Nima Tajbakhsh, Changching Chi, Suryakanth R. Gurudu, and Jianming Liang. Automatic polyp detection from learned boundaries. In *2014 IEEE 11th International Symposium on Biomedical Imaging (ISBI)*, pages 97–100, April 2014. 90, 107, 316

[TF88] Demetri Terzopoulos and Kurt Fleischer. Deformable models. *The visual computer*, 4(6):306–331, 1988. 80

[TGL13] Nima Tajbakhsh, Suryakanth R Gurudu, and Jianming Liang. A classification-enhanced vote accumulation scheme for detecting colonic polyps. In *International MICCAI Workshop on Computational and Clinical Challenges in Abdominal Imaging*, pages 53–62. Springer, 2013. 90, 107, 316

[TGL15] Nima Tajbakhsh, Suryakanth Gurudu, and Jianming Liang. Automated polyp detection in colonoscopy videos using shape and context information. 2015. 90, 107, 316

[TK03] Marta P. Tjoa and Shankar M. Krishnan. Feature extraction for the analysis of colon status from the endoscopic images. *BioMedical Engineering OnLine*, 2(9):1–17, 2003. 312, 313

[TKD02] M. P. Tjoa, S. M. Krishnan, and R. Doraiswami. Automated diagnosis for segmentation of colonoscopic images using chromatic features. In *Electrical and Computer Engineering, 2002. IEEE CCECE 2002. Canadian Conference on*, volume 2, pages 1177–1180. IEEE, 2002. 99, 105, 107

[VF09] OR Vincent and Olusegun Folorunso. A descriptive algorithm for sobel image edge detection. In *Proceedings of Informing Science & IT Education Conference (InSITE)*, volume 40, pages 97–107, 2009. 64, 65

[VS91] Luc Vincent and Pierre Soille. Watersheds in digital spaces: an efficient algorithm based on immersion simulations. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, (6):583–598, 1991. 78

[VWVRVVV10] Cees Van Wijk, Vincent F. Van Ravesteijn, Frans M. Vos, and Lucas J. Van Vliet. Detection and segmentation of colonic polyps

on implicit isosurfaces by second principal curvature flow. *Medical Imaging, IEEE Transactions on*, 29(3):688–698, 2010. 90, 107

[WCLS12] Hao Chun Wang, Wei Ming Chen, Yen Pin Lin, and Wei Chih Shen. Tumor detecting in colonoscopic narrow-band imaging data. In *2012 International Symposium on Intelligent Signal Processing and Communications Systems (ISPACS)*, pages 564–568, November 2012. 50, 139, 315

[WEB] Wikisource. Weber's Law. `http://www.cis.rit.edu/people/faculty/montag/vandplite/pages/chap_3/ch3p1.html`. @ONLINE. Fecha de acceso: 15-12-2016. 54

[Wei06] Eric W Weisstein. Wiener-khinchin theorem. *From MathWorld–A Wolfram Web Resource. http://mathworld. wolfram. com/Wiener-KhinchinTheorem. html*, 2006. 214

[Wil45] Frank Wilcoxon. Individual comparisons by ranking methods. *Biometrics bulletin*, 1(6):80–83, 1945. 164

[WTW+14] Yi Wang, Wallapak Tavanapong, Johnny Wong, JungHwan Oh, and Piet C De Groen. Part-based multiderivative edge cross-sectional profiles for polyp detection in colonoscopy. *IEEE journal of biomedical and health informatics*, 18(4):1379–1389, 2014. 100, 107, 316

[ZBG+14] Mingda Zhou, Guanqun Bao, Yishuang Geng, Bader Alkandari, and Xiaoxi Li. Polyp detection and radius measurement in small intestine using video capsule endoscopy. In *Biomedical Engineering and Informatics (BMEI), 2014 7th International Conference on*, pages 237–241. IEEE, 2014. 99, 107, 316

[ZFL11] Hongbin Zhu, Yi Fan, and Zhengrong Liang. Improved curvature estimation for shape analysis in computer-aided detection of

colonic polyps. In *Virtual Colonoscopy and Abdominal Imaging. Computational Challenges and Clinical Opportunities*, pages 9–14. Springer, 2011. 90, 107

[ZM11] Qian Zhao and MQ-H. Meng. Polyp detection in wireless capsule endoscopy images using novel color texture features. In *Intelligent Control and Automation (WCICA), 2011 9th World Congress on*, pages 948–952. IEEE, 2011. 45, 98, 104, 107

Esta tesis se terminó de escribir en Bilbao el 2 de febrero de 2017