

ESCUELA DE INGENIERÍA DE TELECOMUNICACIÓN Y ELECTRÓNICA



TRABAJO DE FIN DE GRADO

**ANÁLISIS DEL EFECTO DE LA VARIABILIDAD INTER-
PACIENTE EN LA CLASIFICACIÓN SUPERVISADA DE TUMORES
CEREBRALES USANDO IMÁGENES HIPER-ESPECTRALES.
MEJORA DE PRESTACIONES MEDIANTE ALGORITMOS SEMI-
SUPERVISADOS**

TITULACIÓN: Grado en Ingeniería en Tecnologías de la
Telecomunicación
MENCIÓN: Sistemas Electrónicos
AUTOR: Patricia Beltrán Alonso
TUTOR/A: Dr. Gustavo Iván Marrero Callicó
COTUTOR: D. Samuel Ortega Sarmiento
FECHA: Diciembre 2018

ESCUELA DE INGENIERÍA DE TELECOMUNICACIÓN Y ELECTRÓNICA



TRABAJO DE FIN DE GRADO

**ANÁLISIS DEL EFECTO DE LA VARIABILIDAD INTER-PACIENTE EN
LA CLASIFICACIÓN SUPERVISADA DE TUMORES CEREBRALES
USANDO IMÁGENES HIPER-ESPECTRALES. MEJORA DE
PRESTACIONES MEDIANTE ALGORITMOS SEMI-SUPERVISADOS**

HOJA DE EVALUACIÓN

Calificación: _____

Presidente

Fdo.:

Vocal

Secretario/a

Fdo.:

Fdo.:

Fecha: Diciembre 2018

<<UNA TAZA SOLO SIRVE CUANDO ESTA VACÍA>>. Recuerdo ahora la sensación de confusión que sentí la primera vez que leí esto. No conseguía entender lo que significaba. (Cuántas veces me he perdido en la búsqueda del significado, tratando de encontrarlo a través del intelecto, de mi parte computarizada –Que horror--.

Entonces la salida fue –como otras veces—sentirme taza, imaginarme a mí mismo como una taza. Una taza llena...Llena de leche, pensé...La leche es algo útil, nutritivo, importante, vital. ¿De qué otra cosa podía imaginarme lleno yo en mi omnipotencia? Me imaginé llevando mi contenido donde fuera más útil. Pero ¡oh, sorpresa!...no podía darlo sin vaciarme y si lo hacía, dejaba de ser la taza llena... Y lo que me hizo sentir peor: yo solo podía servir para esa leche, caliente o fría, recién ordeñada o podrida...

¡No! No era eso lo que quería para mí. No es eso lo que quiero ahora para mí. Quiero vaciarme...

Para poder llenarme...

Para no estar nunca lleno...

Para ser la esencia de mí mismo. Para vivir...

Jorge Bucay

A Fátima, la mujer que me dio la vida. Aquella que cuando el accidente de coche me robó la identidad me recordó quien era. A mis fracasos, por enseñarme a ser fuerte y crítica conmigo misma. Y a todas esas personas, amigos y familia que hicieron de apoyo. Pero en especial, a los que en el fondo sabían que esto no iba a ser un simple texto de GRACIAS.

Porque sin ellos el camino no hubiese sido recorrido de la misma forma, cada piedra, cada flor y cada bache hicieron de él algo especial.

Resumen

En los últimos años, las imágenes hiperespectrales han supuesto un gran avance tecnológico en el campo de la medicina, debido a su carácter no invasivo y a que proporcionan información útil para el diagnóstico de enfermedades. Actualmente, el proyecto europeo HELICoiD, aplica técnicas avanzadas de clasificación de imágenes hiperespectrales para la detección de tumores cerebrales en tiempo real.

El objetivo principal de este Trabajo Fin de Grado (TFG) es realizar un estudio de los diferentes escenarios propuestos que vienen definidos por la forma en la que se usan los conjuntos de datos de cada paciente en el proceso de clasificación supervisada, para analizar su variabilidad inter-paciente. Para esto, se hace uso de la herramienta software MATLAB, así como de la librería LIBSVM para la clasificación de los datos. El clasificador supervisado empleado es el SVM (*Support Vector Machine*). Por último, con el fin de realizar la evaluación de cada caso de estudio, se aplican cuatro métricas: la tasa de acierto o *accuracy*, la matriz de confusión, la separabilidad y finalmente, la sensibilidad.

Posteriormente, con la finalidad de investigar como mejoraría la clasificación si se añaden muestras del propio paciente, se plantean dos métricas distintas. En la primera, se emplean los datos del paciente actual con etiquetas conocidas y en la segunda se realiza una generación automática de ellas. En este último proceso, se proponen tres métodos semi-supervisados denominados ss1, ss2 y ss3, en donde la principal diferencia es la forma de llevar a cabo el etiquetado de las muestras quirúrgicas de dicho paciente.

Abstract

In recent years, hyperspectral images (HSI) have supposed a relevant technological advance in the field of medicine, due to its non-invasive nature and because it provides useful information for the diagnosis of diseases. Currently, the European project HELICoiD, applies advanced techniques of classification using hyperspectral images for the detection of brain tumours in real time.

The main goal of this Bachelor Degree thesis is to conduct a study of different proposed scenarios that are defined by the way in which the data sets of each patient are used in the supervised classification process, to analyse their variability among patients. For this purpose, the MATLAB software tool is used, as well as the LIBSVM library for data classification. The supervised classifier used is the SVM (Support Vector Machine). Finally, in order to perform the evaluation of each case study, four metrics are applied: the accuracy rate, the confusion matrix, the separability and finally, the sensitivity.

Subsequently, two different metrics are proposed in order to investigate how the classification would improve if samples from the patient were added. In the first case, the current patient data are used with known labels and in the second case, an automatic generation is performed. In this last process, three semi-supervised methods called ss1, ss2 and ss3 are proposed. The main difference relies on the way to carry out the labelling of the surgical samples of the selected patient.

Tabla de contenidos

| | |
|--|----|
| PARTE I: MEMORIA | |
| 1. INTRODUCCIÓN..... | 1 |
| 1.1. Prólogo..... | 1 |
| 1.2. Contexto..... | 2 |
| 1.3. Objetivos | 5 |
| 1.4. Metodología..... | 5 |
| 1.5. Descripción de la memoria | 6 |
| 2. ESTADO DEL ARTE | 9 |
| 2.1. Aplicaciones | 9 |
| 2.1.1. Generales..... | 9 |
| 2.1.2. Aplicaciones médicas..... | 14 |
| 2.2. Imágenes Hiperespectrales..... | 20 |
| 2.2.1. Definición y conceptos básicos | 22 |
| 2.3. Clasificadores..... | 24 |
| 2.3.1. Machine Learning..... | 25 |
| 2.3.2. Algoritmos supervisados | 25 |
| 2.3.3. Algoritmos semi-supervisados | 30 |
| 2.4. Resumen | 30 |
| 3. BASE DE DATOS..... | 31 |
| 3.1. Procedimiento de captura de imágenes hiperespectrales | 31 |
| 3.1.1. Captura de imágenes hiperespectrales..... | 33 |
| 3.1.2. Resección de tejido..... | 34 |
| 3.1.3. Evaluación de expertos..... | 35 |
| 3.1.4. Muestras de etiquetado..... | 35 |
| 3.2. Resumen | 40 |

| | | |
|--------|---|----|
| 4. | CASOS DE ESTUDIO | 41 |
| 4.1. | Metodología | 41 |
| 4.1.1. | Clasificación supervisada | 42 |
| 4.1.2. | Métricas de evaluación..... | 43 |
| 4.1.3. | Escenarios propuestos..... | 46 |
| 4.2. | Resultados..... | 49 |
| 4.2.1. | CS1 | 49 |
| 4.2.2. | CS2 | 50 |
| 4.2.3. | CS3 | 51 |
| 4.2.4. | Comparativa | 52 |
| 4.3. | Resumen | 64 |
| 5. | CASO 4..... | 65 |
| 5.1. | Datos del paciente actual con etiquetas conocidas | 65 |
| 5.2. | Datos del paciente actual con generación automática de nuevas etiquetas | 66 |
| 5.2.1. | SS1 | 67 |
| 5.2.2. | SS2 | 68 |
| 5.2.3. | SS3 | 70 |
| 5.3. | Resultados..... | 70 |
| 5.3.1. | Comparativa | 77 |
| 5.4. | Resumen | 85 |
| 6. | CONCLUSIONES Y LÍNEAS FUTURAS | 87 |
| 6.1. | Conclusiones | 87 |
| 6.2. | Líneas futuras..... | 92 |
| | PARTE II: BIBLIOGRAFÍA..... | |
| | BIBLIOGRAFÍA | 91 |
| | PARTE III: PLIEGO DE CONDICIONES | |

| | |
|--|-----|
| PLIEGO DE CONDICIONES..... | 97 |
| PI.1 Recursos hardware | 97 |
| PI.2 Recursos software | 97 |
| PARTE IV: PRESUPUESTO | |
| PRESUPUESTO | 101 |
| P.1. Trabajo tarifado por tiempo empleado..... | 101 |
| P.2. Amortización del inmovilizado material..... | 102 |
| P.2.1. Amortización del material hardware | 102 |
| P.2.2. Amortización del material software..... | 102 |
| P.3. Redacción del proyecto | 103 |
| P.4. Derechos de visado del COITT | 104 |
| P.5. Gastos de tramitación y envío | 104 |
| P.6. Material fungible | 104 |
| P.7. Aplicación de impuestos y coste total..... | 105 |

ÍNDICE DE FIGURAS

| | |
|---|----|
| Figura 1.1. Registros españoles de cáncer basados en la población que proporcionaron datos para el cálculo de las estimaciones de incidencia de cáncer en España [3]..... | 2 |
| Figura 2.1. Reflectancia espectral media de las especies estudiadas..... | 10 |
| Figura 2.2. Perfiles de los espectros respectivos en un rango de longitudes de onda de 2004-2453 nm..... | 11 |
| Figura 2.3. Mapas de posición de longitud de onda del área de Karrat..... | 11 |
| Figura 2.4. Ejemplos de variabilidad intrapíxel para tres macro-píxeles representativos de: moderadamente turbio (a), (d) y (g); muy turbio (b), (e) y (h); aguas extremadamente turbias (c), (f) y (i)..... | 12 |
| Figura 2.5. Espectros medios de filetes de pechuga de pollo con pérdidas de cocción altas y bajas (VNIR).. | 13 |
| Figura 2.6. Mapas de clasificación de categorías CL a nivel de píxel y filete. (a, d) imagen pseudocolor del filete; (b, e) Mapas de clasificación a nivel de píxel; (c, f) Mapas de clasificación a nivel de filete..... | 14 |
| Figura 2.7. Detección de la bacteria E.Coli concentrado al aire sobre el vidrio y su respectiva firma hiperespectral (a y b). imagen por CARS después de la recuperación de fase (c y d)..... | 15 |
| Figura 2.8. Imagen CARS de la mezcla de E.coli-orina (a). Detección de bacterias en la orina (b). Espectro de salida de cada componente (c)..... | 16 |
| Figura 2.9. Imagen microscópica de los nidos tumorales en los tejidos gástricos..... | 16 |
| Figura 2.10. Imagen microscópica de tejido gástricos cancerígeno y espectro de transmisión de núcleos celulares normales y cancerígenas..... | 17 |
| Figura 2.11. Identificación de células cancerígenas que diseminan a los tejidos normales..... | 17 |
| Figura 2.12. Imágenes hiperespectrales de la saturación de oxígeno en los días 2, 4 y 6 respectivamente después de la implantación del tumor..... | 18 |
| Figura 2.13. a) Sistema de imágenes hiperespectrales; b) Sistema de imágenes hiperespectrales microscópicas..... | 19 |
| Figura 2.14. a) Imagen del tejido cervical de múltiples escalas; b) Imagen hiperespectral del tejido cervical; c) Imagen microscópica hiperespectral del tejido cervical teñido; d) Imagen microscópica hiperespectral no teñido..... | 19 |
| Figura 2.15. Resultados obtenidos de la clasificación de imágenes. a Curva de la reflectancia relativa del tejido localizados en dos partes diferentes. b Espectros. c Imagen cervical de un cuello uterino anormal. d mapa de pseudocolor por tres imágenes hiperespectrales. El resultado clasificación..... | 20 |
| Figura 2.16. Espectro electromagnético..... | 22 |
| Figura 2.17. Firma espectral de diferentes materiales..... | 22 |
| Figura 2.18. Cubo hiperespectral con sus respectivos ejes..... | 23 |
| Figura 2.19. Rangos espectrales..... | 23 |
| Figura 2.20. Efecto cambio de resolución (píxeles) para una imagen en color..... | 24 |
| Figura 2.21. Tipos de imágenes espectrales..... | 24 |
| Figura 2.22. Clasificación hiperplano (linear separable case)..... | 27 |
| Figura 2.23. Un nodo ANN con sus elementos..... | 28 |
| Figura 2.24. Estructura general por capas de una red neuronal..... | 29 |
| Figura 2.25. Ejemplo del k-vecino más cercano con dos clases (a) regla de decisión 1-nn (b) regla de decisión 4-nn..... | 29 |
| Figura 3.1. Plataforma de adquisición de demostradores HELICoiD. (a, b) cámaras VNIR y NIR HS montadas en la plataforma de exploración; (c-e) Fuente de luz QTH conectada al sistema de fibra óptica para la transmisión de luz para obtener una emisión de luz en la plataforma de exploración; (f, g) motor paso a paso | |

| | |
|---|----|
| acoplado al eje y conectado al controlador de motor paso a paso para realizar el movimiento lineal de las cámaras; (h) Posicionamiento de la cámara utilizada para identificar la posición del campo de visión de las cámaras (FOV); (i) El sistema Up & Down utilizado para enfocar las cámaras HS; (j) y (k) Sistemas de panorámica e inclinación manual utilizados para orientar correctamente la plataforma de exploración..... | 32 |
| Figura 3.2. Captura de datos y proceso de etiquetado proyecto HELICoiD. | 33 |
| Figura 3.3. Puntero del sistema IGS sobre el marcador tumoral HELICoiD ubicado en la superficie expuesta del cerebro. | 34 |
| Figura 3.4. Captura de pantalla de la herramienta de etiquetado HELICoiD. | 36 |
| Figura 3.5. Firmas espectrales promedio de cada clase de la base de datos completa: Tumor cerebral (rojo), Tejido cerebral sano (negro), vasos sanguíneos (azul) y Background (amarillo). | 39 |
| Figura 4.1. Diagrama de bloques correspondiente al procedimiento planteado para el TFG. | 42 |
| Figura 4.2. Mecánica de funcionamiento del método hold-out. | 42 |
| Figura 4.3. Mecánica de funcionamiento del método k-fold. | 43 |
| Figura 4.4. Mecánica de funcionamiento del método leave-one-out. | 43 |
| Figura 4.5. Diagrama de bloques correspondiente al caso de estudio 1. | 47 |
| Figura 4.6. Diagrama de bloques correspondiente al caso de estudio 2. | 48 |
| Figura 4.7. Diagrama de bloques correspondiente al caso de estudio 3. | 48 |
| Figura 4.8. Gráfica comparativa del overall accuracy en CS1, CS2 y CS3. | 53 |
| Figura 4.9. Gráfica comparativa de especificidad para la clase tejido normal en CS1, CS2 y CS3. | 55 |
| Figura 4.10. Gráfica comparativa de especificidad para la clase tumor en CS1, CS2 y CS3. | 56 |
| Figura 4.11. Gráfica comparativa de especificidad para la clase blood vessel (vasos sanguíneos) en CS1, CS2 y CS3. | 56 |
| Figura 4.12. Gráfica comparativa de especificidad para la clase background en CS1, CS2 y CS3. | 57 |
| Figura 4.13. Gráfica comparativa de sensibilidad para la clase tejido normal en CS1, CS2 y CS3. | 57 |
| Figura 4.14. Gráfica comparativa de sensibilidad para la clase tumor en CS1, CS2 y CS3. | 58 |
| Figura 4.15. Gráfica comparativa de sensibilidad para la blood vessel (vasos sanguíneos) en CS1, CS2 y CS3. | 58 |
| Figura 4.16. Gráfica comparativa de sensibilidad para la clase background en CS1, CS2 y CS3. | 59 |
| Figura 4.17. Diagrama de caja para la tasa de acierto de CS1 (azul) y CS3 (naranja). | 61 |
| Figura 5.1. Diagrama de bloques correspondiente al caso de estudio CS3 to CS2. | 66 |
| Figura 5.2. Píxeles de cada clase pertenecientes al bloque de pacientes previos con las firmas medias correspondientes (F1, F2, F3 y F4). | 67 |
| Figura 5.3 Píxeles del paciente actual más parecidos a la firma media por clase (F1, F2, F3 y F4)..... | 67 |
| Figura 5.4. Diagrama de bloques correspondiente al CS4 de SS2. Con $i=3$, el bucle se realiza 10 veces correspondientes a cada una de las particiones, generando un total de 10 valores pertenecientes al svmpredict. | 69 |
| Figura 5.5. Gráfica comparativa del overall accuracy para el CS3 y CS4 con sus respectivos porcentajes. ... | 73 |
| Figura 5.6. Gráfica comparativa de especificidad de la clase tumor con el 40% de los datos del paciente actual para CS4, ss1 (Cosine), ss1 (Euclidea), ss2 y ss3. | 80 |
| Figura 5.7. Gráfica comparativa de sensibilidad de la clase tumor con el 40% de los datos del paciente actual para CS4, ss1 (Cosine), ss1 (Euclidea), ss2 y ss3. | 80 |
| Figura 7.1. Diagrama de caja para la tasa de acierto de CS3, CS4, ss1 (Cosine), ss1(Euclidea), ss2 y ss3 (K-NN). | 90 |

ÍNDICE DE TABLAS

| | |
|---|-----|
| Tabla 3.1. Base de datos de las capturas hiperespectrales..... | 37 |
| Tabla 3.2. Porcentajes de cada clase correspondientes a cada paciente. | 39 |
| Tabla 4.1. Ejemplo de una matriz de confusión 4x4 para las clases A-D. | 45 |
| Tabla 4.2. Matriz de confusión binaria, clase A..... | 45 |
| Tabla 4.3. Valores de la tasa de acierto, de especificidad y de sensibilidad para el CS1..... | 50 |
| Tabla 4.4. Valores de la tasa de acierto, de especificidad y de sensibilidad para el CS2..... | 51 |
| Tabla 4.5. Valores de la tasa de acierto, de especificidad y de sensibilidad para el CS3..... | 52 |
| Tabla 4.6. Resultados obtenidos en CS1, CS2 y CS3..... | 54 |
| Tabla 4.7. Análisis obtenido de las matrices de confusión para CS1, CS2 y CS3..... | 60 |
| Tabla 4.8. Matriz de confusión del paciente 022 obtenida para el CS3..... | 61 |
| Tabla 4.9. Matriz del paciente 022 obtenida para el CS3 con los valores de los verdaderos positivos, falsos negativos, falsos positivos y verdaderos negativos..... | 62 |
| Tabla 4.10. Matriz del paciente 022 obtenida para el CS3 con los valores de sensibilidad y especificidad..... | 62 |
| Tabla 4.11. Tabla tiempos de ejecución para cada equipo..... | 63 |
| Tabla 4.12. Tabla comparativa equipos empleados..... | 63 |
| Tabla 5.1. Tabla comparativa CS3 y CS4 con los datos del paciente actual con etiquetas conocidas de los Pacientes 12, 15, y 20..... | 71 |
| Tabla 5.2. Tabla comparativa CS3 y CS4 con los datos del paciente actual con etiquetas conocidas de los Pacientes 22, 25, 28 y 29..... | 72 |
| Tabla 5.3. Tabla de los resultados obtenidos en ss1 con cálculo de distancia Euclídea..... | 74 |
| Tabla 5.4. Tabla de resultados obtenidos en ss1 con cálculo de distancia Coseno..... | 75 |
| Tabla 5.5. Tabla de resultados obtenidos en ss2..... | 76 |
| Tabla 5.6. Tabla de resultados obtenidos en ss3..... | 77 |
| Tabla 5.7. Tabla comparativa resultados especificidad y sensibilidad clase Tumor (CS3, CS4, ss1, ss2 y ss3). | 79 |
| Tabla 5.8. Tabla comparativa resultados especificidad y sensibilidad clase Tejido normal (CS3, CS4, ss1, ss2 y ss3). | 82 |
| Tabla 5.9. Tabla comparativa resultados especificidad y sensibilidad clase Blood Vessel (CS3, CS4, ss1, ss2 y ss3). | 83 |
| Tabla 5.10. Tabla comparativa resultados especificidad y sensibilidad clase Background (CS3, CS4, ss1, ss2 y ss3). | 84 |
| Tabla 6.1. Tabla comparativa Overall Accuracy de CS3, CS4, ss1, ss2 y ss3..... | 89 |
| Tabla P.1. Amortización del material hardware..... | 102 |
| Tabla P.2. Amortización del material software..... | 103 |
| Tabla P.3. Presupuesto total de los costes de redacción del TFG..... | 103 |
| Tabla P.4. Presupuesto con los derechos de visado del COITT..... | 104 |
| Tabla P.5. Presupuesto del material fungible..... | 104 |
| Tabla P.6. Aplicación de impuestos y coste total..... | 105 |

ACRÓNIMOS

| | |
|----------------|---|
| ANN | <i>Artificial Neural Network</i> |
| BPO | <i>Benzoyl Peroxide</i> |
| CARS | <i>Coherent Anti-Stokes Raman Scattering</i> |
| CL | <i>Cooking Loss</i> |
| CS | <i>Case Study</i> |
| CT | <i>Classification Trees</i> |
| ESA..... | <i>European Space Agency</i> |
| FTIR..... | <i>Fourier Transform Infrared</i> |
| H&E..... | <i>Hematoxilina-eosina</i> |
| IR | <i>Infrared Radiation</i> |
| K-NN | <i>K-Nearest Neighbor</i> |
| LiDAR | <i>Light Detection and Ranging</i> |
| MERIS | <i>Medium Resolution Imaging Spectrometer</i> |
| mini-UAV | <i>mini-Unmanned Aerial Vehicle</i> |
| NIR..... | <i>Near Infrared</i> |
| RGB..... | <i>Red, Green and Blue</i> |
| SPM | <i>Suspended Particulate Matter</i> |
| SVM | <i>Support Vector Machine</i> |
| SWIR | <i>Short Wavelength Infrared</i> |
| TN | <i>Tumor Nets</i> |
| TRP..... | <i>Technology Research Project</i> |
| UV | <i>Ultraviolet</i> |
| VIS..... | <i>Visible Spectrum</i> |
| VNIR..... | <i>Visible and Near Infrared</i> |

**PARTE I:
MEMORIA**

CAPÍTULO 1.

1. INTRODUCCIÓN

En este capítulo se presenta el contexto, los objetivos y la metodología a seguir para este Trabajo Fin de Grado. Asimismo, se realiza una descripción de la estructura de la memoria.

1.1. Prólogo

La principal estructura biológica responsable en su gran medida de la coordinación y del control del organismo humano es el cerebro, constituido por el encéfalo y por la médula, que se encuentran alojados dentro del cráneo y en la columna vertebral respectivamente. El cerebro y la médula se encuentran protegidos por las meninges. El conjunto de estas partes se denomina Sistema Nervioso Central (SNC).

El SNC controla a través de diferentes capacidades mentales la memoria, el habla, las emociones y los sentidos al igual que aquellas funciones básicas como las respiración o la frecuencia cardíaca [1].

Un tumor cerebral es un crecimiento de células anormales en el tejido del cerebro, los tumores primarios son aquellos que comienzan en el cerebro y los secundarios (o metastásicos) los que comienzan en alguna otra parte del cuerpo para luego llegar también al cerebro [2]. La diferenciación entre las múltiples variedades de tumores cerebrales se basa principalmente en el tipo de célula que origina el tumor y en el grado de agresividad del mismo, donde se diferencian 4 grados para los tumores primarios. El grado I hace referencia a los tumores menos agresivos mientras que el grado IV son aquellos que se reproducen rápidamente y revisten mayor peligrosidad.

En España, tal y como se muestra en la Figura 1.1, según los datos de los registros poblacionales, el cáncer afecta a un 25% de la población aproximadamente.



Figura 1.1. Registros españoles de cáncer basados en la población que proporcionaron datos para el cálculo de las estimaciones de incidencia de cáncer en España [3].

Según los datos elaborados por el Registro Poblacional de Cáncer de Canarias, la incidencia de cáncer localizada en el encéfalo y el sistema nervioso (C70-C72), entre el periodo 2008 al 2010, fue para ambos sexos de 364 casos [3]. Este tipo de tumores en adultos posee una incidencia del 2%. Sin embargo, en menores de 14 años este porcentaje ronda el 20-25%, que en el caso de Canarias, equivale entre 10 y 14 casos anuales. En el 2017 se han recogido nuevos casos de tumores malignos diagnosticados donde se estima una media anual de 6.868 casos en el archipiélago [4] [5].

La prevención y la detección temprana de estos tumores malignos son fundamentales para detener el alarmante aumento de incidencias. El índice de mortalidad podría estar estabilizado gracias a los avances técnicos de diagnóstico de imagen, ya que ayuda a la correcta eliminación (resección) del tejido maligno [6] [7].

El aumento de la zona de resección con un margen adicional evita que el tumor se vuelva a reproducir lo que provoca una mejora notable de las probabilidades de supervivencias del paciente. Es por ello, que se necesitan técnicas que determinen de forma precisa los límites del tumor, pues una resección excesiva puede provocar daños irreversibles en el mismo.

1.2. Contexto

Este TFG está desarrollado dentro de las líneas de investigación de adquisición y procesamiento de imágenes hiperespectrales que realiza actualmente la División de Sistemas Integrados (DSI) del Instituto Universitario de

Microelectrónica Aplicada (IUMA) de la Universidad de Las Palmas de Gran Canaria (ULPGC), concretamente en el campo del diagnóstico médico.

Asimismo, el IUMA ha estado involucrado en proyectos financiados tanto por entidades públicas como privadas, en el ámbito del procesado y aplicación de imágenes hiperespectrales. Entre estos proyectos se encuentran los proyectos financiados por la Comisión Europea:

- **HELICoiD – HypErspectraL Imaging Cancer Detection (FP7-618080):** Su objetivo principal fue el de aplicar técnicas de imágenes hiperespectrales para la diferenciación entre tejido sano y tumoral durante procedimientos quirúrgicos. Este proyecto desarrolló una configuración intraoperatoria experimental basada en cámaras hiperespectrales no invasivas conectadas a una plataforma que ejecuta un conjunto de algoritmos capaces de discriminar entre tejidos sanos y patológicos.
- **ENABLE-S3 – European Initiative to Enable Validation for Highly Automated Safe and Secure Systems:** Los sistemas físicos cibernéticos automatizados facilitan la existencia de nuevos modelos de negocio y nuevas oportunidades comerciales para las empresas europeas de alta tecnología. Sin embargo, se requiere un mayor esfuerzo para asegurar la seguridad y robustez (fiabilidad). ENABLE-S3 ayudará a la industria europea a ganar liderazgo en el campo estratégico de sistemas autónomos debido a un desarrollo y prueba más rápidos de nuevos productos.

En el ámbito de los proyectos del Plan Nacional:

- **REBBECA – Sistemas electrónicos empotrados confiables para control de ciudades bajo situaciones atípicas (TEC2014-58036-C4-4-R):** Está orientado al paradigma *Smart City*. Este tema plantea desafíos importantes en diferentes áreas desarrolladas con el desarrollo sostenible de ciudades y la prestación de servicios a los ciudadanos. Se centra en la seguridad urbana para grandes espacios públicos.
- **DREAMS – Dynamically Reconfigurable Embedded Platforms for Networked Context-Aware Multimedia Systems (TEC2011-28666-C04-04):** El principal objetivo de DREAMS es proponer nuevos métodos y herramientas para el diseño de sistemas embebidos en red, para la obtención de aspectos clave en el diseño de sistemas embebidos (Re

configurabilidad, validación, especificaciones, análisis de rendimiento, plataformas HW/SW y arquitecturas de núcleos) para hacer frente a aplicaciones complejas como multimedia contextual, con características de adaptabilidad.

- **Sistema de adquisición de imágenes hiperespectrales de alta definición espacial y espectral (UNLP13-3E-2211):** Este proyecto ha financiado la adquisición de varios equipos hiperespectrales, siendo los más relevantes una cámara VNIR operando en el rango de 400 a 1000 nm y otra cámara SWIR operando en la banda de frecuencias de 900 a 2500 nm. El sistema de adquisición de imágenes hiperespectrales permite obtener las firmas espectrales de diferentes materiales, con el que se logran clasificaciones mucho más precisas que las obtenidas con cámaras convencionales.
- **PLATINO - plataforma hw/sw distribuida para el procesamiento inteligente de información sensorial heterogénea en aplicaciones de supervisión de grandes espacios naturales (TEC2017-86722-C4-1-R):** Este proyecto propone un conjunto de soluciones que permitan avanzar en el diseño de plataformas distribuidas hardware/software para el procesamiento inteligente de información sensorial heterogénea. La viabilidad de las soluciones propuestas se demostrará en un escenario propio de la denominada agricultura inteligente, en el cual la introducción de este tipo de redes multisensoriales supone un extraordinario avance en términos de producción económica y de calidad y seguridad de los alimentos.

Además, el proyecto industrial de la *European Space Agency* (ESA) en el programa *Technology Research Project* (TRP):

- **CCSDS IP cores for space applications (ESA ITT AO/1-8032/14/NL/AK):** El objetivo principal de este proyecto es implementar dos núcleos IP independientes correspondientes a las normas CCSDS 123 y CCSDS 121, respectivamente. El primero corresponde a una arquitectura sin pérdida de compresión de imágenes multispectrales e hiperespectrales, mientras que el segundo es un compresor de datos sin pérdidas. Ambos sistemas son integrados en FPGAs habilitadas para el espacio (de Microsemi y Xilinx) y también en células estándar endurecidas por radiación (180 nm ATMEL ATC18RHA).

Finalmente, este proyecto está fuertemente imbricado en el proyecto financiado por el Gobierno de la Comunidad Autónoma de Canarias, a través de la ACIISI:

- **ITHaCA - Identificación Hiperespectral de tumores Cerebrales (ProID2017010164)**: Este proyecto tiene por objetivo una diferenciación y clasificación precisa mediante la utilización de imágenes hiperespectrales de los distintos tipos de tumores cerebrales, combinando para ello imágenes macroscópicas y microscópicas, cuya correlación para tumores cerebrales no se ha realizado todavía en el estado del arte.

1.3. Objetivos

Acorde al problema expuesto, el objetivo principal de este TFG es ver cómo afecta la inclusión de muestras de nuevos pacientes en la clasificación, donde se hace una comparativa de los diferentes casos de estudio con el fin de analizar la variabilidad inter-paciente.

Una vez planteado y analizado el problema, se desglosan los siguientes objetivos específicos que deberán ser alcanzados para cumplir el objetivo principal:

- Estudiar los diferentes casos de estudio en la clasificación de las imágenes hiperespectrales.
- Estudiar las métricas de evaluación para poder realizar una comparativa.
- Evaluar cómo influye la forma de incluir un nuevo paciente en la clasificación.
- Realizar el sistema con un algoritmo semi-supervisado para buscar una mejora en la clasificación.
- Determinar la técnica aplicada al sistema semi-supervisado que ofrece una mejor precisión de los resultados.

1.4. Metodología

La metodología que se llevará a cabo en este TFG para lograr los objetivos nombrados anteriormente consiste en lo siguiente:

- Una investigación exhaustiva del escenario y de las herramientas que se utilizarán durante el desarrollo del trabajo para comprender su funcionamiento. Para ello, se hace hincapié en los conceptos básicos sobre las imágenes hiperespectrales y sus aplicaciones.

- El estudio de los diferentes escenarios propuestos. De forma que se analiza cómo se realiza la inclusión de los pacientes a la hora de realizar la clasificación.
- Una investigación de las diferentes métricas de evaluación a utilizar. De tal forma, que se seleccionan aquellas que más se adapten a la comparativa que se quiere realizar.
- Una investigación de las diferentes técnicas de clasificación semi-supervisada.
- El desarrollo del software aplicado a los escenarios propuestos durante el desarrollo del TFG. Tras el estudio realizado de las imágenes hiperespectrales, de cada uno de los casos de estudio propuestos y de las métricas de evaluación se desarrolla el software.
- Validación del software desarrollado usando los datos reales disponibles de los proyectos de investigación ya ejecutados o en ejecución.

1.5. Descripción de la memoria

La memoria de este TFG se organiza de la siguiente manera:

- *Capítulo 1- Introducción.* Exponen los objetivos del TFG y se realiza una introducción general sobre el escenario y las herramientas utilizadas en este Trabajo Fin de Grado.
- *Capítulo 2- Estado del arte.* Explica los conceptos básicos necesarios para el desarrollo del TFG. Asimismo, se hace un estudio de las distintas aplicaciones de las imágenes hiperespectrales existentes. Finalmente, se realiza un breve estudio de los diferentes tipos de clasificadores supervisados.
- *Capítulo 3- Base de datos.* Expone el procedimiento aplicado a las capturas de las imágenes hiperespectrales de los tumores cerebrales. Se describe también, la base de datos que se utilizará durante el desarrollo de este TFG.
- *Capítulo 4- Casos de estudio.* Describe los diferentes casos de estudio que hacen referencia a la forma de inclusión de las muestras de los pacientes en el clasificador. Describe las métricas que se han seleccionado para analizar los diferentes escenarios propuestos.

Finalmente, muestra los resultados obtenidos de la evaluación realizada, a modo de comparativa.

- *Capítulo 5- Caso 4.* Presenta un cuarto caso de estudio, con sus distintas variaciones, añadido a los tres casos de estudio contemplados hasta el momento. Realiza una comparativa de los resultados del capítulo anterior mediante la evaluación obtenida con las distintas métricas
- *Capítulo 6- Conclusiones y líneas futuras.* Se exponen las conclusiones alcanzadas tras realizar un profundo análisis de los resultados. Además, se plantean posibles líneas futuras de este trabajo fin de grado.

CAPÍTULO 2.

2. ESTADO DEL ARTE

En este capítulo se presentarán los conceptos que se consideran fundamentales para el desarrollo de este proyecto. Para ello, se considera necesario comprender la composición, las especificaciones de los sistemas de adquisición de las imágenes hiperespectrales, así como los campos de aplicación de estas.

2.1. Aplicaciones

Actualmente, la tecnología de las imágenes hiperespectrales se puede encontrar en un gran número de aplicaciones, esto se debe a que su avance tecnológico permite obtener un mayor volumen de información por imagen. Los procesos de calidad de un alimento o algunos de los diagnósticos médicos ya pueden venir dados por este tipo de imágenes que poseen información sustancial, no solo sobre la naturaleza y los atributos de los objetos que hay presentes en una escena sino también del espectro electromagnético de los mismos en rangos donde el ojo humano no puede operar. En este apartado se realizará un estudio de algunas aplicaciones recientes de las imágenes hiperespectrales.

2.1.1. Generales

La capacidad para discriminar entre distintos materiales ha abierto nuevas vías para las aplicaciones de teledetección, como la meteorología [8] las observaciones de la Tierra [9], la agricultura [10], la identificación de depósitos minerales [11] o incluso la contaminación ambiental [12].

La tecnología de la teledetección (*Remote Sensing*) puede proporcionar información detallada de los bosques, que permite discriminar ciertas especies de árboles en base a su firma espectral. Una identificación precisa de las especies arbóreas facilita la gestión de los recursos forestales y la evaluación por ejemplo del almacenamiento de carbono. En un estudio realizado en el área de Yushan Forest, un parque nacional en el sureste de China, que cubre aproximadamente 1103 ha, se emplearon los índices de vegetación para clasificar seis especies de árboles y tres tipos de bosques generales. Para ello, se adquirió datos

hiperespectrales aéreos y en un conjunto con datos LiDAR para delinear y clasificar las especies arbóreas en los bosques subtropicales.

Se emplearon las bandas que van desde el espectro visible (VIS) hasta el infrarrojo cercano (NIR), que depende de los pigmentos, la estructura y la fisiología de cada corona se identificaron las especies arbóreas. En la Figura 2.1 se muestran las firmas espectrales de las especies estudiadas.

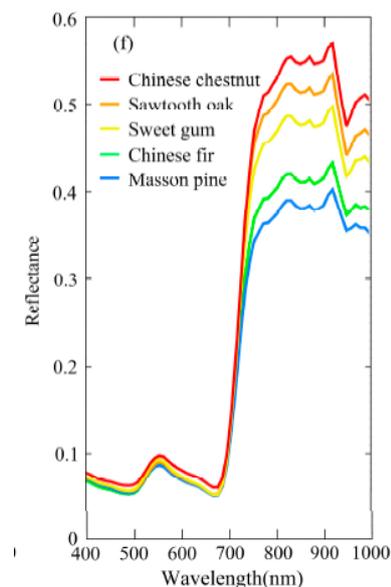


Figura 2.1. Reflectancia espectral media de las especies estudiadas.

En otros estudios se plantea un enfoque para realizar una estimación del carbono orgánico que se encuentra en el suelo o el estudio de la concentración de nitrógeno en la hoja, el cual es un método clave para comprender los patrones de alimentación de los herbívoros [13] estas imágenes hiperespectrales por lo general se realizan por satélite o en plataformas aviónicas. No obstante, existe una tercera alternativa que son las plataformas mini-UAV (vehículos aéreos no tripulados de menos de 20 kg) [14].

El mapeo geológico y la exploración minera de las regiones más remotas, como el Ártico, continúan siendo un gran desafío, debido a que las secciones de los acantilados casi verticales en estas regiones ofrecen excelentes exposiciones para investigar los depósitos minerales. Las imágenes hiperespectrales se han aplicado con éxito en el mapeo de distintos tipos de rocas y minerales. En un estudio realizado en Dinamarca proporcionan un método para permitir adquisiciones de las muestras sin necesidad de una estación en tierra, donde se optimiza el rendimiento y reduce el tiempo para caracterizar grandes áreas inaccesibles de afloramiento vertical. Y por tanto, permite completar estos modelos

con información cuantitativa sobre las variaciones minerales mediante el uso de datos combinados de la fotografía digital y el escaneo hiperespectral [15].

Para generar los espectros representativos se recolectaron y promediaron los datos de reflectancia para el cielo, la vegetación, el agua y la exposición a la roca, tal y como se puede observar en Figura 2.2, en el cual la asignación a una clase se basa en las características pronunciadas de absorción que representan el mineral dominante.

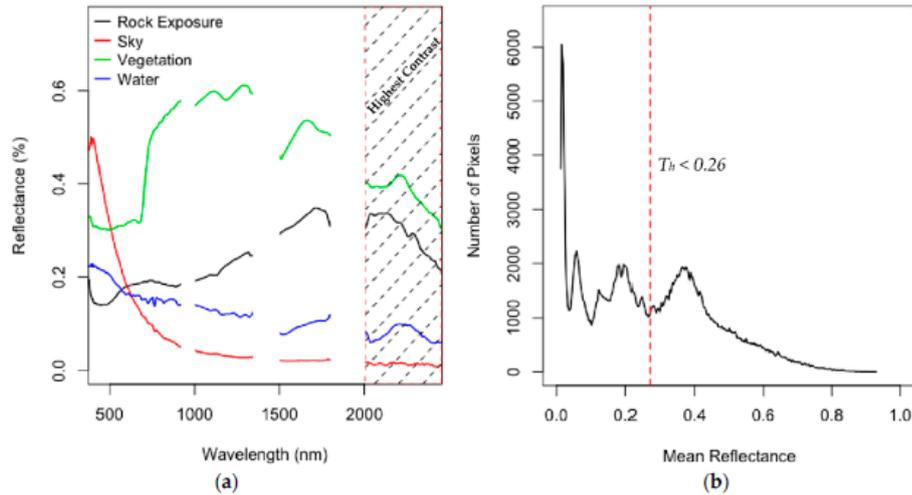


Figura 2.2. Perfiles de los espectros respectivos en un rango de longitudes de onda de 2004-2453 nm.

En la Figura 2.3 se pueden observar las variaciones asociadas con la abundancia de AlOH, FeOH y MgOH. El material no geológico en este caso como la vegetación y las áreas afectadas por sombras se enmascararon y se excluyeron de los cubos de datos antes de aplicar el mapeo de longitud de onda. Lo novedoso de este estudio es que los resultados enfatizan el uso de la información espectral detallada de las imágenes hiperespectrales y la información geométrica de datos de fotogrametría 3D.

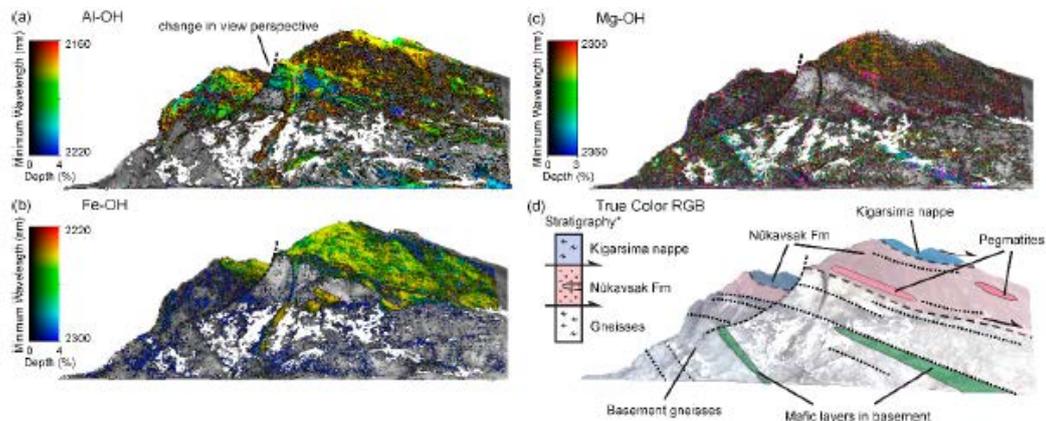


Figura 2.3. Mapas de posición de longitud de onda del área de Karrat.

Por otra parte, en un estudio realizado en Francia se emplea la técnica de las imágenes hiperespectrales para el control de calidad del agua en zonas costeras [16]. El litoral canario posee condiciones ambientales favorables para el desarrollo de especies marinas. Sin embargo, en las últimas décadas se está produciendo una alarmante pérdida de biodiversidad ya que a las costas canarias llegan residuos que inciden de forma negativa a su conservación [17]. Por consiguiente, dicho estudio cobra una gran importancia para el archipiélago, pues facilita el control de calidad del agua.

En la Figura 2.4 se seleccionaron tres ejemplos representativos de macro-píxeles turbios para ilustrar las cantidades de variabilidad espacial que hay dentro de un píxel de resolución media (MERIS).

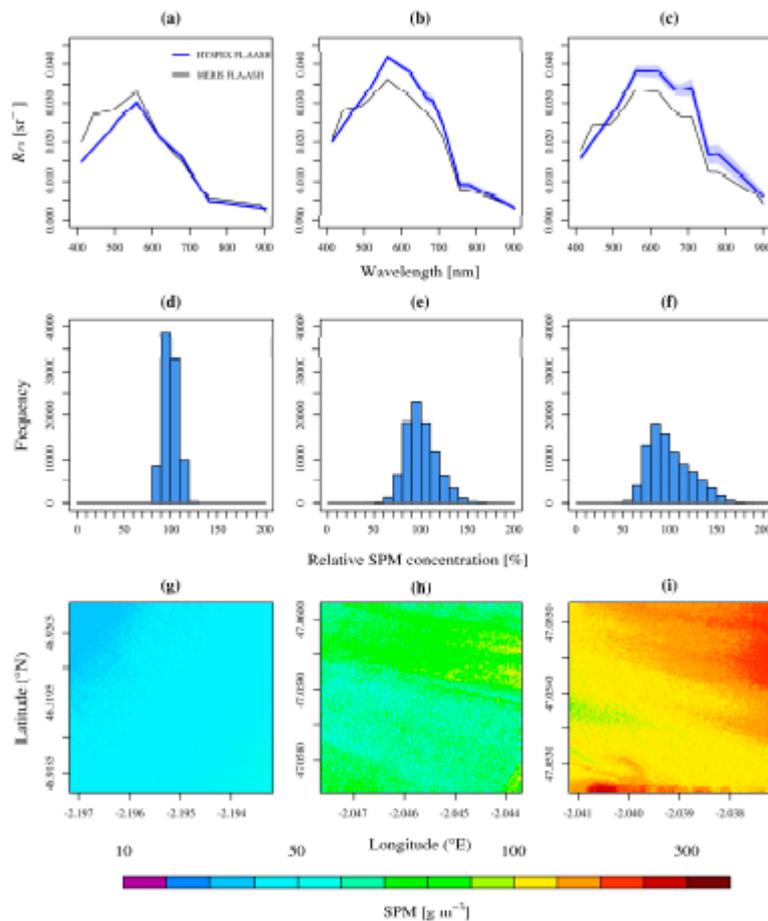


Figura 2.4. Ejemplos de variabilidad intrapíxel para tres macro-píxeles representativos de: moderadamente turbio (a), (d) y (g); muy turbio (b), (e) y (h); aguas extremadamente turbias (c), (f) y (i).

Los valores de suspensión de partículas (SPM) se encuentran representadas a escala de color en la Figura 2.4 desde la (g) hasta la (i). El monitoreo de los componentes del agua de mar como la suspensión de partículas suspendidas (SPM) y la clorofila-a (Chl-a), o las microalgas, es crucial pues su variabilidad

espaciotemporal es uno de los principales impulsores del funcionamiento de los ecosistemas costeros.

Otro de los campos de aplicación de las imágenes hiperespectrales está relacionado con la industria alimenticia, lo innovador de aplicar esta técnica hiperespectral es que permite medir parámetros relacionados con la calidad y la composición de los alimentos de manera rápida y no destructiva [18].

La carne de corral es considerada uno de los alimentos más populares cuyo consumo va en aumento cada año debido a su bajo precio y sus elevados valores nutricionales. Por ello, asegurar una calidad a los consumidores es esencial para las industrias de este sector [19]. Este control se hace mediante un método para determinar la capacidad de retención de agua y la pérdida de cocción que es (CL,%) parámetro que indica la jugosidad de la carne [20].

Tradicionalmente las pérdidas de cocción se medían como la diferencia de peso, en porcentaje, antes y después de la cocción. No obstante, este método es invasivo por lo que la técnica no invasiva de este estudio realizado en China supone una mejora en este tipo de controles de calidad. Utiliza el espectro visible del infrarrojo cercano (VNIR) para evaluar y visualizar las pérdidas de cocción en los filetes de pollo frescos, tal y como se muestra en la Figura 2.5. en donde solo se observaron diferencias menores en los contenidos de humedad de los músculos con alto CL y bajo CL.

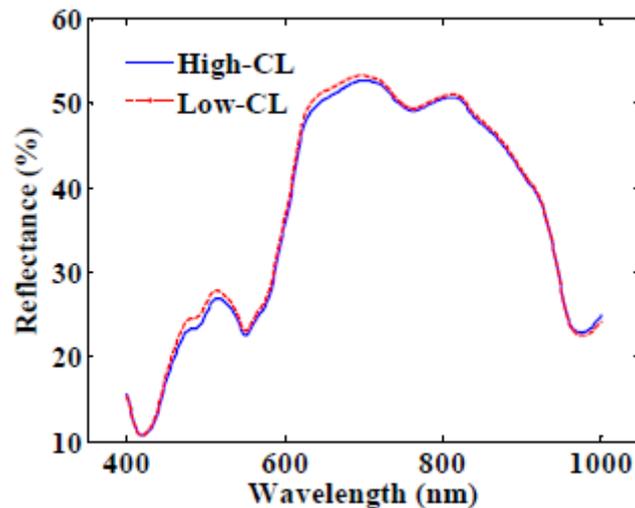


Figura 2.5. Espectros medios de filetes de pechuga de pollo con pérdidas de cocción altas y bajas (VNIR).

En la Figura 2.6 (a) y (d) se muestran las imágenes de pseudo-color de dos filetes con distinto CL, tal y como se puede apreciar no se diferencian a simple vista.

En la Figura 2.6 (b) y (e), se presenta la clasificación a nivel de píxel, en rojo (CL alto) y en verde (CL bajo). Y finalmente, los mapas de clasificación a nivel de filete se pueden observar en la Figura 2.6 (c) y (f), los cuales podrían usarse para la automatización de la inspección de calidad.

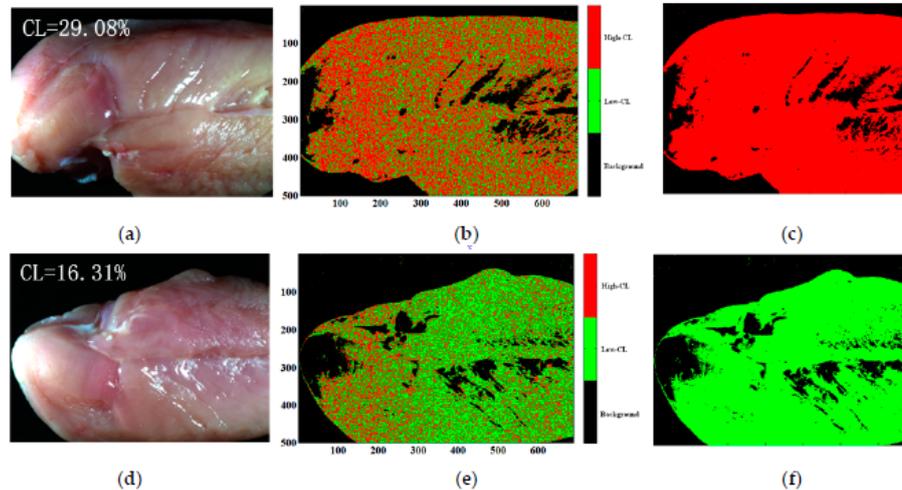


Figura 2.6. Mapas de clasificación de categorías CL a nivel de píxel y filete. (a, d) imagen pseudocolor del filete; (b, e) Mapas de clasificación a nivel de píxel; (c, f) Mapas de clasificación a nivel de filete.

Las imágenes hiperespectrales en el infrarrojo cercano (NIR) se han utilizado para la detección y variación de bacterias en los alimentos y para el análisis cuantitativo del aditivo de BPO en la harina [21]. El uso de las imágenes hiperespectrales dentro del sector alimenticio se emplea también para la identificación de las variedades de semillas de arroz o para la predicción del contenido de proteínas en granos de trigo [22]. Así como para la evaluación de la viabilidad de la semilla de maíz o la adulteración de los granos de pistacho o de la leche en polvo [23] [24].

La técnica de las imágenes hiperespectrales permite a los investigadores un análisis y una detección rápida de forma segura de las diferentes sustancias de tal forma que se agilizan los procesos de estudio en el campo de aplicación. Estas características hacen que esta tecnología cobre mayor relevancia y, por tanto, cada vez existen un mayor número de sectores que apuesten por ella.

2.1.2. Aplicaciones médicas

En los últimos años, en el campo de la medicina las imágenes hiperespectrales han supuesto un gran avance tecnológico, debido a su carácter no invasivo y a que proporcionan información útil para el diagnóstico de enfermedades.

El análisis de bacterias y su rápida detección en su entorno natural no solo son fundamentales para la seguridad alimenticia sino también para el diagnóstico clínico de enfermedades infecciosas. Los métodos actuales, requieren de largos tiempos de cultivo bacteriano y no son sensibles a entornos complejos. Sin embargo, las técnicas hiperespectrales, como la espectroscopía infrarroja de la transformada de Fourier (FTIR) y Raman, han demostrado su eficacia en la identificación de las bacterias de tal forma, que se permite su libre cultivo de manera no destructiva.

En [25] se utiliza la microscopía coherente de dispersión *Raman anti-Stokes* (CARS) para la detección de las bacterias. Esta técnica no emplea etiquetas, y ofrece una mejora en los niveles de señal. La técnica hiperespectral CARS registra una pila de imágenes que contienen un espectro en cada píxel y se usan para la detección no invasiva de endosporas bacterianas únicas.

En la Figura 2.7 (a y b) se muestra la detección de la bacteria *E.coli* concentrado al aire sobre el vidrio y su respectiva firma hiperespectral. En la Figura 2.7 (c y d) se observa la imagen CARS después de la recuperación de fase y el espectro correspondiente de *E.coli*.

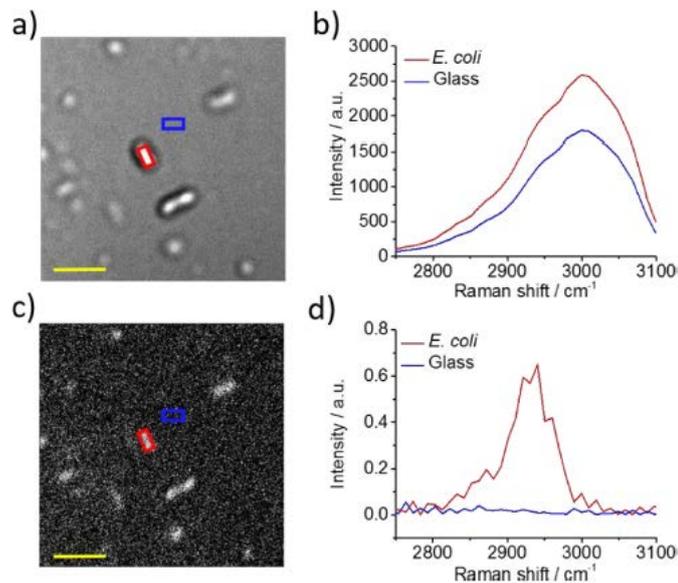


Figura 2.7. Detección de la bacteria *E.Coli* concentrado al aire sobre el vidrio y su respectiva firma hiperespectral (a y b). imagen por CARS después de la recuperación de fase (c y d).

Esta técnica también se utiliza para la detección de dicha bacteria en la orina tal y como se muestra en la Figura 2.8.

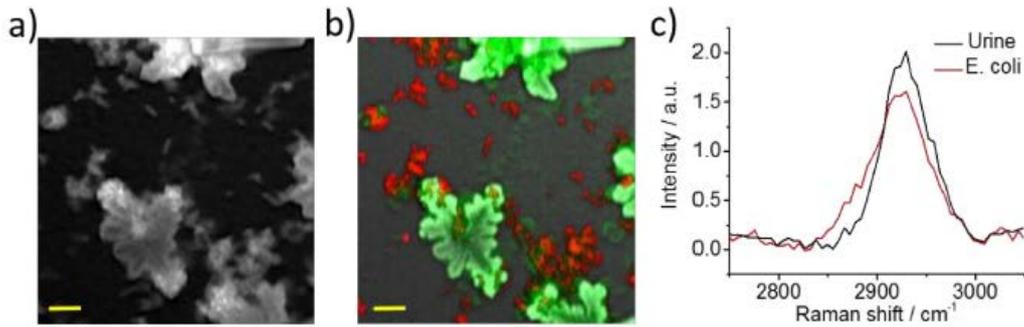


Figura 2.8. Imagen CARS de la mezcla de E.coli-orina (a). Detección de bacterias en la orina (b). Espectro de salida de cada componente (c).

En la Figura 2.8 a) se muestra primero la imagen de CARS de la mezcla de E.coli-orina, mientras que la segunda imagen se corresponde con la detección de bacterias en la orina. La E.coli se mapea con el color rojo y la orina se mapea con el color verde. La imagen final se corresponde con los espectros de salida recuperados de cada componente.

En otro estudio se utiliza un sistema de imágenes hiperespectrales microscópicas para distinguir entre células gástricas normales y cancerígenas [26]. Se analizaron las características del espectro de transmisión tiñendo previamente las muestras de ocho pacientes diferentes. Mediante este método se consiguen observar características distintivas entre los núcleos de las células normales y las cancerígenas, que depende del nivel de pH del núcleo de la célula.

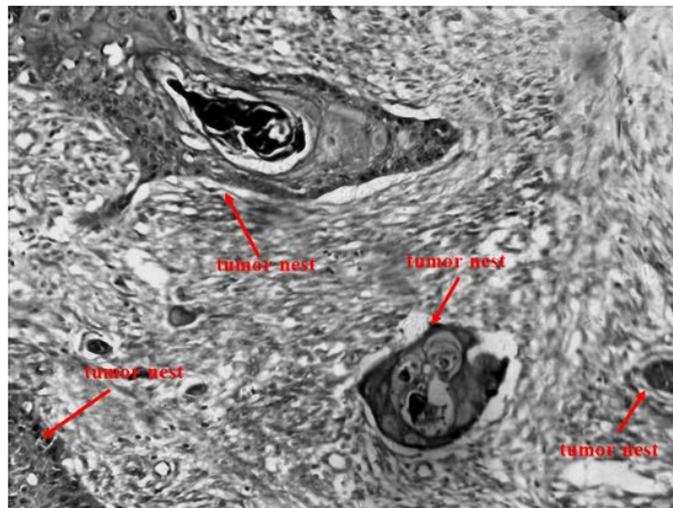


Figura 2.9. Imagen microscópica de los nidos tumorales en los tejidos gástricos.

En la Figura 2.9 se observan las células cancerígenas, denominadas nidos tumorales (TN), con una geometría y morfología característica. Por norma general, los núcleos de las células cancerígenas son más grandes que las células normales por lo que son fáciles de identificar. Sin embargo, en ciertas ocasiones las células

cancerígenas individuales diseminan a los tejidos circundantes siendo similares a las células normales. Por lo tanto, se requieren mayores detalles para la identificación de dichas células, y para ello se hace uso de la información espectral.

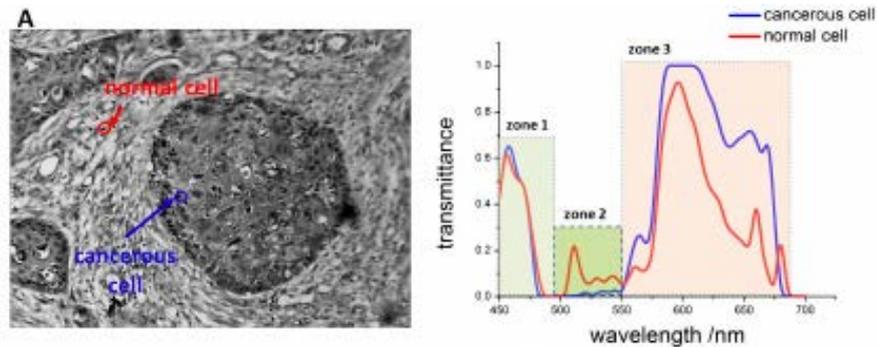


Figura 2.10. Imagen microscópica de tejido gástrico cancerígeno y espectro de transmisión de núcleos celulares normales y cancerígenas.

En la Figura 2.10 se muestran las tres zonas diferentes en la región visible identificadas con distintos colores. Mediante las imágenes hiperespectrales se recogió información espectral de 50 células normales y 50 cancerígenas. Debido a las variaciones biológicas individuales en las muestras de cada paciente, los espectros de transmisión obtenidos a partir de diferentes muestras no son idénticos.

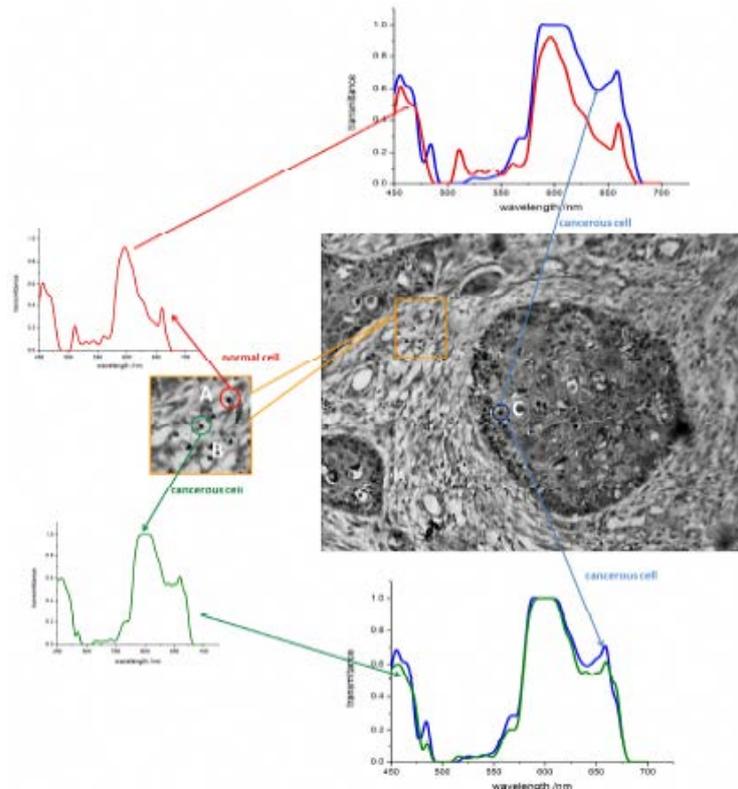


Figura 2.11. Identificación de células cancerígenas que diseminan a los tejidos normales.

En la Figura 2.11, se puede observar que la etiqueta A se corresponde con una célula normal, la B se trata de una célula cancerígena que disemina a los tejidos normales y finalmente, la etiqueta C la cual indica una célula cancerígena en el nido

tumoral. Aunque las células A y B son morfológicamente iguales exhiben diferentes respuestas espectrales.

Además, se ha propuesto utilizar la tecnología de las imágenes hiperespectrales para la detección de la saturación de oxígeno. Los diferentes estudios han demostrado que la combinación de la información tanto espacial como espectral obtenida en este tipo de sistemas contribuye de forma directa en la detección y el diagnóstico de cambios patológicos.

Para medir la tendencia de cambios de la saturación del oxígeno en la microvasculatura lo que se hizo fue obtener los datos de un ratón, durante dos días, cuatro y seis. Después de la implantación de un tumor, las muestras se presentan en la Figura 2.12. Imágenes hiperespectrales de la saturación de oxígeno en los días 2, 4 y 6 respectivamente, en donde se observa que la primera fila presentan las imágenes de la banda 12, mientras que en la segunda las imágenes utilizan las bandas 12 y 30. La tercera fila se corresponde con los pseudocolores, donde se puede apreciar que con el crecimiento del tumor la saturación de oxígeno se reduce. Esta tendencia se muestra en los mapas de abundancia de la cuarta fila que se encuentra acorde a los cambios de saturación de hemoglobina.

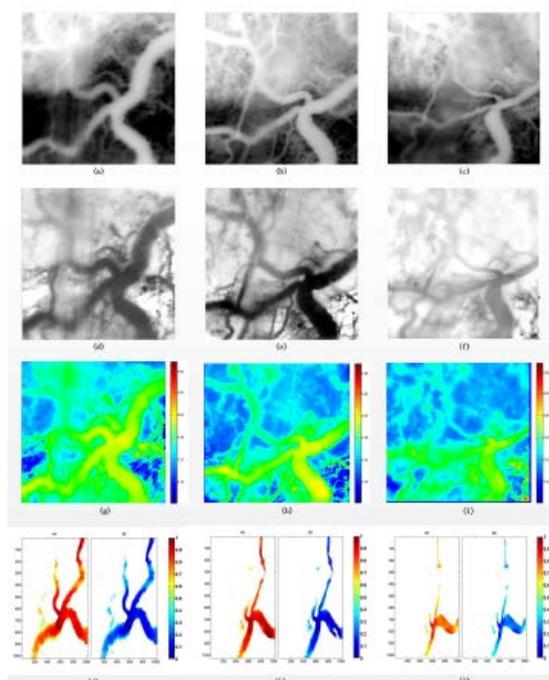


Figura 2.12. Imágenes hiperespectrales de la saturación de oxígeno en los días 2, 4 y 6 respectivamente después de la implantación del tumor.

El examen patológico de la neoplasia cervical se puede llevar a cabo convencionalmente tomando muestras de biopsia cervical y tiñéndolas para identificar células con morfología anormal. Es un método lento e invasivo que

provoca daños al paciente de forma innecesaria en la mayoría de los casos. Por ello, el siguiente estudio tiene como objetivo investigar la efectividad de un método de diagnóstico no invasivo. Para ello, se emplean generadores de imágenes hiperespectrales a múltiples escalas con el fin detectar y localizar tanto a nivel celular como de tejidos neoplasias cervicales [27].

A nivel microscópico, el generador de imágenes hiperespectrales se acopló para recoger las imágenes de transmitancia del deslizamiento patológico. En la Figura 2.13 se muestra el sistema desarrollado para la detección de la neoplasia cervical y el sistema de imágenes microscópicas hiperespectrales.

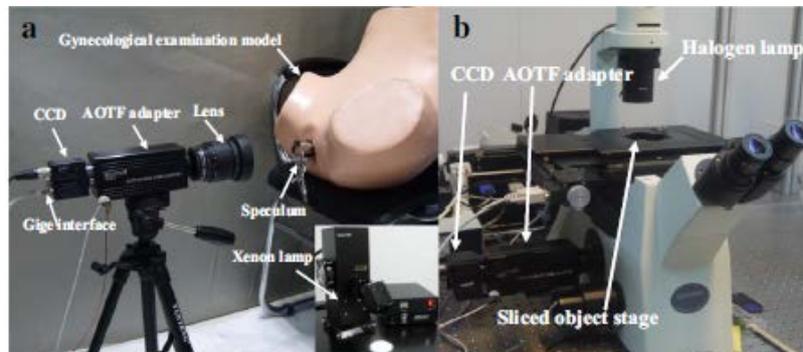


Figura 2.13. a) Sistema de imágenes hiperespectrales; b) Sistema de imágenes hiperespectrales microscópicas.

Para cada paciente se realizó una biopsia del tejido cervical en cuatro lugares sospechosos. Cada muestra se cortó en dos secciones (ver Figura 2.14, una que se tiñó para el examen histopatológico convencional y la otra para preservar las características del tejido original, la cual no se tiñó.

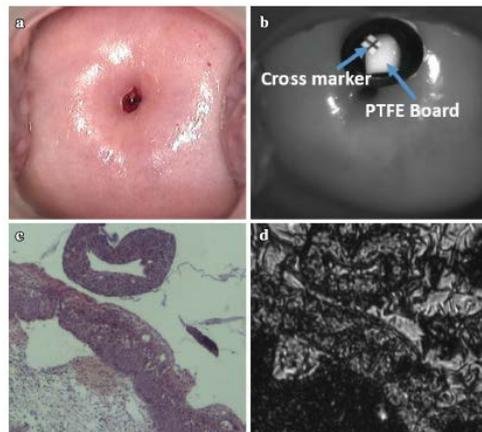


Figura 2.14. a) Imagen del tejido cervical de múltiples escalas; b) Imagen hiperespectral del tejido cervical; c) Imagen microscópica hiperespectral del tejido cervical teñido; d) Imagen microscópica hiperespectral no teñido.

En función de los hallazgos patológicos de este estudio la neoplasia cervical se dividió en tres categorías en CIN1, CIN2 y CIN3 que se corresponde con la displasia severa. En la Figura 2.15 se muestran los resultados de la clasificación de

las imágenes. Los círculos negros de la Figura 2.15 corresponden con las áreas sospechosas identificadas por el médico.

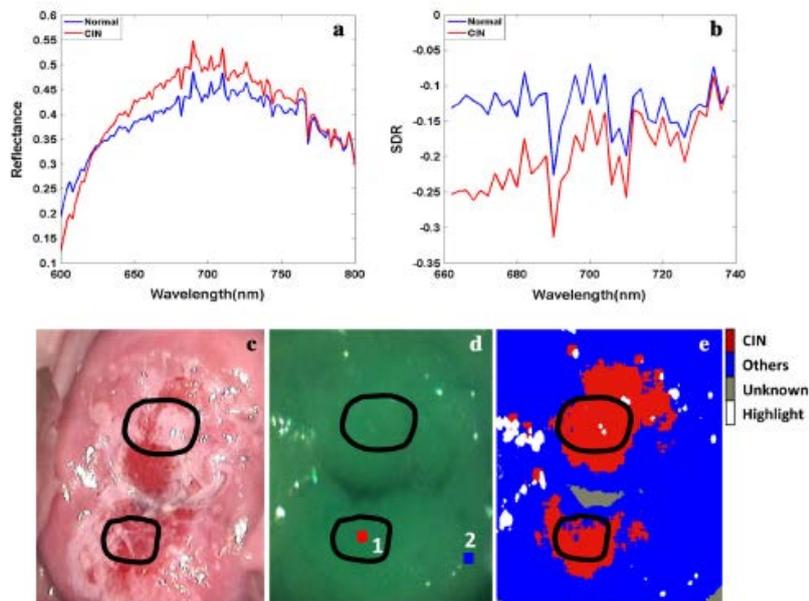


Figura 2.15. Resultados obtenidos de la clasificación de imágenes. a Curva de la reflectancia relativa del tejido localizados en dos partes diferentes. b Espectros. c Imagen cervical de un cuello uterino anormal. d mapa de pseudocolor por tres imágenes hiperespectrales. El resultado clasificación.

Las tecnología de estas imágenes así como su aplicación en los diferentes campos de la medicina avanzan a pasos agigantados, un estudio desarrolla un enfoque moderno para la detección de lesiones de hiperintensidades de materia blanca en imágenes cerebrales de resonancia magnética [28]. La imagen hiperespectral es una tecnología innovadora no invasiva con aplicaciones médicas como por ejemplo en el melanoma [29] o la celulitis, que es una enfermedad infecciosa que produce una inflamación de la piel. Un estudio ofrece la posibilidad de evaluar la celulitis dando la posibilidad de realizar un estudio primario de forma no invasiva y rápida [30]. Otro de los nuevos campos más reciente es usa esta técnica para el estudio y evaluación cuantitativa del proceso de envejecimiento de la piel, tema importante para las investigaciones no solo médicas sino también de la industria cosmética [31].

2.2. Imágenes Hiperespectrales

Para facilitar la comprensión de los conceptos fundamentales asociados al de imagen hiperespectral (*imaging spectroscopy*) se partirá de la definición de cada uno de estos términos con el fin de entender su contexto.

La palabra imagen hace referencia a la representación de la apariencia o forma de un objeto. Por otro lado, la espectroscopía es el estudio de la interacción de la radiación electromagnética con los distintos materiales. Con la fusión de estos conceptos se entiende que una imagen hiperespectral es aquella que viene descrita por un vector con información tanto espacial (x, y) como espectral (λ) dentro de una misma escena. El prefijo hiper- hace referencia al número de bandas utilizadas para esta técnica.

El impacto de las imágenes hiperespectrales en el mundo científico se debe principalmente a su alta resolución espectral, ya que aportan mayor información de la que el ojo humano es capaz de percibir. Dentro del espectro electromagnético, que se muestra en la Figura 2.16, el ojo humano solo es capaz de captar una ínfima parte de la radiación electromagnética. El espectro visible comprende desde los 400 hasta los 750 nanómetros (nm) aproximadamente, percibiendo el ojo cada una de estas longitudes de onda como un color diferente (Rojo, verde y azul, RGB.). Esto se debe, a que en la retina solo se encuentran tres tipos de células sensibles al color, denominada conos.

A diferencia del ojo humano, los sensores utilizados en las cámaras hiperespectrales tienen la capacidad de medir la radiación reflejada no sólo dentro sino también fuera de dicho espectro visible, se captan así centenares de bandas espectrales desde la ultravioleta (UV) hasta el infrarrojo (IR) [32].

Otra de las características relevantes de la tecnología de las imágenes hiperespectrales es que la firma espectral (*spectral signature*) hace posible la identificación de los diferentes objetos que se encuentran en una misma escena. Para ello, se explota el hecho de que cada material refleja, absorbe y emite una radiación electromagnética en relación con las características de su composición y su forma molecular. Por lo que mide en las diferentes longitudes de onda la radiación reflejada, sobre una región espectral suficientemente amplia, se puede utilizar la firma espectral para caracterizar, identificar o discriminar cualquier tipo de objeto [33].

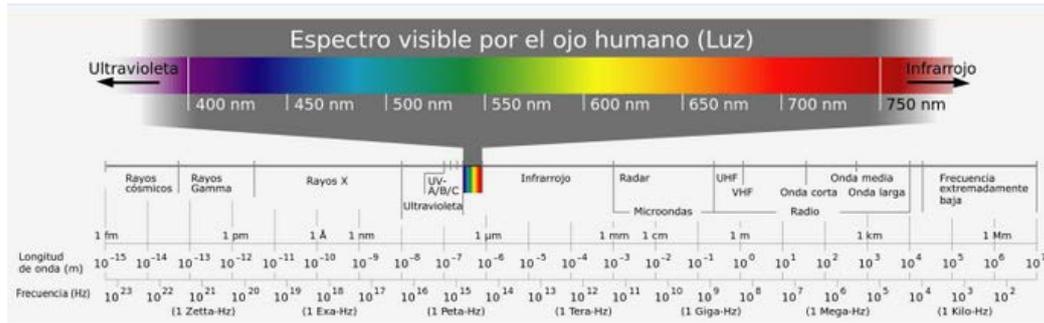


Figura 2.16. Espectro electromagnético.

2.2.1. Definición y conceptos básicos

Es importante conocer la terminología básica asociada a las imágenes hiperespectrales, siendo esto de gran utilidad para familiarizarse con la información técnica y las definiciones utilizadas para este campo. Tal y como se ha comentado anteriormente sobre estas líneas y se muestra en la Figura 2.17, es posible identificar distintos materiales (Suelo, agua y vegetación) a partir de su firma espectral. La reflectancia, término que hace referencia a la capacidad que tiene un objeto de reflejar luz, varía con la longitud de onda. Este fenómeno se debe principalmente a que la energía es absorbida en ciertas longitudes, por lo que partiendo de esta base y si se analizan las gráficas mostradas en la Figura 2.17, se entiende que la firma espectral es la curva en la que se recogen las variaciones de la reflectancia para cada uno de los distintos materiales encontrados [34].

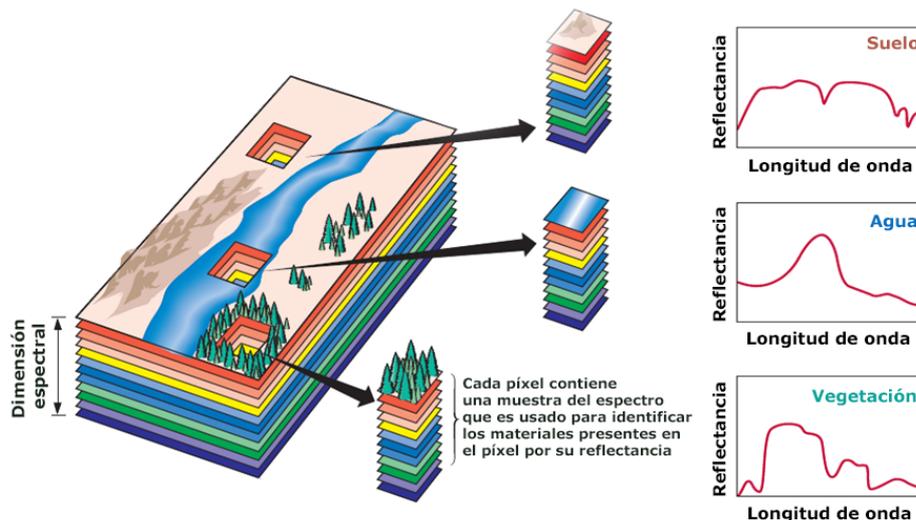


Figura 2.17. Firma espectral de diferentes materiales.

Toda la información muestreada en esta técnica es almacenada en una estructura de datos tridimensional llamada cubo hiperespectral (*hyperspectral cube*) de tres dimensiones, los ejes X e Y corresponden a la información espacial,

posición del píxel, mientras que λ se corresponde con la información espectral, tal y como se puede observar en la Figura 2.18.

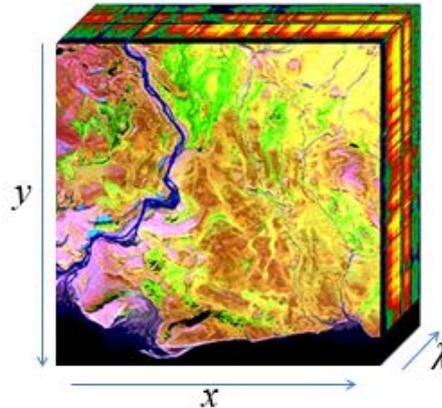


Figura 2.18. Cubo hiperespectral con sus respectivos ejes.

En cuanto al rango espectral, este describe las regiones de longitud de onda cubiertas por el sistema. En otras palabras, es la parte muestreada del espectro electromagnético, en donde en la Figura 2.19, se muestran dichas longitudes de onda (ultravioleta, visible e infrarroja).

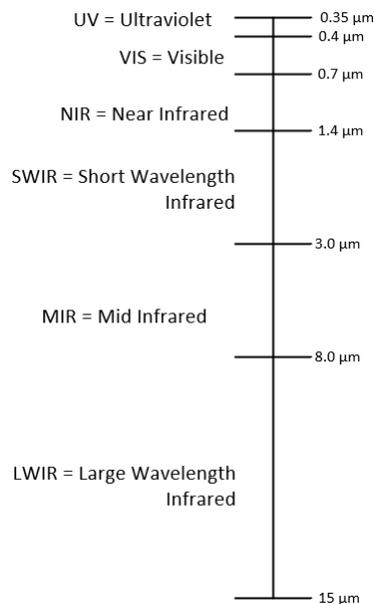


Figura 2.19. Rangos espectrales.

Existen varios rangos espectrales que se ajustan a diferentes aplicaciones como el estudio de la vegetación que trabaja en longitudes de onda VNIR (*Visible and Near Infrared*), rango correspondiente al visible e infrarrojo cercano, o la mineralogía que emplea las SWIR (*Short Wavelength Infrared*) debido a que el suelo tiene una menor reflectancia espectral [34].

Asimismo, la resolución hace referencia al nivel de detalle con el cual se pueden capturar las imágenes [35]. Por consiguiente, la resolución espacial es la medida del nivel de detalles visibles en una imagen y viene determinada por el tamaño del píxel. Cuanto menor es el área que se representa por cada píxel mayores serán los detalles captados, obteniéndose una mejor resolución espacial, tal y como se muestra en la Figura 2.20.

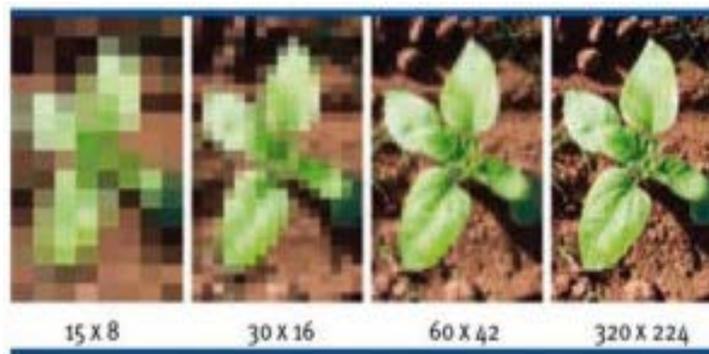


Figura 2.20. Efecto cambio de resolución (píxeles) para una imagen en color.

Por otra parte, la resolución espectral hace referencia a la mínima separación que puede existir entre las bandas espectrales consecutivas. Por lo que el número de bandas y el ancho de estas determinan dicha resolución. En función de la resolución espectral, el número de bandas variará. En la Figura 2.21, se muestran los distintos tipos de imágenes, las multispectrales están conformadas por unas pocas bandas (decenas) mientras que las hiperespectrales están formadas por un número mayor, aportando así mucha más información de la escena observada.

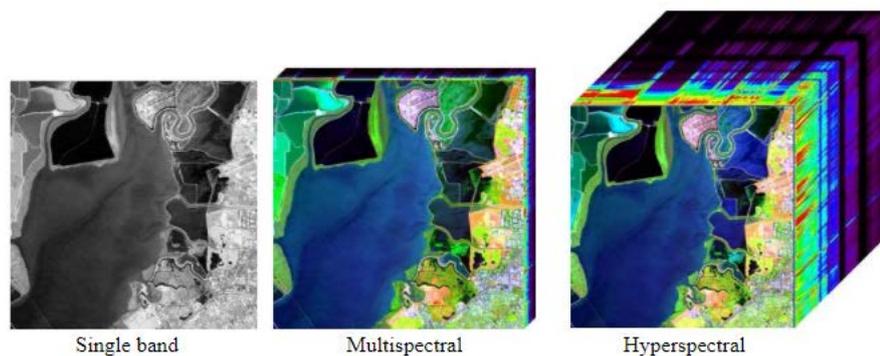


Figura 2.21. Tipos de imágenes espectrales.

2.3. Clasificadores

Las técnicas de clasificación constituyen un campo muy activo en el análisis de las imágenes hiperespectrales. Su principal objetivo, es el de asignar una etiqueta, correspondiente a un determinado material, a cada vector de píxel. Sin

embargo, es una ardua tarea debido a los retos que presenta: la escasez de muestras etiquetadas, con la presencia de las características redundantes o con la alta dimensionalidad de las imágenes. Dichos problemas dificultan tanto los procesos de clasificación supervisados como los semi-supervisados. En esta sección se presentarán los conceptos básicos asociados a las técnicas de clasificación.

2.3.1. Machine Learning

Los métodos de aprendizaje automáticos (*Machine Learning*) han sido foco de numerosas investigaciones en los últimos años. *Machine Learning* es una disciplina basada en el ámbito de la Inteligencia Artificial, centrada en la idea de generalizar comportamientos a partir de una información no estructurada suministrada en forma de ejemplos [36]. En otras palabras, consiste en sistemas capaces de analizar y realizar una comprensión de los datos, para detectar y generar un modelo que facilite la posterior toma de decisiones.

Además de generar un modelo, otros de los objetivos del *Machine Learning* es desarrollar algoritmos eficientes y robustos capaces de lidiar con grandes cantidades de datos, que pueden estar representados en espacios de gran tamaño dimensional [37].

2.3.2. Algoritmos supervisados

En el aprendizaje supervisado se incluyen diferentes algoritmos de clasificación, que se encuentran recogidos dentro del concepto explicado anteriormente. Dicha técnica, toma como entrada un conjunto de datos conocidos para realizar las predicciones. El conjunto de datos de entrenamiento se apoya por un lado en los datos de entrada y por otro, en los valores de respuesta, que son los datos ya etiquetados. De tal forma, que a partir del conjunto de datos y una vez entrenado el algoritmo, es capaz de generar un modelo que realiza predicciones para un nuevo conjunto de datos [38].

De manera conceptual, se puede formalizar como un problema de optimización. Sea $X \in \mathbb{R}_n$ el dominio de los atributos y $G = \{G_1, G_2, \dots, G_k\}$ el conjunto de etiquetas de grupo. La finalidad, es el establecimiento de una función matemática que permita mapear $h(\cdot): X \rightarrow G$, conocido como clasificador, que

optimiza una medida adecuada de la capacidad de predicción cuando se aplica a entidades con datos de grupos desconocidos [39].

Ponga por caso, la observación de varios ejemplos de un vector aleatorio a , y un valor asociado o vector b . El aprendizaje supervisado consistirá en aprender a predecir b desde a , con la estimación de la probabilidad existente entre estos dos vectores, $p(b|a)$ [40]. Por consiguiente, los algoritmos supervisados parten de un conjunto de datos (a) , que contienen una serie de características con sus correspondientes etiquetas asociadas. Algunos ejemplos de algoritmos de aprendizaje supervisado son: *Support Vector Machine (SVM)*, *Classification Trees (CT)*, *Artificial Neural Network (ANN)* entre otros.

2.3.2.1. Support Vector Machine (SVM)

El SVM es un algoritmo supervisado de clasificación binaria basado en el principio de minimización de riesgos estructurales. Una manera simple de construir un clasificador binario es generar un hiperplano óptimo en forma de superficie de decisión, que divida los datos en función de sus características con un margen de separación máximo [41].

En teoría, se parte de un conjunto separable de datos de entrenamiento $C = \{(x_1, y_1) \dots, (x_n, y_n)\}$ que consisten en una secuencia ordenada de datos y etiquetas, donde $x_i \in \mathbb{R}^d$ e $y_i \in \{+1, -1\}$ que se define como un hiperplano de separación, cuya función lineal es capaz de separar el conjunto dado por la expresión (2.1) donde $w_i \in \mathbb{R} \forall i = 1, \dots, d$ y $b \in \mathbb{R}$

$$D(x) = (w_1x_1 + \dots + w_dx_d) + b = \langle w, x \rangle + b_1 \quad (2.1)$$

Dicho hiperplano deberá cumplir las desigualdades (2.2) y (2.3):

$$\langle w, x_i \rangle + b \geq 0 \text{ si } y_i = +1 \quad \forall i = 1, \dots, n \quad (2.2)$$

$$\langle w, x_i \rangle + b \leq 0 \text{ si } y_i = -1 \quad \forall i = 1, \dots, n \quad (2.3)$$

En donde si $y_i = +1$ la clase es positiva y, en caso contrario, cuando $y_i = -1$ la clase es negativa y, por consiguiente, no son miembros pertenecientes a la clase [42].

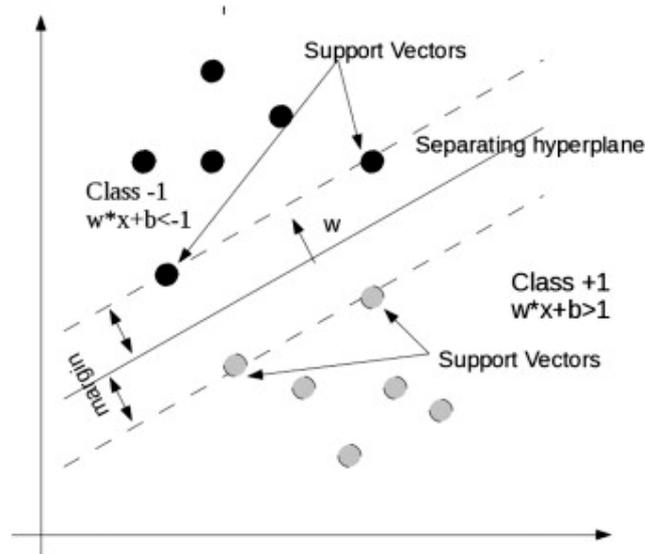


Figura 2.22. Clasificación hiperplano (linear separable case).

Asimismo, en la *Figura 2.22* se observa un ejemplo del modo de trabajo del SVM en donde se muestra que el algoritmo emplea los *Support Vectors*, ejemplos de entrenamiento que se encuentran en los límites del margen del hiperplano, como datos de entrenamiento para construir la superficie de decisión [43].

2.3.2.2. Árboles de Clasificación (CT)

Los CT son unas de las técnicas más empleadas para los problemas de clasificación gracias a la facilidad de la interpretabilidad de sus datos. Los árboles de decisión dividen recursivamente el espacio de características y asignan una etiqueta a cada partición resultante. Por tanto, a partir de estas divisiones y etiquetas se clasifican los puntos futuros.

Dados los datos de entrenamiento (X, Y) que contiene n observaciones $(x_i, y_i), i = 1, \dots, n$, cada uno con p características $x_i \in \mathbb{R}^d$ y una etiqueta de clase $y_i \in \{1, \dots, K\}$, que indica cuál de las posibles etiquetas K está asignada a ese punto. Donde, se supone que los valores de entrenamiento se encuentran normalizados al intervalo 0-1, entonces cada $x_i \in [0,1]^p$. Y, por consiguiente, para producir las regiones jerárquicas, se busca la partición recursiva de $[0,1]^p$ [44].

Asimismo, el árbol final está compuesto, por un lado, por nodos ramas y por otro, por nodos hojas [45].

2.3.2.3. Redes Neuronales Artificiales (ANN)

Las ANN emplean como base el modelo neuronal del cerebro humano, para desarrollar la capacidad de interpretar, elaborar y utilizar la información de forma

adecuada. Por lo que las ANN pertenecen al campo de la inteligencia artificial, destacando por su capacidad de modelar de manera efectiva problemas altamente complejos [46].

En la Figura 2.23, se considera un nodo i que recibe X_i entradas con sus respectivos pesos de conexión w_{ij} . El θ_j , es el valor de umbral o sesgo, siendo otro factor asociado con el almacenamiento de información.

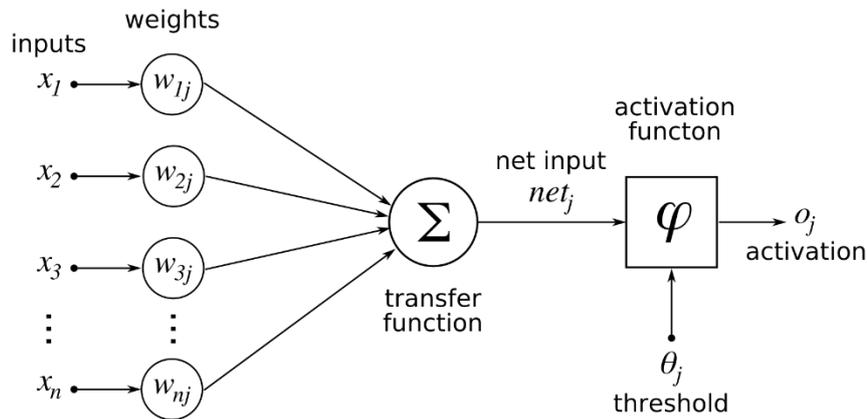


Figura 2.23. Un nodo ANN con sus elementos.

En primer lugar, las señales de entrada se multiplican por el factor de peso. Una vez que las señales ponderadas se recopilan en el nodo, estos valores se agregan para hacer la suma ponderada, ecuación que indica que la señal con el peso más elevado tiene un mayor efecto. Finalmente, el nodo ingresa la suma ponderada en la función de activación, que es la que determina el comportamiento del nodo, y obtiene el resultado [47].

Se puede crear una gran variedad de redes neuronales en función de cómo estén conectados los nodos, el número de capas dependerá de la complejidad del sistema. La estructura que se muestra en la Figura 2.24 está compuesta por la capa de entrada, que son los que transmiten las señales iniciales a los siguientes nodos. La capa de salida que es la que da el resultado final de la red neuronal. Y finalmente, la capa que se encuentran entre la de entrada y la de salida que se conoce como capa oculta, recibe este nombre porque no es accesibles desde el exterior de la red neuronal.

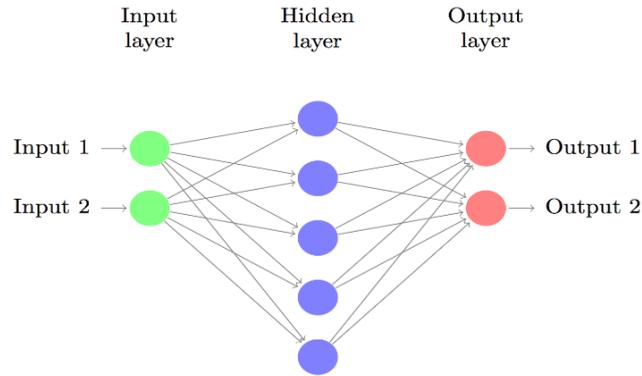


Figura 2.24. Estructura general por capas de una red neuronal.

2.3.2.4. K-Nearest Neighbors

Es un método no paramétrico que permite estimar la función de densidad de una o varias variables para cada clase de un conjunto. Para la clasificación calcula la probabilidad de que un elemento pertenezca a una clase a partir de los patrones de ejemplo de esa misma clase, es decir, trata de clasificar una muestra desconocida basada en la clasificación conocida de sus vecinos [48].

En la Figura 2.25, se muestra la toma de decisiones k-nn para $k = 1$, donde se utiliza de referencia solo una muestra conocida y $k = 4$, donde se consideran las 4 muestras más cercanas para realizar la clasificación de la muestra desconocida. El conjunto de muestras se encuentra dividido en 2 clases (clase cuadrados rojos y clase triángulos verdes).

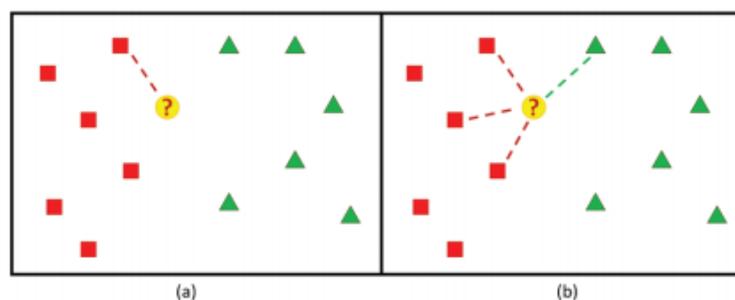


Figura 2.25. Ejemplo del k-vecino más cercano con dos clases (a) regla de decisión 1-nn (b) regla de decisión 4-nn.

En ambos casos, la muestra desconocida se clasifica como perteneciente a la clase de la izquierda (clase cuadrados rojos) [49].

2.3.3. Algoritmos semi-supervisados

En el aprendizaje supervisado se genera el modelo a partir de una gran cantidad de ejemplos etiquetados de entrenamiento. Sin embargo, en muchas aplicaciones prácticas de clasificación se encuentran grandes cantidades de muestras sin etiquetar. Esto se debe principalmente a que la recopilación de ejemplos etiquetados es normalmente costosa. Asignar etiquetas a estos modelos sin etiqueta es un proceso que requiere esfuerzo y experiencia humana. Por ese motivo, es interesante desarrollar algoritmos que puedan utilizar tanto datos etiquetados como no etiquetados para la clasificación [50].

El aprendizaje semi-supervisado (SSL) se enfoca para los casos en los que la proporción de muestras de datos etiquetados es pequeña en comparación con las muestras sin etiquetar. Es una herramienta potente para generar modelos de aprendizaje donde el número de datos etiquetados es relativamente bajo [51].

La mayoría de los enfoques de aprendizaje semi-supervisado se basan en diseñar algoritmos de aprendizaje especializados para utilizar con eficacia los datos disponibles. Sin embargo, en muchas ocasiones ocurre que ya se tiene un algoritmo supervisado escogido, por lo que en este caso la solución más factible es mejorar su rendimiento utilizando los datos no etiquetados disponibles.

2.4. Resumen

En este capítulo, se han presentado los conceptos fundamentales que se deben tener en cuenta para la comprensión del desarrollo de este proyecto. Donde, se consideraba necesario entender tanto la composición como las especificaciones de los sistemas de adquisición de imágenes hiperespectrales. Además, se realizó una breve introducción de los diferentes campos de aplicación con el objetivo de comprender el alcance de dicha técnica.

Por otra parte, se ahondó en el concepto de *Machine Learning*. Donde se presentaron los diferentes tipos de algoritmos y los clasificadores que se emplearán en este TFG con la finalidad de clasificar el contenido de una imagen hiperespectral.

CAPÍTULO 3.

3. BASE DE DATOS

En este capítulo se describe la base de datos empleada para evaluar los diferentes casos de estudio en la clasificación de las imágenes hiperespectrales. Asimismo, se realiza una descripción del procedimiento llevado a cabo para la obtención de dichas imágenes en el proyecto de investigación HELICoiD.

HELICoiD (www.helicoid.eu) fue un proyecto europeo del programa de Tecnologías Futuras y Emergentes (FET-Open), en el marco del séptimo Programa Marco de la Unión Europea, coordinado por el Instituto Universitario de Microelectrónica Aplicada (IUMA) de la Universidad de Las Palmas de Gran Canaria (ULPGC).

El proyecto HELICoiD, aplica técnicas avanzadas de clasificación de imágenes hiperespectrales para la detección de tumores cerebrales. Su objetivo principal es generar un demostrador no invasivo capaz de discriminar entre tejido sano y tumoral en tiempo real durante las intervenciones de neurocirugía. De tal forma que se ha fabricado un sistema experimental intraoperatorio, que permite a los neurocirujanos confirmar en tiempo real la resección completa del tejido tumoral, evitando la resección excesiva del tejido sano adyacente.

3.1. Procedimiento de captura de imágenes hiperespectrales

Con el fin de obtener las imágenes hiperespectrales de la superficie del cerebro humano durante las operaciones neuroquirúrgicas, las cámaras hiperespectrales seleccionadas son, por un lado, el modelo *Hyperspec® VNIR Serie A* y por otro, el modelo *Hyperspec® NIR 100/U*.

El modelo *Hyperspec® VNIR Serie A* (Figura 3.1 a) cubre un rango espectral que va desde 400 a 1000 nm y es capaz de capturar 826 bandas espectrales y 1004 píxeles espaciales. Mientras que el modelo *Hyperspec® NIR 100/U* (Figura 3.1 b) oscila entre 900 a 1700 nm, con 172 canales espectrales y 320 píxeles espaciales. Ambas se basan en la técnica de barrido lineal (escaneo de línea), método utilizado para obtener el cubo hiperespectral, que cubre un rango espectral

total de 400 y 1700nm (VNIR y NIR), donde se muestran las regiones espectrales más relevantes para la aplicación de este proyecto.

El sensor es una matriz de detectores bidimensional, una dimensión espacial y otra espectral completa donde la escena se captura en una sola toma o *frame*. La técnica empleada por estas cámaras ofrece un compromiso entre la resolución espectral y espacial, así como del tiempo de adquisición [52].

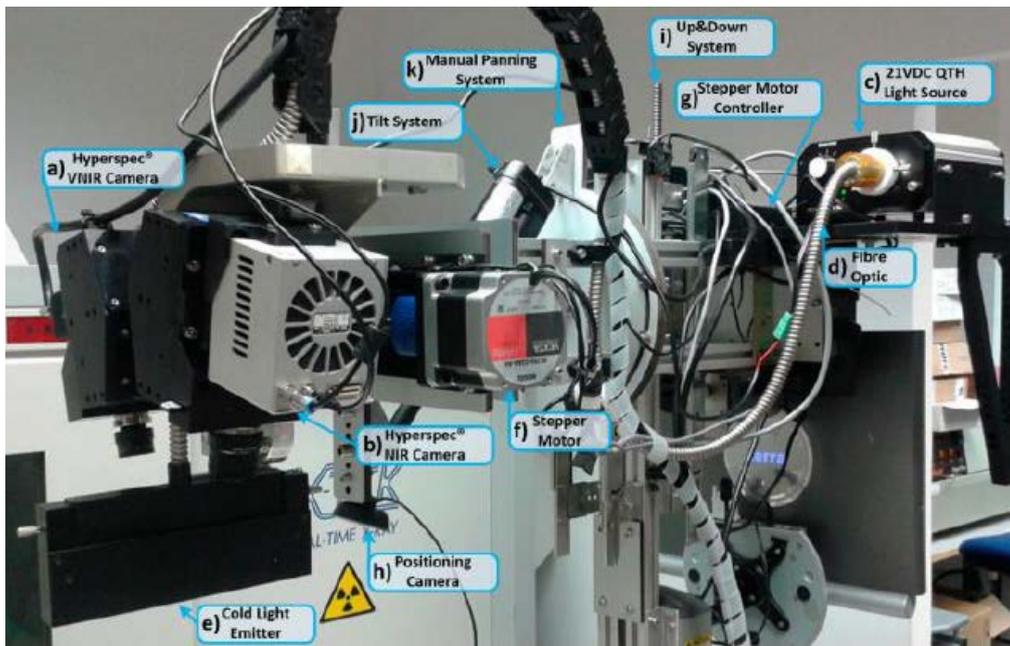


Figura 3.1. Plataforma de adquisición de demostradores HELICoiD. (a, b) cámaras VNIR y NIR HS montadas en la plataforma de exploración; (c-e) Fuente de luz QTH conectada al sistema de fibra óptica para la transmisión de luz para obtener una emisión de luz en la plataforma de exploración; (f, g) motor paso a paso acoplado al eje y conectado al controlador de motor paso a paso para realizar el movimiento lineal de las cámaras; (h) Posicionamiento de la cámara utilizada para identificar la posición del campo de visión de las cámaras (FOV); (i) El sistema Up & Down utilizado para enfocar las cámaras HS; (j) y (k) Sistemas de panorámica e inclinación manual utilizados para orientar correctamente la plataforma de exploración.

En la Figura 3.1, se muestra la plataforma instalada en el área de preoperatorio del Hospital Doctor Negrín que se empleó en el proyecto HELICoiD para la adquisición de dichas imágenes. El sistema de iluminación es una lámpara tungsteno de cuarzo (QTH) de 150 W, con una emisión de banda ancha entre 400 y 2200 nm. Esta elección se debe a la elevada homogeneidad de su espectro que ofrece en todo el rango espectral.

El proyecto HELICoiD ha desarrollado un demostrador capaz de obtener simultáneamente dos cubos hiperespectrales, en la Figura 3.2 se muestra dicho elemento mediante un diagrama de flujo. Los pasos mostrados en él se explican en las siguientes secciones de este capítulo.

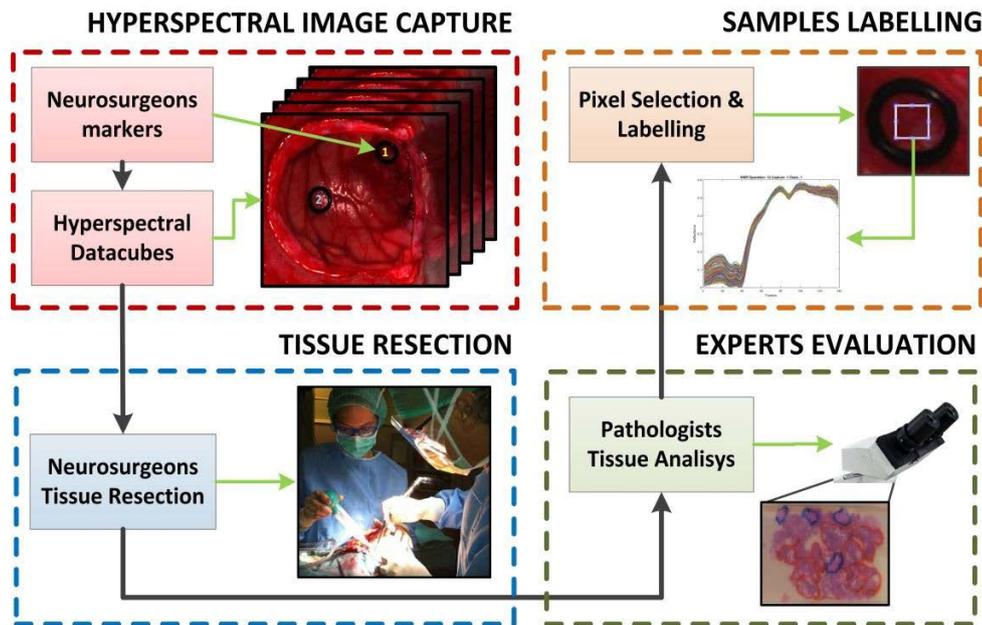


Figura 3.2. Captura de datos y proceso de etiquetado proyecto HELICoID.

En primer lugar, antes de la operación, el paciente tiene una guía de imagen estereotáctica (IGS) con tomas compatibles de Tomografía Computarizada (CT) y Resonancia Magnética (MRI) que se cargan en el sistema IGS. Después, el paciente se somete a anestesia general para realizar una incisión en el cuero cabelludo. Se expone el cráneo antes de perforarlo con un taladro de alta velocidad donde seguidamente, se inserta un craneótomo en el orificio de la trépana y se realiza una craneotomía. En otras palabras, se extrae parte del hueso del cráneo conocido como colgajo óseo. Y posteriormente, la duramadre (durotomía) se corta con un cuchillo para exponer la superficie del cerebro.

Finalmente, tras usar el demostrador, se crea una base de datos de imágenes hiperespectrales del cerebro humano *in vivo*, donde se han obtenido los cubos hiperespectrales con un total de 22 pacientes del Hospital Universitario Doctor Negrín. Los tumores capturados se corresponden tanto a tumores cerebrales primarios como secundarios, correspondientes a la metástasis [53].

3.1.1. Captura de imágenes hiperespectrales

Las imágenes son capturadas después de la durotomía y antes de que las aracnoides y la piamadre, cubiertas del sistema nervioso central, se hayan roto. En caso de que el tumor pueda observarse en la superficie, a partir de la apariencia visual, se colocan dos marcadores en forma de anillo de goma esterilizados, tal y

como se muestra en la Figura 3.3. De manera que, con el juicio del cirujano se identifica tanto la posición de dicho tumor como la parte de tejido cerebral sano.

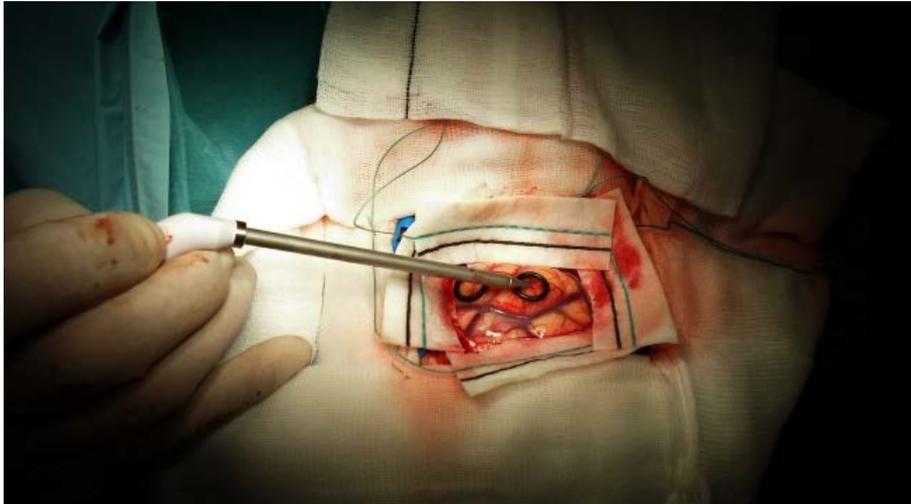


Figura 3.3. Puntero del sistema IGS sobre el marcador tumoral HELICoiD ubicado en la superficie expuesta del cerebro.

En caso de que sea posible la ubicación exacta de los marcadores, se utiliza el puntero del sistema IGC se identifica la ubicación de dichos marcadores del cerebro. Así, se permite conocer la posición de los marcadores del anillo de goma con respecto a una MRI o CT realizada previamente al paciente para el procedimiento quirúrgico. Se capturan las imágenes hiperespectrales de la superficie del cerebro expuesta tanto con marcadores como sin ellos. Los marcadores ofrecen un área de la imagen donde los píxeles pueden etiquetarse con la evaluación previa del cirujano y esta finalmente se contrasta con los resultados de la patología [54].

3.1.2. Resección de tejido

Una vez realizada la primera captura de la imagen hiperespectral, se retira el demostrador HELICoiD de la zona quirúrgica. Posteriormente, los cirujanos comienzan la resección del tumor y toman una muestra del tejido que se encuentra dentro del marcador tumoral. Esta se almacena en un contenedor con la etiqueta HELICoiD y se le asigna el número correspondiente con el marcador. Luego, se envían a patología y el resultado será usado como referencia para el desarrollo del algoritmo donde los números asociados ayudarán al proceso de etiquetado.

Mientras el tumor se reseca gradualmente, se captura el segundo conjunto de imágenes. Llegado el momento, en que el cerebro y el tumor macroscópicamente normales estén expuestos, si el cirujano considera seguro

detener la cirugía, este asegura una hemostasia perfecta y lava el campo cuidadosamente con solución salina tibia para eliminar cualquier resto de sangre sin modificar la temperatura y el cambio de flujo sanguíneo resultante. Seguidamente, el campo es succionado mediante la aplicación de un algodón al parénquima. El cirujano identifica la ubicación más adecuada para capturar las imágenes donde se colocan los marcadores (tumor y tejido normal sano), para obtener nuevamente las imágenes hiperespectrales con y sin ellos. Finalmente, las muestras de tejido que se obtienen a partir de la posición de los marcadores se envían al laboratorio de patología para el diagnóstico final del tejido.

3.1.3. Evaluación de expertos

La totalidad del tejido resecado se envía al laboratorio de Anatomía Patológica donde se procesa histológicamente y se somete a tinción H&E estándar y cualquier tinción adicional requerida para establecer un diagnóstico histopatológico definitivo. Los únicos que pueden determinar si un tejido dentro del marcador es o no un tumor, son los neuropatólogos, esto lo realizan mediante el análisis de las biopsias extraídas durante la operación. Las muestras se diagnostican como tumor o cerebro normal. Las tumorales se subdividen en tipo y grado tumoral, mientras que las cerebrales normales se clasifican como sustancia blanca o gris.

3.1.4. Muestras de etiquetado

A partir de la información proporcionada por los patólogos, y empleando la herramienta MATLAB, algunos píxeles de cada imagen hiperespectral se etiquetaron (ver Figura 3.4). De tal forma que se genera la verdad terrena o *ground truth* para el entrenamiento de los algoritmos. Las firmas espectrales de los píxeles etiquetados como *ground truth* serán usados en este TFG como entradas al algoritmo de clasificación supervisada para generar un modelo y determinar la calidad de la clasificación utilizando métricas cuantitativas. El procedimiento a seguir fue recortar aquellos píxeles encontrados dentro de los marcadores, sin incluir aquellos que tuvieran reflejos debido principalmente a la no uniformidad del cerebro. Los píxeles etiquetados se han dividido en cuatro clases: **tejido normal (sano)**, **tejido tumoral**, **vasos sanguíneos** y **background**.

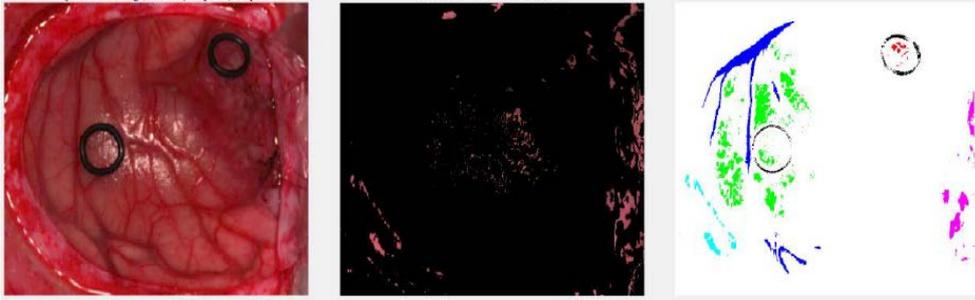


Figura 3.4. Captura de pantalla de la herramienta de etiquetado HELICoiD.

Para la realización de este proyecto se ha partido de una base de datos con imágenes hiperespectrales pre-procesadas, a las cuáles anteriormente se les eliminó el ruido y se le promediaron las bandas [55]. Con un total de 14 pacientes y 28 capturas, donde había pacientes que poseían más de una captura, y por ello, se unificaron los datos de cada paciente (Tabla 3.1). Dichas imágenes fueron obtenidas con el sistema de adquisición descrito anteriormente.

Los ficheros utilizados almacenan el *dataset* de las imágenes etiquetadas que contienen las siguientes variables:

- **data:** Matriz 2D en donde se almacenan las firmas espectrales de cada píxel etiquetado (número de píxeles X número de bandas).
- **label:** Vector donde se especifica la clase de cada píxel almacenado en data.

La variable *label4Classes* contiene las 4 clases nombradas anteriormente. La codificación se ha realizado de manera que el valor 1 de etiqueta se corresponde a un tejido normal sano, el valor 2 a tumor, el 3 a vasos sanguíneos (*Blood Vessel*) y por último, el valor de etiqueta 4 a *background*.

Tabla 3.1. Base de datos de las capturas hiperespectrales.

| Patients ID | Normal | Tumor | Blood Vessel | Background | Total | Diagnóstico |
|--------------------|---------------|--------------|---------------------|-------------------|--------------|---|
| 004 | 5007 | 28 | 965 | 1992 | 7992 | Lung Adenocarcinoma (<i>Secondary</i>) |
| 005 | 6061 | 21 | 1727 | 20483 | 28292 | Renal Carcinoma (<i>Secondary</i>) |
| 008 | 4482 | 1359 | 2331 | 8074 | 16246 | Grade IV Glioblastoma (<i>Primary</i>) |
| 012 | 11069 | 3994 | 14738 | 10416 | 40217 | Grade IV Glioblastoma (<i>Primary</i>) |
| 013 | 1827 | 16 | 129 | 589 | 2561 | Lung Adenocarcinoma (<i>Secondary</i>) |
| 015 | 1251 | 2046 | 4089 | 696 | 8082 | Grade IV Glioblastoma (<i>Primary</i>) |
| 016 | 8743 | 96 | 1996 | 22546 | 33381 | Grade IV Glioblastoma (<i>Primary</i>) |
| 017 | 1328 | 179 | 68 | 3069 | 4644 | Grade IV Glioblastoma (<i>Primary</i>) |
| 020 | 1842 | 3655 | 1513 | 2625 | 9635 | Grade IV Glioblastoma (<i>Primary</i>) |
| 021 | 6727 | 325 | 2985 | 8860 | 18897 | Breast Carcinoma (<i>Secondary</i>) |
| 022 | 10980 | 96 | 1744 | 3677 | 16497 | Grade III Anaplastic Oligodendroglioma (<i>Primary</i>) |
| 025 | 977 | 1282 | 907 | 3687 | 6853 | Grade IV Glioblastoma (<i>Primary</i>) |
| 028 | 2839 | 1920 | 73 | 23366 | 28198 | Lung Adenocarcinoma (<i>Secondary</i>) |
| 029 | 2098 | 1748 | 3341 | 15043 | 22230 | Grade III Anaplastic Oligodendroglioma (<i>Primary</i>) |

En la Tabla 3.1 se puede observar la cantidad de píxeles etiquetados pertenecientes a cada clase, los cuales son un total de cuatro: Normal, Tumor, *Blood Vessel* y *Background*. Para el paciente 4 (*Patient 004*) hay un total de 28 píxeles de la clase tumor, un número reducido en comparación con los valores del resto de clases donde 5.007 píxeles son de tejido normal sano, 956 de vasos sanguíneos y finalmente, 1.992 de *background*. Ocurre lo mismo para los pacientes 5, 13, 16 y 22, lo que implica un reto para la clasificación de la clase tumor. El modesto número de píxeles de esta clase se debe a la dificultad de conseguir una gran cantidad de píxeles de tejido tumoral que puedan ser etiquetados.

Por otra parte, se muestra el diagnóstico realizado por el equipo de neurocirujanos del Hospital Doctor Negrín para cada proceso quirúrgico. Donde se identificaron un total de 5 tipos diferentes de tumor (*Lund Adenocarcinoma*, *Renal Carcinoma*, *Grade IV Glioblastoma*, *Breast Carcinoma*, *Grade III Anaplastic Oligodendroglioma*)

Si se analiza la base de datos más en profundidad (ver *Tabla 3.2*), en el paciente 4 se obtienen que los píxeles identificados como tejido normal sano son los más abundantes conformando el 62.65% de las muestras. Le sigue la clase 4 (*background*) con un valor del 24.93%, la clase 3 (*Blood Vessel*) con el 12.07% y finalmente, la clase 2 (Tumor) con un porcentaje casi despreciable del 0.35%. Asimismo, entendiendo la base de datos como un conjunto único, la clase *Normal* conforma el 26.76% de las muestras, la clase *Tumor* el 6.88%, los *Vasos Sanguíneos* el 15.02% y finalmente a la *Background* pertenece el 51.34% de los datos.

Tabla 3.2. Porcentajes de cada clase correspondientes a cada paciente.

| Patients ID | Normal (%) | Tumor (%) | <i>Blood Vessel</i> (%) | <i>Background</i> (%) |
|-------------|------------|-----------|----------------------------|--------------------------|
| 004 | 62.65 | 0.35 | 12.07 | 24.93 |
| 005 | 21.43 | 0.07 | 6.10 | 72.40 |
| 008 | 27.59 | 8.36 | 14.35 | 49.70 |
| 012 | 27.52 | 9.93 | 36.65 | 25.90 |
| 013 | 71.34 | 0.62 | 5.04 | 23 |
| 015 | 15.48 | 25.32 | 50.59 | 8.61 |
| 016 | 26.19 | 0.29 | 5.98 | 67.54 |
| 017 | 28.60 | 3.85 | 1.46 | 66.09 |
| 020 | 19.12 | 37.93 | 15.7 | 27.25 |
| 021 | 35.60 | 1.72 | 15.80 | 46.88 |
| 022 | 66.56 | 0.58 | 10.57 | 22.29 |
| 025 | 14.26 | 18.75 | 13.23 | 53.8 |
| 028 | 10.06 | 6.82 | 0.26 | 82.86 |
| 029 | 9.40 | 7.87 | 15.03 | 67.70 |

Finalmente, en la *Figura 3.5* se muestran las firmas espectrales promedio del conjunto unificado de datos.

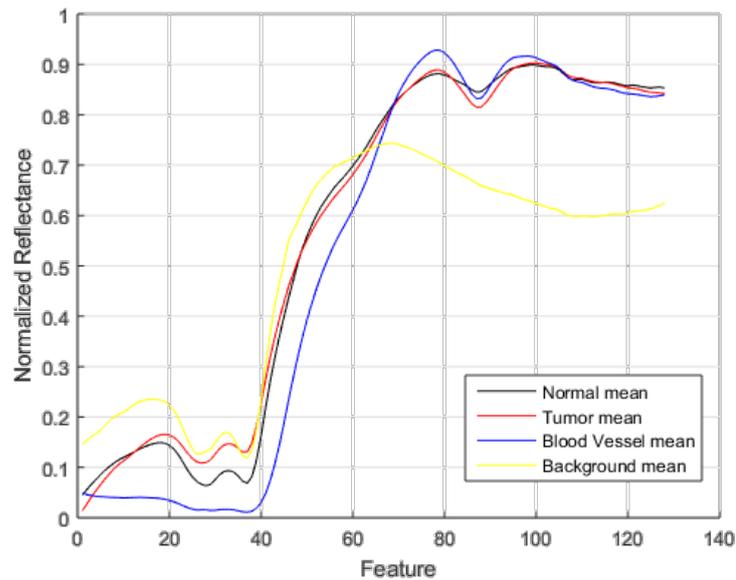


Figura 3.5. Firmas espectrales promedio de cada clase de la base de datos completa: Tumor cerebral (rojo), Tejido cerebral sano (negro), vasos sanguíneos (azul) y *Background* (amarillo).

3.2. Resumen

En este capítulo se ha presentado el procedimiento realizado para las capturas de las imágenes hiperespectrales de los tejidos cerebrales. Se observa que, para la obtención de dichas imágenes, el cirujano habilitado debe seguir un procedimiento estricto para poder sacar las imágenes que forman parte de la base de datos de este TFG. Para ello, es necesario realizar una craneotomía y extraer algunos tejidos (Cubiertas Fibrosas) con el fin de llegar al tejido cerebral para posteriormente, indicar con los marcadores, cuál es el tejido sano y cuál el tumor y realizar las capturas de las imágenes. Por último, se procede a realizar el etiquetado de las muestras.

4. CASOS DE ESTUDIO

Este TFG, tiene como objetivo analizar los efectos de la inclusión de nuevos pacientes en la clasificación. Por lo que se han propuesto cuatro casos de estudio (CS) diferentes donde el enfoque difiere principalmente en la forma de añadir a los pacientes como sujeto de estudio. El objetivo principal, es comparar los diferentes casos de estudio con el fin de estudiar la variabilidad inter-paciente.

En primer lugar, se detalla la metodología seguida durante el desarrollo de este TFG y se describen los escenarios propuestos. Asimismo, se presentan los resultados obtenidos en dicho análisis mediante unas tablas comparativas donde se valorará la eficiencia y efectividad de los distintos escenarios. Finalmente, y a modo de conclusión, se muestra el tiempo de cómputo requerido para cada uno de los casos de estudio.

Para el desarrollo de este trabajo se empleó la herramienta *software* MATLAB debido a su potencia para analizar datos, desarrollar algoritmos y generar modelos predictivos.

Una vez se dispone de la base de datos, se procede a escoger un clasificador. El clasificador supervisado seleccionado para realizar la comparativa de este TFG fue el SVM (*Support Vector Machines*). Para ello, se ha utilizado la librería pública LIBSVM [56]. El objetivo principal de este tipo de clasificador es el de encontrar un hiperplano que divida los datos en función de sus características [41].

4.1. Metodología

La metodología a seguir es la siguiente: se aplica cada uno de los casos de estudio, que hacen referencia a la forma de introducir los datos de los pacientes en el clasificador, con el fin de poder entrenarlo, generar un modelo y finalmente, testarlo, tal y como se muestra en la Figura 4.1. Para ello, se han utilizado las siguientes métricas de evaluación: el *accuracy* que se trata de la tasa de acierto o de precisión, la matriz de confusión, la especificidad y finalmente la sensibilidad. Estas métricas emplean la técnica de *cross-validation* que se explica en el siguiente apartado.



Figura 4.1. Diagrama de bloques correspondiente al procedimiento planteado para el TFG.

Además de estas métricas de evaluación, se compararán los tiempos de cómputo para cada uno de los casos en dos equipos con distintas prestaciones.

4.1.1. Clasificación supervisada

Para el desarrollo de este TFG, se ha utilizado SVM lineal, aunque el estudio propuesto podría haberse implementado con otros clasificadores. El procedimiento seguido es utilizar las firmas espectrales (Capítulo 3) para entrenar el clasificador. Asimismo, para separar los datos de entrenamiento, test y proporcionar validez a las métricas de evaluación se emplea la técnica de *cross-validation*.

La técnica del *cross-validation* o validación cruzada, permite estimar la precisión del modelo generado. Para ello, se realiza una partición de los datos donde, por un lado, habrá un conjunto de entrenamiento y por otro, un grupo de datos de test o prueba [57]. Para el desarrollo de este proyecto, se han empleado dos métodos de *cross-validation*: el método *k-fold cross-validation* y el *leave-one-out*.

La validación cruzada *k-fold* es una mejora del método *hold-out*. En el modelo *hold-out* se dividen los datos en dos subconjuntos, una parte de entrenamiento y otra de validación (ver Figura 4.2). Mientras que en el método *k-fold* los datos son divididos en k subconjuntos. De tal forma que, este proceso se repite un conjunto de k iteraciones, tal y como se muestra en el ejemplo de Figura 4.3, donde $k = 4$. Ambos métodos utilizan el mismo principio funcionamiento, testear con datos que no han sido empleados durante el entrenamiento.



Figura 4.2. Mecánica de funcionamiento del método hold-out.

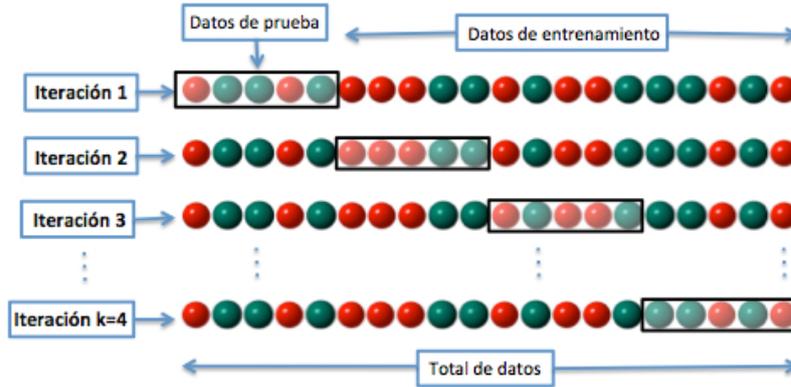


Figura 4.3. Mecánica de funcionamiento del método *k-fold*.

El método *leave-one-out* es una validación cruzada en n , donde n es el número de instancias en el conjunto de datos. Cada instancia de n se deja fuera y el clasificador es entrenado con todas restantes, véase Figura 4.4 [58].

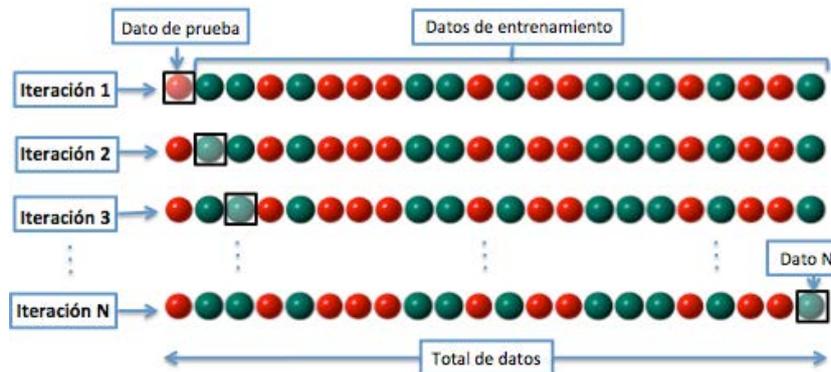


Figura 4.4. Mecánica de funcionamiento del método *leave-one-out*.

Los n resultados se promedian siendo ese promedio la representación de la estimación del error final. Asimismo, los subconjuntos generados de manera aleatoria para cada uno de los métodos se realizan de forma que contengan aproximadamente la misma proporción de etiquetas que el conjunto de datos original [59]. Finalmente, para el caso de la validación cruzada (*k-fold*) se lleva a cabo la media aritmética de cada iteración obteniéndose así un único resultado.

4.1.2. Métricas de evaluación

En este apartado se describen las métricas de evaluación empleadas para valorar la precisión de la clasificación en cada uno de los casos estudiados. Con el fin de dar validez a los resultados obtenidos, es recomendable contrastar con al menos más de una métrica, ya que usar una única no es suficiente para describir la bondad de los resultados de un clasificador, y podría llevar a conclusiones

erróneas. Es por ello, por lo que en este TFG se utilizará el *accuracy*, la matriz de confusión, la especificidad y la sensibilidad.

4.1.2.1. Accuracy

A continuación, se pretende definir el concepto de *accuracy* pues es una métrica que se utilizará de forma extendida a lo largo del proyecto. Este término hace referencia a la tasa de acierto y determina la precisión con la que el clasificador es capaz de predecir correctamente las clases de los píxeles de las muestras. Se calcula como la tasa de acierto de las predicciones del clasificador y viene definido por ecuación (4.1).

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (4.1)$$

4.1.2.2. Matriz de confusión

Por otra parte, otra métrica a tener en consideración es la matriz de confusión que se emplea para evaluar el comportamiento de los modelos generados por el clasificador. Se trata de una métrica que complementa al *accuracy* ya que una tasa de acierto elevada no implica que el clasificador haya etiquetado todos los píxeles de manera correcta. Por ello, la matriz de confusión permite visualizar los errores cometidos en la clasificación en forma de matriz, donde las filas se corresponden con el valor real de cada clase y las columnas con el valor predicho.

En este TFG la dimensión de la matriz de confusión trabajada es de 4x4, ya que para la clasificación se han definido un total de 4 clases o etiquetas (Normal, Tumor, vasos sanguíneos y *background*), descrito anteriormente en el capítulo 3. Dichas matrices muestran las formas en las que el modelo se “confunde” cuando efectúa las predicciones, pues en ocasiones un píxel puede ser etiquetado de forma errónea.

En la Tabla 4.1 se observa un ejemplo de matriz de confusión y siendo fiel al modo de trabajo llevado a cabo, se muestra una matriz 4x4, con las siguientes clases: A, B, C y D. Tal y como se ha comentado con anterioridad, las filas corresponden con el valor real de la etiqueta mientras que las columnas con el predicho.

Tabla 4.1. Ejemplo de una matriz de confusión 4x4 para las clases A-D.

| | | INFERRED CLASS | | | |
|------------|---|----------------|---|---|---|
| | | A | B | C | D |
| TRUE CLASS | A | a | b | c | d |
| | B | e | f | g | h |
| | C | i | j | k | l |
| | D | m | n | o | p |

Ahora bien, para comprender el funcionamiento de este tipo de matrices de confusión multiclase, en la Tabla 4.2 se muestra la matriz de confusión binaria para, por ejemplo, la clase A. En ella se pueden observar los distintos indicadores de rendimiento obtenidos a partir de la matriz anterior (ver Tabla 4.1). Esto se lleva a cabo mediante: los verdaderos positivos (TP) que se corresponde al valor real, en otras palabras, corresponde al número de píxeles reales que pertenecen a esa clase y, por consiguiente, son etiquetados correctamente. Los falsos negativos (FN) son aquellos píxeles que pertenecen a esa clase y, sin embargo, fueron etiquetados como de otra. Los falsos positivos (FP) se trata de los píxeles que fueron etiquetados como pertenecientes a esa clase, pero que en realidad pertenecían a otra y finalmente, los verdaderos negativos (TN) píxeles de otras clases que fueron identificados correctamente [60] [61].

Tabla 4.2. Matriz de confusión binaria, clase A.

| | | INFERRED CLASS | |
|------------|-------|----------------|------------------------|
| | | A | Not-A |
| TRUE CLASS | A | a (TP) | b+c+d (FN) |
| | Not-A | e+i+m (FP) | f+g+h+j+k+l+n+o+p (TN) |

4.1.2.3. Especificidad

La especificidad (*specificity*) es la proporción de los negativos reales que el clasificador identifica como tales y se halla mediante la expresión (4.2).

$$Specificity = \frac{TN}{TN + FP} \quad (4.2)$$

Donde TN es el número de los verdaderos negativos y FP corresponde con el número de los falsos positivos.

4.1.2.4. Sensibilidad

La sensibilidad (*sensitivity*) corresponde a la proporción de los positivos reales que el clasificador identifica correctamente como positivos y se puede calcular mediante la ecuación (4.3).

$$Sensitivity = \frac{TP}{TP + FN} \quad (4.3)$$

Donde TP es el número de verdaderos positivos y FN el número de falso negativos [62].

4.1.3. Escenarios propuestos

En este apartado, se explican cada uno de los escenarios propuestos, CS1, CS2 y CS3, que vienen definidos por la forma en la que se usan los conjuntos de datos de cada paciente en el proceso de clasificación supervisada. El objetivo, es realizar una selección de datos, añadirlos al clasificador SVM, entrenar y generar un modelo que posteriormente será testado.

4.1.3.1. Caso 1

En el caso de estudio 1, también denominado como CS1, los pacientes son clasificados de manera independiente. El objetivo de este CS es verificar si la discriminación entre el tejido sano y el tumor se puede realizar usando únicamente la información espectral de los píxeles sanos y tumorales de los datos etiquetados disponibles. Para ello, se emplean los datos etiquetados de cada procedimiento quirúrgico y se clasifican por separado con el fin de evitar la variabilidad de los datos entre pacientes.

El proceso de este caso se muestra en la Figura 4.5, y consiste en acceder al *dataset* de un paciente para posteriormente, con el *Cross-Validation*, realizar una partición 10-veces (*10-fold*) de los datos. En otras palabras, se realiza una validación cruzada de k iteraciones.

En primer lugar, se hace una partición aleatoria de los datos (*10-fold*), del paciente actual, en este caso el Paciente 004. En cada iteración, se emplea una partición de las 10 existentes (cuadrado celeste) para testear el modelo y el resto (cuadrados azules) para entrenar al clasificador. Seguidamente, se genera el modelo y con el trozo restante, se testea. Este procedimiento, se lleva a cabo 10

veces en total, número de particiones existentes. Una vez finalizado este proceso, se aplica la misma metodología con todos los pacientes restantes que se encuentran en la base de datos y se calculan las métricas correspondientes.

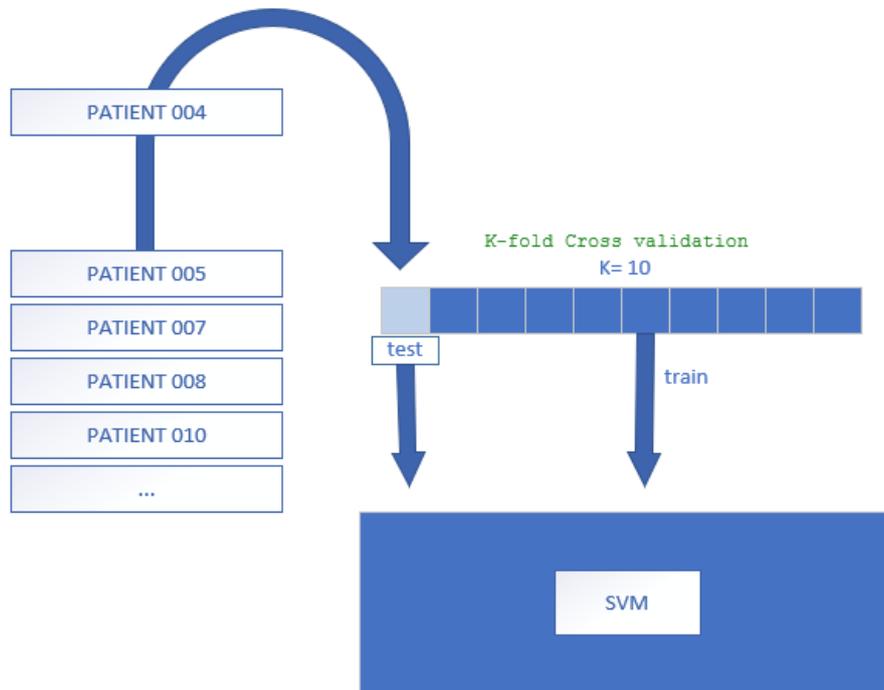


Figura 4.5. Diagrama de bloques correspondiente al caso de estudio 1.

4.1.3.2. Caso 2

El caso de estudio 2 (CS2) posee el mismo procedimiento que el anterior. No obstante, en este estudio los datos etiquetados disponibles de todos los pacientes son fusionados y unificados en un solo conjunto de datos. Es decir, se crea una base de datos única al unir todos los datos de pacientes individuales, por lo que se toma en cuenta la variabilidad entre pacientes (ver Figura 4.6). Posteriormente, se lleva a cabo el mismo proceso que en el CS1 donde primero se realiza una partición de los datos k-veces, se obtiene el modelo generado por el clasificador y finalmente, se testea dicho modelo.

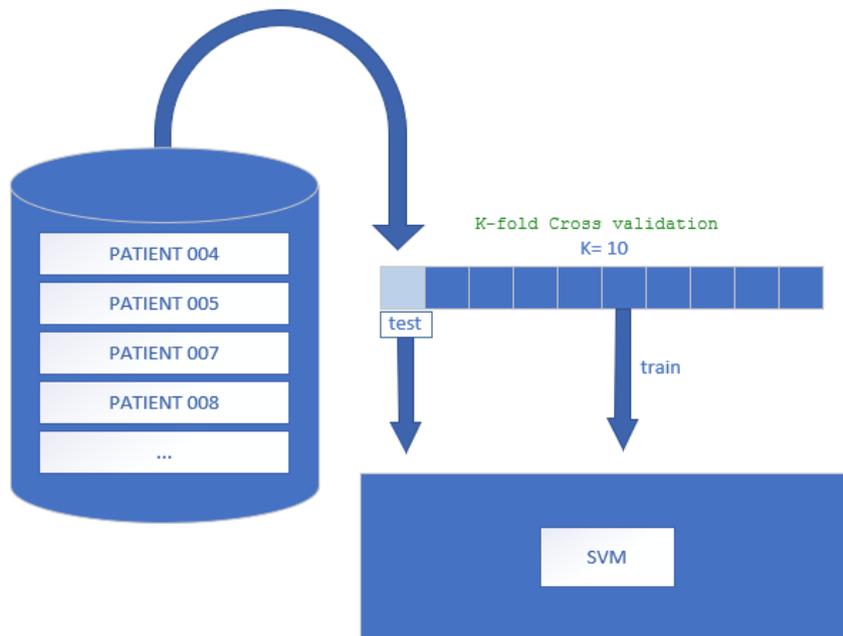


Figura 4.6. Diagrama de bloques correspondiente al caso de estudio 2.

4.1.3.3. Caso 3

Para este caso de estudio, denominado CS3, también se emplea un conjunto de pacientes unificados, pero a diferencia del anterior, no se añade al paciente actual.

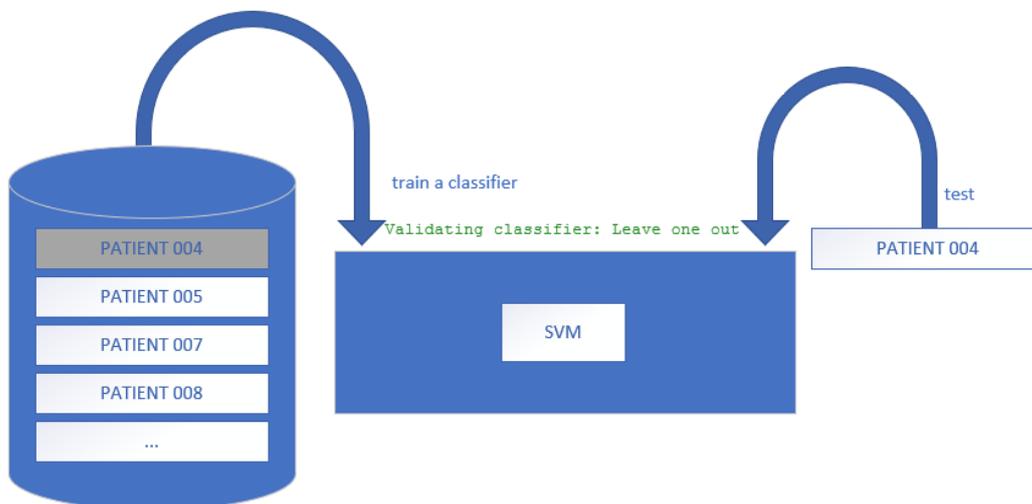


Figura 4.7. Diagrama de bloques correspondiente al caso de estudio 3.

En este escenario, los datos del paciente actual son clasificados de forma totalmente independiente, utilizando el bloque unificado de pacientes, excepto el actual, para entrenar el clasificador con el fin de hacer el estudio más realista en cuanto al diagnóstico se refiere. Por ello, se entrena empleando la información de otros pacientes cuyos datos ya han sido etiquetados y se testea con un paciente

cuyo modelo inicialmente se desconoce. Este escenario representa el caso real de una nueva operación quirúrgica, donde la clasificación debe realizarse con un clasificador ya entrenado con datos hiperespectrales de operaciones anteriores. En esta ocasión, en vez de emplear la técnica del *cross-validation k-fold* para validar los resultados, se aplica el *leave-one-out cross-validation* tal y como se puede apreciar en la Figura 4.7, ya que los datos de entrenamiento y test ya están separados por definición en este caso de estudio.

4.2. Resultados

Por último, una vez presentada la metodología, en este apartado se muestran los resultados obtenidos al realizar la clasificación supervisada para cada uno de los casos de estudio. Para ello, se lleva a cabo una comparativa de los valores conseguidos usando las métricas de evaluación propuestas: el *accuracy*, la matriz de confusión, la especificidad y la sensibilidad. Otra comparativa a tener en consideración son los tiempos de ejecución, por lo que se ha decidido obtener los datos en dos equipos con distintas prestaciones.

4.2.1. CS1

A continuación, se muestran los resultados obtenidos para este caso. Primero, el resultado del *accuracy* y posteriormente, los valores obtenidos con la matriz de confusión de sensibilidad y especificidad para cada uno de los pacientes.

En este caso de estudio, los conjuntos de datos de los pacientes han sido procesados en el clasificador (SVM) de forma independiente. En la Tabla 4.3, se muestra la tasa de acierto obtenida para cada uno de ellos, junto con los valores de sensibilidad y especificidad. En ella, se aprecia que la tasa de acierto es más elevada para la mayor parte de los pacientes, siendo el paciente 13 el caso menos favorable, con una tasa de acierto del 86,9%.

Tabla 4.3. Valores de la tasa de acierto, de especificidad y de sensibilidad para el CS1.

| ID | O. A. | Specificity (%) | | | | Sensitivity (%) | | | |
|--------------|---------------|-----------------|---------|---------|---------|-----------------|---------|---------|---------|
| | (%) | N | T | BV | B | N | T | BV | B |
| 4 | 97,59% | 93,57% | 100,00% | 100,00% | 100,00% | 100,00% | 0,00% | 100,00% | 91,77% |
| 5 | 99,89% | 100,00% | 100,00% | 99,92% | 99,88% | 99,85% | 0,00% | 100,00% | 100,00% |
| 8 | 91,98% | 91,98% | 96,57% | 99,72% | 93,82% | 99,22% | 99,96% | 32,23% | 98,20% |
| 12 | 99,18% | 99,18% | 99,57% | 99,94% | 99,60% | 99,72% | 99,79% | 94,37% | 99,86% |
| 13 | 86,92% | 86,92% | 54,36% | 100,00% | 100,00% | 100,00% | 100,00% | 0,00% | 0,00% |
| 15 | 99,58% | 99,58% | 99,94% | 99,60% | 99,85% | 100,00% | 99,36% | 100,00% | 99,90% |
| 16 | 99,29% | 99,29% | 99,94% | 100,00% | 100,00% | 97,94% | 98,42% | 0,00% | 100,00% |
| 17 | 94,68% | 94,68% | 99,06% | 100,00% | 100,00% | 85,90% | 100,00% | 0,00% | 0,00% |
| 20 | 97,19% | 97,19% | 96,61% | 99,96% | 99,94% | 100,00% | 99,62% | 100,00% | 82,55% |
| 21 | 97,49% | 98,40% | 100,00% | 98,99% | 98,71% | 99,54% | 0,00% | 96,05% | 100,00% |
| 22 | 99,42% | 98,26% | 100,00% | 100,00% | 100,00% | 100,00% | 0,00% | 100,00% | 100,00% |
| 25 | 93,90% | 98,01% | 97,20% | 100,00% | 94,89% | 100,00% | 93,21% | 80,15% | 95,90% |
| 28 | 99,74% | 99,84% | 100,00% | 100,00% | 99,31% | 100,00% | 100,00% | 0,00% | 100,00% |
| 29 | 99,97% | 100,00% | 100,00% | 100,00% | 99,90% | 99,67% | 100,00% | 100,00% | 100,00% |
| Media | 96,92% | 96,92% | 95,95% | 99,87% | 98,99% | 98,70% | 70,74% | 64,49% | 83,44% |

En la Tabla 4.3, se puede observar que para la especificidad todos los valores son superiores al 90%. A excepción de las clases correspondientes a tumor y tejido sano del paciente 13 con un 54,36% y un 86,92% respectivamente.

En cuanto a los valores de sensibilidad, siendo la clase tumor objeto importante de estudio para este TFG, el resultado obtenido en los pacientes 4, 5, 21 y 22 es del 0%. Por otro lado, para los pacientes 13, 17, 28 y 29 se consiguió el porcentaje más elevado con un valor de probabilidad del 100%. Para el resto de los casos los valores obtenidos con esta métrica son todos superiores al 93%. Finalmente, la media aritmética de sensibilidad para la clase tumor es del 70,74%, siendo el valor más bajo para la clase correspondiente a vasos sanguíneos con un 64,49%.

4.2.2. CS2

En este caso, solo se obtiene un valor en la métrica de evaluación, ya que como se comentó anteriormente, los pacientes se unificaron en único conjunto de

datos. La tasa de acierto obtenida para el CS2 ha sido de un 95,30%, tal y como se muestra en la Tabla 4.4. Obteniéndose para la clase tumor un valor de especificidad del 98,56% y de sensibilidad del 85,67%. Los valores conseguidos con estas métricas son todos superiores al 85%.

Tabla 4.4. Valores de la tasa de acierto, de especificidad y de sensibilidad para el CS2.

| ID | O. A. | Specificity (%) | | | | Sensitivity (%) | | | |
|----------|--------|-----------------|--------|--------|--------|-----------------|--------|--------|--------|
| | (%) | N | T | BV | B | N | T | BV | B |
| Patients | 95,30% | 98,81% | 98,56% | 98,79% | 96,69% | 93,80% | 85,67% | 94,41% | 97,59% |

4.2.3. CS3

En esta sección se presenta la Tabla 4.5 con la tasa de aciertos y los valores de especificidad y sensibilidad obtenidos para el tercer caso de estudio. Cabe destacar que la ID hace referencia al paciente actual, que es únicamente con el que se testea el modelo generado, tras entrenar el clasificador con el bloque de datos unificado del resto de los pacientes.

En la Tabla 4.5, el paciente con menor tasa de acierto es el 22 (tumor primario) cuyo *accuracy* es inferior al 50%, más concretamente del 34,66%. Mientras, que el paciente 28 (tumor secundario), posee la tasa de acierto más elevada con un valor del 97,20%.

En cuanto a los valores de especificidad para la clase tumor, en la mayoría de los casos los valores son superiores al 90%. Sin embargo, para los pacientes 22 y 25, la probabilidad cae al 77,44% y 75,47% respectivamente. Por otro lado, los pacientes 17, 20 y 28 alcanzaron una probabilidad del 100%.

Para el resto de las clases tejido normal sano, *blood vessel* y *background* los valores de especificidad son superiores al 70% a excepción de la clase correspondiente a los vasos sanguíneos del paciente 29 con un 62,11% y de la clase *background* del paciente 20 con un 57,17% y del paciente 22 con un 19,33%.

Con respecto a la sensibilidad, las medias aritméticas conseguidas para cada clase son valores bajos en comparación con los obtenidos para especificidad, salvo para la clase *background* que con esta métrica de evaluación alcanzó un valor del 86,46% frente al 83,94% adquirido en especificidad.

Para la clase tejido sano, el valor más reducido fue para el paciente 22 con un 3,84%. Si se analiza la clase tumor, el porcentaje de sensibilidad para este caso

de estudio, es de un 17,52%. Solo los pacientes 25 y 28 superaron el 50% con una un 91,19% y un 88,23%. Asimismo, el resto de los valores se encuentran por debajo del 20%, dando una probabilidad del 0% en los pacientes 4, 5, 13, 21 y 22, siendo el *accuracy* más bajo para este último paciente con un 34,66% comentado anteriormente.

Tabla 4.5. Valores de la tasa de acierto, de especificidad y de sensibilidad para el CS3.

| ID | O. A. | Specificity (%) | | | | Sensitivity (%) | | | |
|--------------|---------------|-----------------|---------------|---------------|---------------|-----------------|---------------|---------------|---------------|
| | (%) | N | T | BV | B | N | T | BV | B |
| 4 | 95,85% | 97,19% | 99,78% | 99,75% | 96,39% | 95,71% | 0,00% | 98,34% | 96,34% |
| 5 | 84,64% | 95,84% | 89,11% | 99,91% | 92,35% | 90,17% | 0,00% | 100,00% | 81,79% |
| 8 | 84,07% | 95,87% | 96,21% | 91,64% | 91,42% | 87,62% | 15,67% | 77,01% | 95,65% |
| 12 | 82,41% | 85,78% | 99,65% | 87,24% | 98,72% | 97,21% | 1,68% | 88,58% | 88,90% |
| 13 | 90,08% | 71,96% | 99,96% | 98,38% | 99,27% | 97,76% | 0,00% | 95,35% | 67,57% |
| 15 | 72,70% | 69,26% | 100,00% | 99,85% | 97,74% | 94,48% | 6,35% | 94,96% | 97,84% |
| 16 | 67,57% | 80,61% | 91,35% | 83,80% | 94,58% | 52,57% | 5,21% | 93,24% | 71,38% |
| 17 | 91,77% | 100,00% | 100,00% | 95,23% | 87,40% | 82,76% | 14,53% | 100,00% | 100,00% |
| 20 | 58,33% | 69,32% | 100,00% | 98,71% | 57,17% | 95,06% | 3,53% | 73,69% | 100,00% |
| 21 | 90,08% | 98,47% | 94,59% | 99,16% | 93,46% | 98,83% | 0,00% | 70,79% | 93,25% |
| 22 | 34,66% | 99,72% | 77,44% | 98,61% | 19,33% | 3,84% | 0,00% | 100,00% | 96,60% |
| 25 | 70,84% | 99,92% | 75,97% | 100,00% | 73,79% | 94,78% | 91,19% | 26,35% | 68,38% |
| 28 | 97,20% | 99,68% | 100,00% | 97,98% | 96,51% | 80,13% | 88,23% | 100,00% | 100,00% |
| 29 | 59,76% | 92,01% | 98,29% | 62,11% | 76,97% | 84,32% | 18,94% | 97,61% | 52,68% |
| Media | 77,14% | 89,69% | 94,45% | 93,74% | 83,94% | 82,52% | 17,52% | 86,85% | 86,46% |

4.2.4. Comparativa

En este apartado se realizará una comparativa de los resultados obtenidos para cada uno de los casos de estudio. En CS1 los conjuntos de datos de los pacientes han sido añadidos al clasificador (SVM) de manera totalmente independiente, la tasa de acierto media para este caso de estudio es del 96,92%.

De forma análoga, para los resultados del segundo caso de estudio, CS2, donde se crea una base de datos única al unir todos los datos de los pacientes individuales, se obtiene un único valor de *accuracy* donde la tasa de acierto obtenida ha sido de un 95,30%. Si se compara con el obtenido para el CS1 se

observa que es ligeramente inferior debido a que para el caso de estudio 2 existe una variabilidad inter-paciente.

En el caso de estudio 3 se parte de un conjunto de datos unificados sin el paciente actual. El CS3 es el caso que más se ajusta a la realidad de estudio, debido a que se entrena con un conjunto de datos, se genera el modelo y finalmente, se testea con unos datos de paciente que el modelo desconoce. La tasa de acierto es más baja que para el resto de los casos de estudio (ver Figura 4.8), siendo de un 77.14%, tal y como era de esperar.

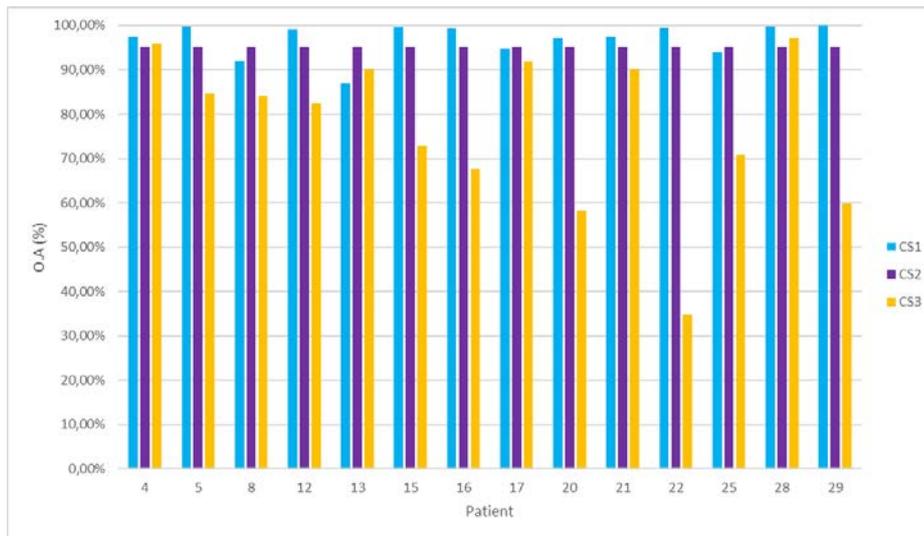


Figura 4.8. Gráfica comparativa del overall accuracy en CS1, CS2 y CS3.

A continuación, en la Tabla 4.6 se presentan los resultados de la tasa de acierto, de especificidad y de sensibilidad para cada paciente correspondiente a cada caso de estudio.

Tabla 4.6. Resultados obtenidos en CS1, CS2 y CS3.

| ID | CS | O. A. (%) | Specificity (%) | | | | Sensitivity (%) | | | |
|----|-----|---------------|-----------------|---------|---------|---------|-----------------|---------|---------|---------|
| | | | N | T | BV | B | N | T | BV | B |
| 4 | CS1 | 97,59% | 93,57% | 100,00% | 100,00% | 100,00% | 100,00% | 0,00% | 100,00% | 91,77% |
| | CS2 | 95,30% | 98,81% | 98,56% | 98,79% | 96,69% | 93,80% | 85,67% | 94,41% | 97,59% |
| | CS3 | 95,85% | 97,19% | 99,78% | 99,75% | 96,39% | 95,71% | 0,00% | 98,34% | 96,34% |
| 5 | CS1 | 99,89% | 100,00% | 100,00% | 99,92% | 99,88% | 99,85% | 0,00% | 100,00% | 100,00% |
| | CS2 | 95,30% | 98,81% | 98,56% | 98,79% | 96,69% | 93,80% | 85,67% | 94,41% | 97,59% |
| | CS3 | 84,64% | 95,84% | 89,11% | 99,91% | 92,35% | 90,17% | 0,00% | 100,00% | 81,79% |
| 8 | CS1 | 91,98% | 96,57% | 99,72% | 93,82% | 99,22% | 99,96% | 32,23% | 98,20% | 95,81% |
| | CS2 | 95,30% | 98,81% | 98,56% | 98,79% | 96,69% | 93,80% | 85,67% | 94,41% | 97,59% |
| | CS3 | 84,07% | 95,87% | 96,21% | 91,64% | 91,42% | 87,62% | 15,67% | 77,01% | 95,65% |
| 12 | CS1 | 99,18% | 99,57% | 99,94% | 99,60% | 99,72% | 99,79% | 94,37% | 99,86% | 99,42% |
| | CS2 | 95,30% | 98,81% | 98,56% | 98,79% | 96,69% | 93,80% | 85,67% | 94,41% | 97,59% |
| | CS3 | 82,41% | 85,78% | 99,65% | 87,24% | 98,72% | 97,21% | 1,68% | 88,58% | 88,90% |
| 13 | CS1 | 86,92% | 54,36% | 100,00% | 100,00% | 100,00% | 100,00% | 0,00% | 0,00% | 67,74% |
| | CS2 | 95,30% | 98,81% | 98,56% | 98,79% | 96,69% | 93,80% | 85,67% | 94,41% | 97,59% |
| | CS3 | 90,08% | 71,96% | 99,96% | 98,38% | 99,27% | 97,76% | 0,00% | 95,35% | 67,57% |
| 15 | CS1 | 99,58% | 99,94% | 99,60% | 99,85% | 100,00% | 99,36% | 100,00% | 99,90% | 96,84% |
| | CS2 | 95,30% | 98,81% | 98,56% | 98,79% | 96,69% | 93,80% | 85,67% | 94,41% | 97,59% |
| | CS3 | 72,70% | 69,26% | 100,00% | 99,85% | 97,74% | 94,48% | 6,35% | 94,96% | 97,84% |
| 16 | CS1 | 99,29% | 99,94% | 100,00% | 100,00% | 97,94% | 98,42% | 0,00% | 100,00% | 99,99% |
| | CS2 | 95,30% | 98,81% | 98,56% | 98,79% | 96,69% | 93,80% | 85,67% | 94,41% | 97,59% |
| | CS3 | 67,57% | 80,61% | 91,35% | 83,80% | 94,58% | 52,57% | 5,21% | 93,24% | 71,38% |
| 17 | CS1 | 94,68% | 99,06% | 100,00% | 100,00% | 85,90% | 100,00% | 0,00% | 0,00% | 100,00% |
| | CS2 | 95,30% | 98,81% | 98,56% | 98,79% | 96,69% | 93,80% | 85,67% | 94,41% | 97,59% |
| | CS3 | 91,77% | 100,00% | 100,00% | 95,23% | 87,40% | 82,76% | 14,53% | 100,00% | 100,00% |
| 20 | CS1 | 97,19% | 96,61% | 99,96% | 99,94% | 100,00% | 99,62% | 100,00% | 82,55% | 100,00% |
| | CS2 | 95,30% | 98,81% | 98,56% | 98,79% | 96,69% | 93,80% | 85,67% | 94,41% | 97,59% |
| | CS3 | 58,33% | 69,32% | 100,00% | 98,71% | 57,17% | 95,06% | 3,53% | 73,69% | 100,00% |
| 21 | CS1 | 97,49% | 98,40% | 100,00% | 98,99% | 98,71% | 99,54% | 0,00% | 96,05% | 100,00% |
| | CS2 | 95,30% | 98,81% | 98,56% | 98,79% | 96,69% | 93,80% | 85,67% | 94,41% | 97,59% |
| | CS3 | 90,08% | 98,47% | 94,59% | 99,16% | 93,46% | 98,83% | 0,00% | 70,79% | 93,25% |
| 22 | CS1 | 99,42% | 98,26% | 100,00% | 100,00% | 100,00% | 100,00% | 0,00% | 100,00% | 100,00% |
| | CS2 | 95,30% | 98,81% | 98,56% | 98,79% | 96,69% | 93,80% | 85,67% | 94,41% | 97,59% |
| | CS3 | 34,66% | 99,72% | 77,44% | 98,61% | 19,33% | 3,84% | 0,00% | 100,00% | 96,60% |
| 25 | CS1 | 93,90% | 98,01% | 97,20% | 100,00% | 94,89% | 100,00% | 93,21% | 80,15% | 95,90% |
| | CS2 | 95,30% | 98,81% | 98,56% | 98,79% | 96,69% | 93,80% | 85,67% | 94,41% | 97,59% |
| | CS3 | 70,84% | 99,92% | 75,97% | 100,00% | 73,79% | 94,78% | 91,19% | 26,35% | 68,38% |
| 28 | CS1 | 99,74% | 99,84% | 100,00% | 100,00% | 99,31% | 100,00% | 100,00% | 0,00% | 100,00% |
| | CS2 | 95,30% | 98,81% | 98,56% | 98,79% | 96,69% | 93,80% | 85,67% | 94,41% | 97,59% |
| | CS3 | 97,20% | 99,68% | 100,00% | 97,98% | 96,51% | 80,13% | 88,23% | 100,00% | 100,00% |
| 29 | CS1 | 99,97% | 100,00% | 100,00% | 100,00% | 99,90% | 99,67% | 100,00% | 100,00% | 100,00% |
| | CS2 | 95,30% | 98,81% | 98,56% | 98,79% | 96,69% | 93,80% | 85,67% | 94,41% | 97,59% |
| | CS3 | 59,76% | 92,01% | 98,29% | 62,11% | 76,97% | 84,32% | 18,94% | 97,61% | 52,68% |

Se pueden observar los valores correspondientes a la tasa de acierto, en el que el paciente 13 es el único que mejora los datos del CS1 al CS3, pasando de un 86,92% al 90,08%. Para el resto de los pacientes los mejores resultados se obtienen en el caso 1. Esto se puede deber a que para el CS1 no existe una variabilidad inter-paciente en los datos. De manera general, los valores de la tasa de acierto para los diferentes casos de estudio son superiores al 67%, a excepción del paciente 20 con un 58,33% y del paciente 22 con un 34,66% en el CS3, ambos pacientes han sido diagnosticados con tumores primarios.

En cuanto a los valores de especificidad obtenidos se aprecia una mejora considerable al pasar del CS1 al CS3 en los pacientes 13 y 21, diagnosticados como tumor secundario y en los pacientes 17, 22 y 25 como primario, para la clase tejido sano, esto se observa en la Figura 4.9.

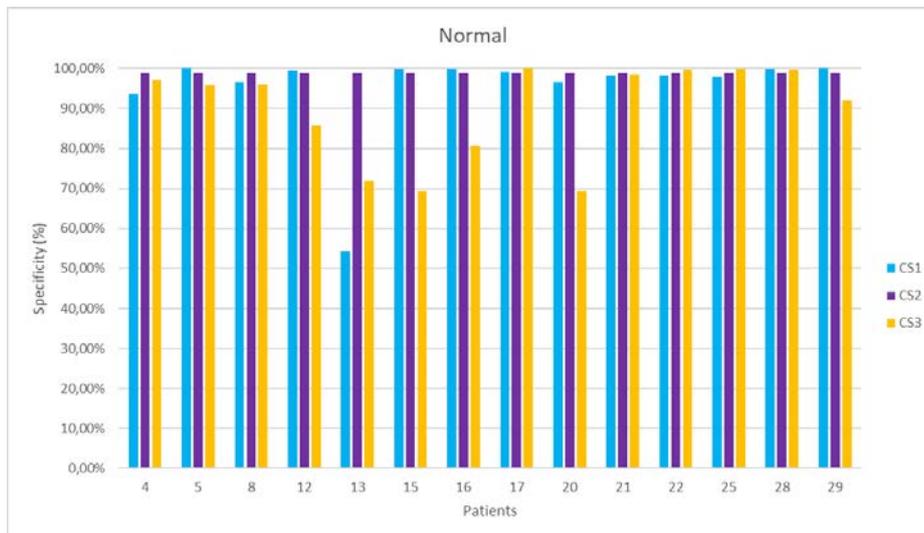


Figura 4.9. Gráfica comparativa de especificidad para la clase tejido normal en CS1, CS2 y CS3.

Respecto a la clase tumor, ver Figura 4.10, la mejora se produce en el paciente 15 (tumor primario), aunque la diferencia es prácticamente despreciable, pasando del 99,60% en CS1 al 100% en CS3. Para la clase tumor, pacientes 17 y 28 y para la clase vasos sanguíneos (Figura 4.11), pacientes 15 y 25, se mantienen los valores al pasar del CS1 al CS3.

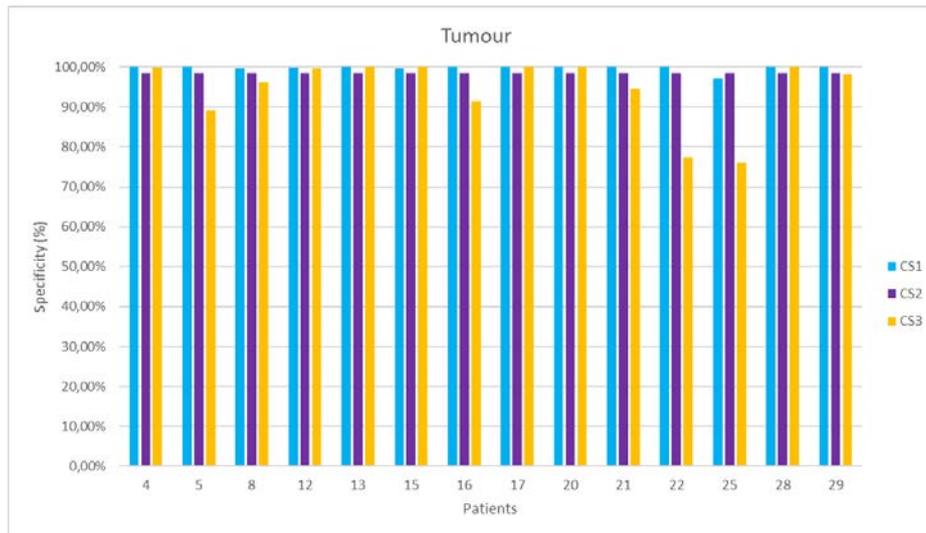


Figura 4.10. Gráfica comparativa de especificidad para la clase tumor en CS1, CS2 y CS3.

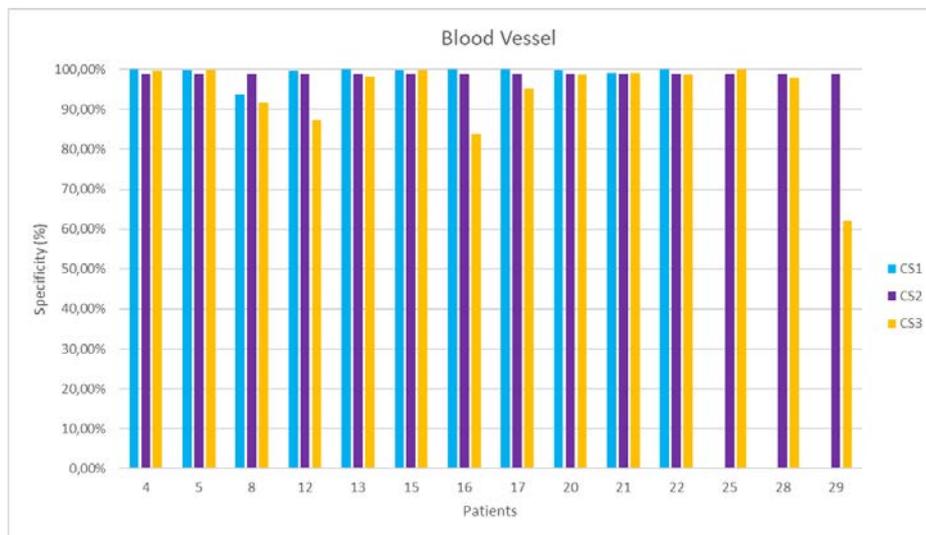


Figura 4.11. Gráfica comparativa de especificidad para la clase blood vessel (vasos sanguíneos) en CS1, CS2 y CS3.

Finalmente, para la clase *background*, tal y como se muestra en la Figura 4.12, se produce una disminución en el porcentaje del paciente 22 (tumor primario), obteniéndose un valor del 100% en CS1 y del 19,33% en CS3.

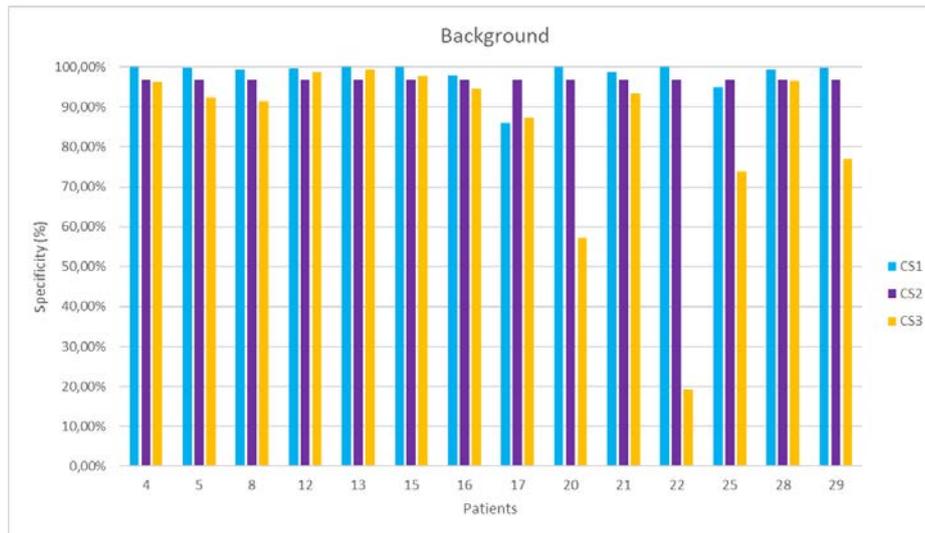


Figura 4.12. Gráfica comparativa de especificidad para la clase background en CS1, CS2 y CS3.

Por otro lado, en la métrica de sensibilidad, los valores son superiores al 80% para la clase tejido sano, salvo para los pacientes 16 y 22 cuyo porcentaje son del 52,57% y del 3,84% respectivamente. Tal y como se observa en la gráfica de la Figura 4.13, el porcentaje en CS3 cae de manera considerable en dichos pacientes con respecto a los obtenidos en CS1.

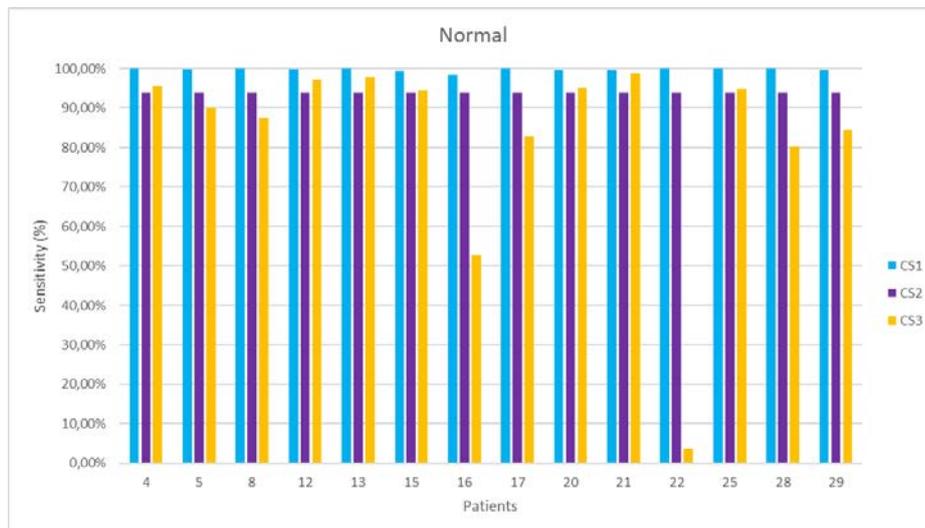


Figura 4.13. Gráfica comparativa de sensibilidad para la clase tejido normal en CS1, CS2 y CS3.

Los valores de la clase tumor para cada uno de los casos de estudio varían de forma considerable. Se mantienen los resultados del 0% en CS1 y CS3 para los pacientes 4, 5, 13, 21 y 22, todos diagnosticados con tumores secundarios, salvo el 22, que es un tumor primario. Para los pacientes 12, 15, 20 y 29 (tumores primarios) los porcentajes alcanzados en CS1 disminuyen en CS3. El cambio más drástico se produce en los pacientes 15 y 20, pasando del 100% al 6,35% y al 3,53%. Las mejoras para CS3, son en los pacientes 16 y 17 (tumores primarios),

cuyo porcentaje cambia del 0% al 5,21 y al 14,53%. Lo comentado sobre estas líneas se muestra gráficamente en la Figura 4.14.

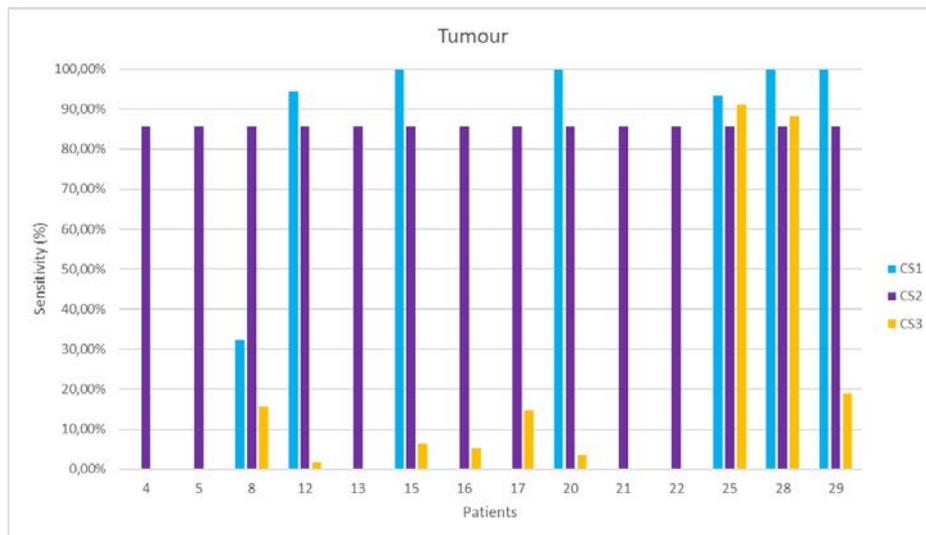


Figura 4.14. Gráfica comparativa de sensibilidad para la clase tumor en CS1, CS2 y CS3.

En la clase de los vasos sanguíneos, estas mejoras se logran en los pacientes 13 que pasa del 0 al 985,35%, mientras que para los pacientes 17 y 28 llega al 100%. En *backgroud* no existen mejoras. Sin embargo, se mantienen los valores de CS1 en CS3 en los pacientes 17, 20 y 29, encontrándose los valores de CS2 dentro del intervalo de valores de CS3 y CS1 (ver gráficas Figura 4.15 y Figura 4.16).

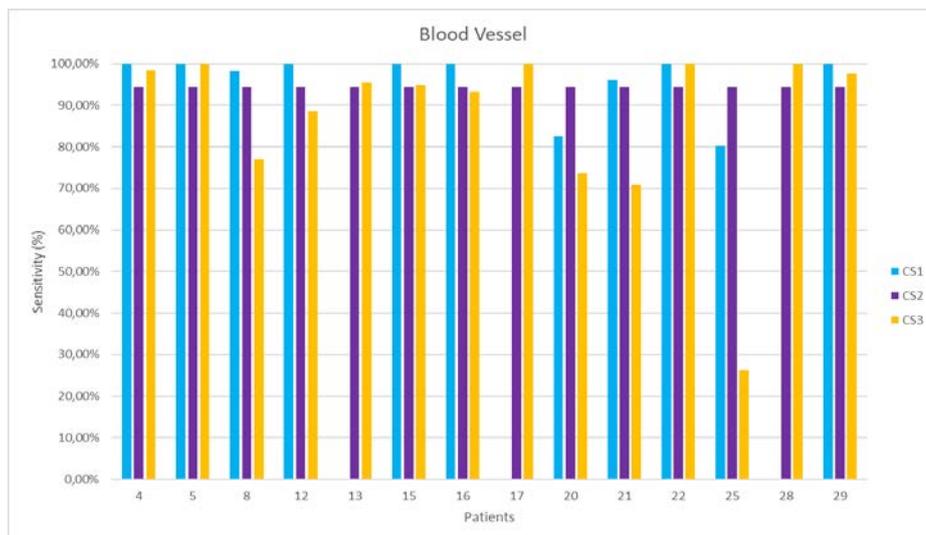


Figura 4.15. Gráfica comparativa de sensibilidad para la blood vessel (vasos sanguíneos) en CS1, CS2 y CS3.

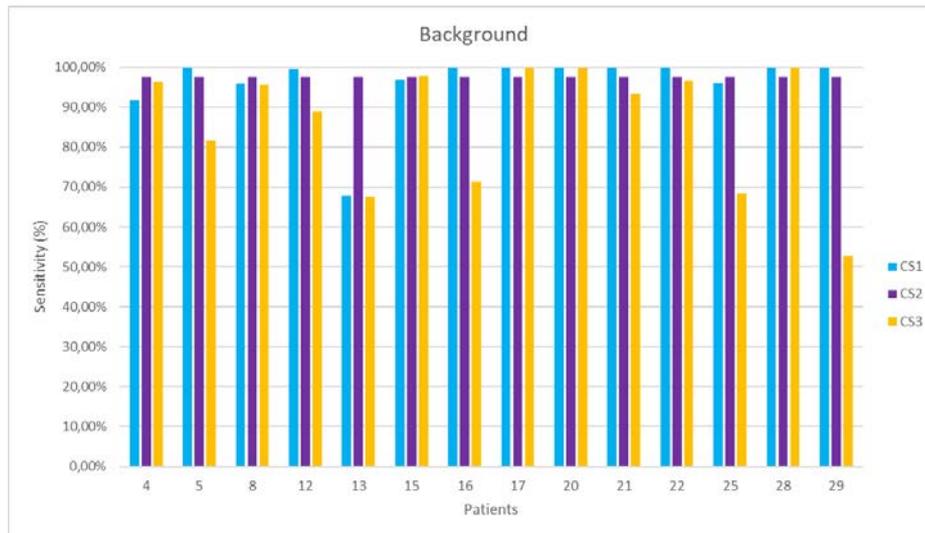


Figura 4.16. Gráfica comparativa de sensibilidad para la clase background en CS1, CS2 y CS3.

Por último, para los valores medios se obtiene que en CS3 el valor de sensibilidad para la clase tumor es el más reducido con un 17,52%. Mientras que para CS1, el valor obtenido fue del 70,74%. Esto se debe principalmente a que para el tercer caso de estudio existe una variabilidad inter-paciente por lo que las muestras de tumor no son identificadas correctamente en su totalidad.

Tras analizar los valores obtenidos de la matriz de confusión, con la Tabla 4.7, se puede concluir que para CS1 las clases que más se confunden entre sí era tejido sano (clase 1) con *background* (clase 4). Las muestras correspondientes a la clase 2 en numerosas ocasiones no eran identificadas correctamente, esto se debe principalmente a que el porcentaje de esta clase tumor con respecto al resto era relativamente inferior. Para CS2 todas las clases en algún momento fueron confundidas entre sí, debido a la variabilidad inter-paciente. Finalmente, en CS3 el número de clases identificadas correctamente en total se redujo en comparación con el CS1. Además, la confusión entre clases se produce de forma reiterada.

Tabla 4.7. Análisis obtenido de las matrices de confusión para CS1, CS2 y CS3.

| CS1 | Clase 1 | Clase 2 | Clase 3 | Clase 4 | |
|---------------------|------------|------------|------------|------------|----------------------------|
| 4 | 1 | 1 | 3 | 4, 1 | |
| 5 | 1, 4 | 3 | 3 | 4, 1 | |
| 8 | 1, 3, 4 | 2, 1, 3, 4 | 3, 1, 2 | 4, 1 | |
| 12 | 1, 3 | 2, 1, 3, 4 | 3, 1, 2 | 4, 1, 2 | |
| 13 | 1 | 1 | 1 | 4, 1 | |
| 15 | 1, 2, 3 | 2 | 3, 1 | 4, 2 | |
| 16 | 1, 4 | 1, 4 | 3 | 4, 1 | |
| 17 | 1 | 4 | 1, 4 | 4 | |
| 20 | 1, 2, 3 | 2 | 3, 2 | 4 | |
| 21 | 1, 3 | 1, 4 | 3, 1 | 4 | |
| 22 | 1 | 1 | 3 | 4 | |
| 25 | 1 | 2, 4 | 3, 4, 1 | 4, 2 | |
| 28 | 1 | 2 | 4, 1 | 4 | |
| 29 | 1, 4 | 2 | 3 | 4 | |
| CS2 | Clase 1 | Clase 2 | Clase 3 | Clase 4 | |
| base datos única | 1, 2, 3, 4 | 2, 1, 3, 4 | 3, 1, 2, 4 | 4, 1, 2, 3 | |
| CS3 | Clase 1 | Clase 2 | Clase 3 | Clase 4 | |
| 4 | 1, 4 | 1, 3 | 3, 2 | 4, 1, 2 | |
| 5 | 1, 4 | 3 | 3 | 4, 1, 2 | |
| 8 | 1, 3, 4 | 2, 1, 3, 4 | 3, 1, 2, 4 | 4, 1, 2 | |
| 12 | 1, 4 | 2, 1, 3, 4 | 3, 1 | 4, 1, 2 | |
| 13 | 1, 3, 4 | 1, 4 | 3, 4 | 4, 1, 2 | |
| 15 | 1, 4 | 2, 1, 3, 4 | 3, 1, 4 | 4, 1 | |
| 16 | 1, 2, 3, 4 | 2, 1, 4 | 3, 2, 4 | 4, 1, 2, 3 | |
| 17 | 1, 3, 4 | 2, 4 | 3 | 4 | |
| 20 | 1, 3, 4 | 2, 1, 4 | 3, 1 | 4 | |
| 21 | 1, 2, 4 | 1, 3, 4 | 3, 1, 2, 4 | 4, 2 | |
| 22 | 1, 2, 3, 4 | 4 | 3 | 4, 1, 2 | |
| 25 | 1, 4 | 2, 4 | 3, 1, 4 | 4, 2 | |
| 28 | 1, 3 | 2, 1, 4 | 3 | 4 | Confundida en su totalidad |
| 29 | 1, 2, 3, 4 | 2, 4 | 3, 2 | 1, 2, 3 | Identificada correctamente |

En la Figura 4.17, se observa el diagrama de cajas (*box plot*) correspondiente a los casos CS1 y CS3. Este diagrama representa gráficamente la tasa de acierto a través de sus cuartiles. El primer cuartil representa el 25% de los datos, el segundo la mediana (50%) y, por último, el tercer cuartil que representa el 75% de los datos. Los valores que se encuentran fuera de los límites calculados (máximos y mínimos) son atípicos, como el paciente 22 para CS3.

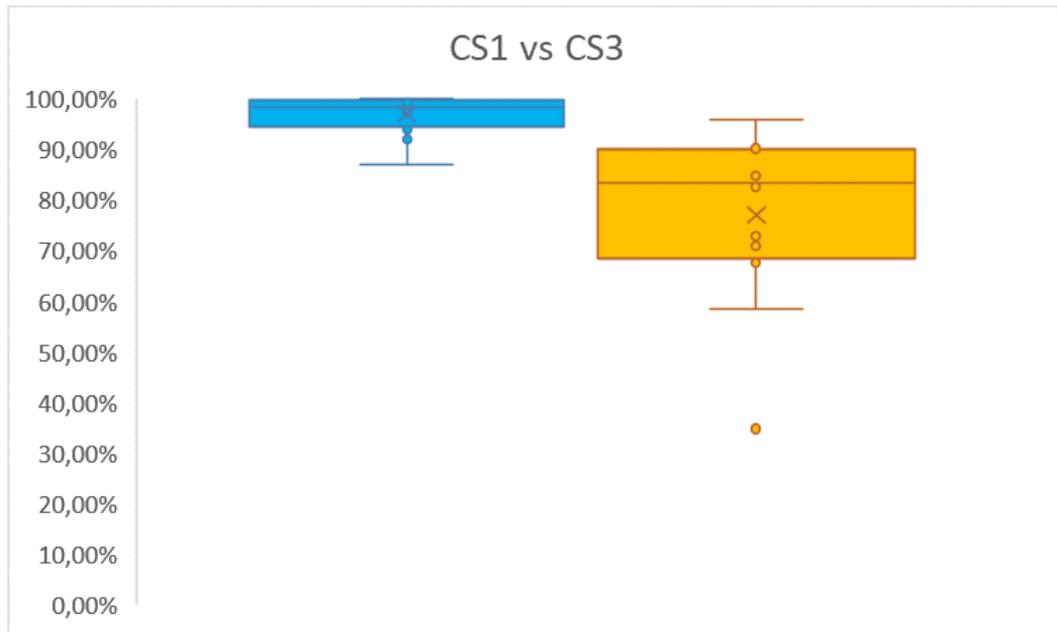


Figura 4.17. Diagrama de caja para la tasa de acierto de CS1 (azul) y CS3 (naranja).

Por otra parte, tal y como era de esperar en CS1 al añadir los pacientes al clasificador de forma totalmente independiente se evita la variabilidad inter-paciente. Sin embargo, en CS3 si existe dicha variabilidad, reflejándose en las dimensiones de la caja correspondiente a este caso de estudio.

Tabla 4.8. Matriz de confusión del paciente 022 obtenida para el CS3.

| | Normal Tissue | Tumour Tissue | Blood Vessels | Background |
|---------------|---------------|---------------|---------------|------------|
| Normal Tissue | 422 | 1556 | 56 | 8946 |
| Tumour Tissue | 0 | 0 | 0 | 96 |
| Blood Vessels | 0 | 0 | 1744 | 0 |
| Background | 15 | 110 | 0 | 3552 |

Si se observa la matriz de confusión obtenida en CS3 más detenidamente (ver Tabla 4.8) para el peor de los casos, el paciente 22, con un *accuracy* del 34,66%, se contempla como la clase 2 (tumor) ha sido confundida en todo momento con la clase 4 (*background*). El resto de los píxeles de la clase 3 (vasos sanguíneos) se etiquetaron correctamente. Por otro lado, la clase 1 (tejido sano) ha sido confundida con el resto de las clases siendo bien identificadas 422 muestras. Por último, la clase 4 ha sido identificada en algunas ocasiones de manera errónea como tejido sano o tumor.

Tabla 4.9. Matriz del paciente 022 obtenida para el CS3 con los valores de los verdaderos positivos, falsos negativos, falsos positivos y verdaderos negativos.

| | TP | FP | TN | FN |
|----------------------|------|------|------|-------|
| Normal Tissue | 422 | 15 | 5296 | 10558 |
| Tumour Tissue | 0 | 1666 | 5718 | 96 |
| Blood Vessels | 1744 | 56 | 3974 | 0 |
| Background | 3552 | 9042 | 2166 | 125 |

En la Tabla 4.9, se muestran los verdaderos positivos (TP), los falsos negativos (FN), los falsos positivos (FP) y finalmente, los verdaderos negativos (TN) (Capítulo 4, apartado 4.1.2.2) correspondientes al paciente 22. Donde, tal y como se nombró anteriormente ningún píxel de la clase tumor fue identificado como tal por lo que da un valor de 0 en los verdaderos positivos. La totalidad de los píxeles de tumor, con un valor de 96 se encuentran como falsos positivos, ya que fueron identificados como pertenecientes a otra clase.

Tabla 4.10. Matriz del paciente 022 obtenida para el CS3 con los valores de sensibilidad y especificidad.

| Class | Specificity | Sensitivity |
|-----------|-------------|-------------|
| C1 | 0,997175673 | 0,038433515 |
| C2 | 0,774377031 | 0 |
| C3 | 0,986104218 | 1 |
| C4 | 0,193254818 | 0,966004895 |

De la matriz mostrada en la Tabla 4.9, se obtienen los valores de especificidad y sensibilidad correspondientes a dicho paciente (ver Tabla 4.10). Donde, se obtiene un valor 0 de sensibilidad para la clase tumor (C2). Esto se debe principalmente a lo comentado con anterioridad, ya que ningún píxel de tumor fue identificado como perteneciente a esa misma clase. Sin embargo, tal y como se pudo observar en la matriz de confusión la clase 3 (vasos sanguíneos) fue identificada correctamente en su totalidad, con un valor de sensibilidad de 1.

Por último, en la Tabla 4.11 se muestran los tiempos de ejecución requerido para cada caso de estudio, en donde se observa que el CS3, es el caso que más tiempo ha tardado tanto en generar el modelo como en testarlo. Sin embargo, el CS1, al ir paciente por paciente, el número de muestras manejadas es menor y, por consiguiente, el tiempo necesario durante del proceso también se ve reducido.

Tabla 4.11. Tabla tiempos de ejecución para cada equipo.

| | LAPTOP-U91C0M06 | | DESKTOP-II2N235 | |
|---------------|------------------------|---------|------------------------|---------|
| Tiempo | minutos | horas | minutos | horas |
| CS1 | 29,2690 | 0,4878 | 18,8313 | 0,31385 |
| CS2 | 935,9833 | 15,5997 | 616,2452 | 10,2708 |
| CS3 | 1261,8418 | 21,0307 | 1026,5712 | 17,1095 |

Tal y como se ha comentado al inicio de este capítulo, los tiempos de cómputo dependen de distintos factores como pueden ser las características de los equipos empleados. Para la realización de la comparativa, se ha ejecutado el código correspondiente en dos dispositivos con diferentes prestaciones (ver Tabla 4.12), con el objetivo de escoger aquél que ahorre mayor tiempo de cómputo.

Tabla 4.12. Tabla comparativa equipos empleados.

| | LAPTOP-U91C0M06 | DESKTOP-II2N235 |
|------------------------|--|--|
| Procesador | Intel® Core™ i5-7200U CPU 2.50GHz-2.70GHz | Intel® Core™ i5-8600K CPU 3.60GHz-4.30GHz |
| Núcleos | 2 | 6 |
| RAM | 8GB | 16GB |
| Tarjeta gráfica | Intel 620 | Gigabyte GeForce GTX 1060 6GB |
| SO | Windows 10 | Windows 10 |

Por tanto, para el primer equipo (LAPTOP-U91C0M06) mostrado en la Tabla 4.11, se tardó un total de 37,1182 horas en extraer todos los datos correspondientes a los distintos casos de estudio. Mientras que para el segundo equipo (DESKTOP-II2N235) se tardaron 27,6934 horas. Reduciéndose el tiempo de cómputo entre equipos en un total de casi 10 horas. A partir de este momento, ya que se requiere de altos tiempos de cómputo para las simulaciones, en primer lugar, se ha decidido disminuir el número de pacientes implicados en el estudio y en segundo lugar se ha decidido usar más de un equipo para obtener los resultados, perdiendo de esta forma la posibilidad de realizar una comparación justa de los tiempos de ejecución de cada una de las alternativas de procesamiento propuestas.

4.3. Resumen

En este capítulo se han mostrado los resultados en forma de tablas comparativas para cada uno de los diferentes casos de estudio. Se comprueba con distintas métricas de evaluación la eficacia de la clasificación en función de la forma de inclusión de los datos quirúrgicos de los pacientes en el clasificador. La media aritmética más baja de la tasa de acierto se obtuvo para el tercer escenario de estudio propuesto.

El análisis se hace también de forma que se comprueba la confusión que existe entre clases a la hora de realizar la clasificación, comprobándose que existe una apreciable variabilidad inter-paciente para CS2 y CS3. Esta variabilidad se elimina en CS1 al añadir los datos del paciente de forma totalmente independiente en el clasificador SVM empleado.

CAPÍTULO 5.

5. CASO 4

Como se ha visto en el capítulo anterior (Capítulo 4) para CS3, se obtuvo de promedio una tasa de acierto del 77,14%. Asimismo, se obtuvieron unos valores de especificidad bajos en CS3 con respecto al CS1. Por otro lado, los resultados de sensibilidad también se han visto reducidos de una forma considerable en algunos casos.

Este capítulo tiene como objetivo buscar una mejora de la calidad en la clasificación de CS3, escenario que representa el caso real de una nueva operación quirúrgica, donde la clasificación se realiza con datos hiperespectrales de operaciones anteriores y se testea con muestras quirúrgicas que el modelo generado desconoce. Por consiguiente, se incluirá un porcentaje escogido aleatoriamente de los datos del propio paciente a la clasificación con la misma proporción de etiquetas de cada clase. De tal forma que, se realizará un estudio de cómo afecta añadir dichos porcentajes en las métricas de evaluación. En otras palabras, se añadirá progresivamente al *dataset* de entrenamiento un porcentaje de los datos del paciente actual y se estudiará su efecto con las métricas de clasificación.

Este proceso se realizará de dos formas. Primero, se entrenará el clasificador con los datos conocidos del propio paciente y después, se aplicarán distintos métodos para la generación automática de etiquetas.

5.1. Datos del paciente actual con etiquetas conocidas

En este apartado se presenta el cuarto escenario de estudio propuesto, denominado CS4. Es un caso de estudio en el que se utiliza el bloque de pacientes unificados (pacientes previos) y algunos datos del paciente actual con etiquetas ya conocidas para entrenar el clasificador. Para este nuevo planteamiento, se añade progresivamente al *dataset* de entrenamiento un porcentaje, con la misma proporción de etiquetas de cada clase, del paciente actual.

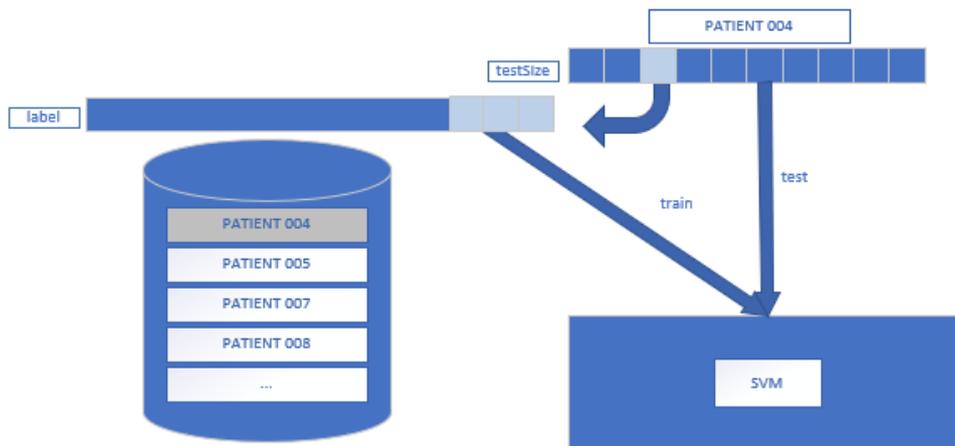


Figura 5.1. Diagrama de bloques correspondiente al caso de estudio CS3 to CS2.

Tras realizar las particiones de los datos del paciente actual, con sus respectivas etiquetas, la correspondiente al test, es añadida al bloque de datos de los pacientes unificados. Con este nuevo conjunto de datos se genera un modelo que será posteriormente testeado con el resto de las particiones del paciente actual.

En la Figura 5.1 se ha añadido al bloque de pacientes unificados (*previous patients*) el 30% de los datos del paciente 4 (*current patient*) con sus respectivas etiquetas (misma proporción de cada clase). Este proceso se repite un total de 10 veces para cada porcentaje de los datos añadidos del *current patient* y finaliza cuando al bloque unificado de pacientes se le ha integrado el 80% de los datos hiperespectrales etiquetados del paciente actual.

5.2. Datos del paciente actual con generación automática de nuevas etiquetas

Para realizar este proceso se proponen diferentes métodos para la generación automática de las etiquetas correspondientes al paciente actual, denominados ss1, ss2 y ss3 respectivamente. No obstante, existen otras técnicas supervisadas que no se han empleado en este trabajo debido a que superan el alcance del TFG.

En el caso de estudio planteado con anterioridad (apartado 5.1), la clasificación se llevaba a cabo con etiquetas ya conocidas de los pacientes que se extrajeron del diagnóstico realizado por el equipo de neurocirujanos. Sin embargo,

a diferencia del apartado anterior, en este el paciente actual no parte de etiquetas conocidas si no que se genera un nuevo etiquetado de sus muestras quirúrgicas.

5.2.1. SS1

En este nuevo procedimiento propuesto, para realizar de forma automática el nuevo etiquetado de las muestras quirúrgicas del paciente actual, inicialmente se utiliza el bloque de pacientes previos (*previous patients*) para calcular las firmas medias por clase, denominadas F1, F2, F3 y F4. Esto se aprecia gráficamente en la Figura 5.2, donde la firma media correspondiente a cada clase se representa con las líneas discontinuas en vertical, mientras que las X son las firmas de cada clase.

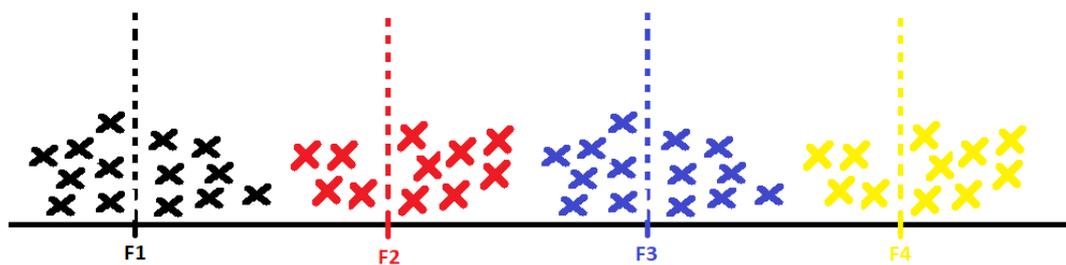


Figura 5.2. Píxeles de cada clase pertenecientes al bloque de pacientes previos con las firmas medias correspondientes (F1, F2, F3 y F4).

Una vez calculadas las firmas medias, se calculan las distancias por pares entre dos conjuntos de observaciones: las firmas medias de cada clase y el set de los datos correspondientes al paciente actual, con el objeto de obtener los píxeles del paciente actual con mayor similitud a las firmas medias correspondientes a cada clase. Con esta información se procederá a realizar el nuevo etiquetado de las muestras quirúrgicas del paciente actual, en el que se genera un nuevo conjunto de entrenamiento.

En la Figura 5.3, las X corresponden a los píxeles del paciente actual (sin clase asignada), donde tras calcular la distancia con respecto a la media de las firmas se procede a realizar el etiquetado de los píxeles más cercanos a dicha media. No obstante, tal y como se aprecia en la Figura 5.3, con esta técnica puede darse el caso de que un píxel de una clase sea etiquetado como de otra.

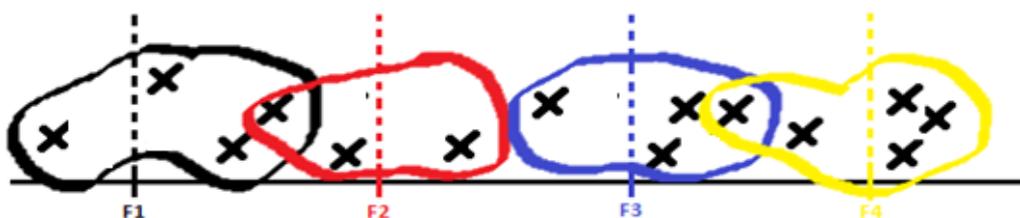


Figura 5.3 Píxeles del paciente actual más parecidos a la firma media por clase (F1, F2, F3 y F4)

Finalmente, para realizar el entrenamiento se emplea el conjunto de datos unificados de los pacientes previos y un porcentaje de los datos etiquetados con esta nueva metodología del paciente actual. Se ha decidido evaluar los resultados con el 10%, 20%, 30% y el 40% de los datos del paciente actual. La elección de estos porcentajes se debe a que se ha observado que para la gran mayoría de los pacientes a partir del 40% las variaciones en las métricas de evaluación no son significativas.

Asimismo, para esta versión de algoritmo semi-supervisado se emplearon dos formas diferentes de calcular distancias. La distancia euclídea en un espacio euclídeo de n -dimensiones para los puntos $F = (f_1, f_2, \dots, f_i)$ y $P = (p_1, p_2, \dots, p_i)$ y viene dado por la ecuación (5.1).

$$d = \sqrt{\sum_{i=1}^n (p_i - q_i)^2} \quad (5.1)$$

Como medida alternativa de similitud se usa el coseno entre dos vectores, en la geometría donde el triángulo está formado por una línea como parte inferior y puntos originales de n -dimensiones en el espacio del vector. No obstante, el valor del ángulo es incierto debido a que, aunque la distancia entre dos puntos es fija, pueden variar los valores del coseno. Este tipo de distancia viene definida como uno menos el coseno del ángulo formado entre dos puntos tratados como vectores y formulación se realiza mediante la ecuación (5.2).

$$\text{cosine}(X_f, X_p) = 1 - \frac{\sum_{j=1}^p X_{Kj} X_{pj}}{\sqrt{\sum_{j=1}^p X_{Kj}^2 * \sum_{j=1}^p X_{pj}^2 X_{pj}^2}} \quad (5.2)$$

En general este tipo de distancia se utiliza como vector de distancia discriminante [63] [64].

5.2.2. SS2

Para el planteamiento de este método de clasificación semi-supervisado, denominado ss2, se utilizan 10 clasificadores en paralelo para generar de forma automatizada las nuevas etiquetas del paciente actual. De tal forma que, se genera una partición de los datos del bloque unificado de los pacientes previos en diez partes iguales, en donde la proporción de muestras de cada clase se mantiene en

cada una de las particiones que se usan para entrenar el clasificador (ver Figura 5.4).

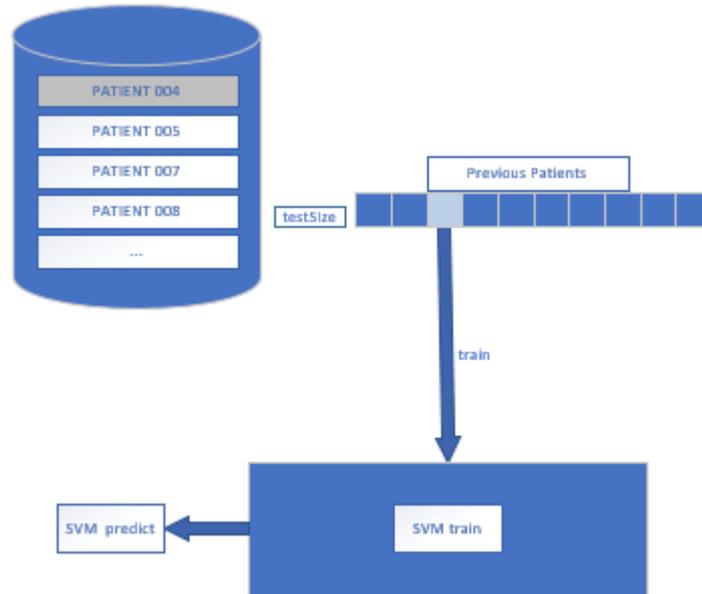


Figura 5.4. Diagrama de bloques correspondiente al CS4 de SS2. Con $i=3$, el bucle se realiza 10 veces correspondientes a cada una de las particiones, generando un total de 10 valores pertenecientes al *svm*predict.

Una vez entrenados los 10 clasificadores se procede a realizar la predicción, correspondientes a las 10 particiones generadas anteriormente. Los resultados se unifican en una única matriz. Asimismo, para proceder a realizar el etiquetado del paciente actual, se extrae de la matriz generada el número de veces que un píxel fue etiquetado como perteneciente a una misma clase. De modo que se obtienen unos valores nuevos de etiquetas correspondientes a las clases tejido sano, tumor, vasos sanguíneos y *background* para cada píxel.

Con esta información y al igual que en *ss1*, se realiza el nuevo etiquetado de las muestras del paciente actual. Finalmente, para el entrenamiento se emplea el conjunto de datos unificados de los pacientes previos y un porcentaje de los datos etiquetados con esta nueva metodología del paciente actual. Los porcentajes son los mismos que para *ss1* de tal forma que se facilita la comparativa.

Una vez entrenados los 10 clasificadores se procede a realizar la predicción, correspondientes a las 10 particiones generadas anteriormente. Los resultados se unifican en una única matriz. Asimismo, para proceder a realizar el etiquetado del paciente actual, se extrae de la matriz generada el número de veces que un píxel fue etiquetado como perteneciente a una misma clase. De modo que se obtienen

unos valores nuevos de etiquetas correspondientes a las clases tejido sano, tumor, vasos sanguíneos y *background* para cada píxel.

5.2.3. SS3

En este método de etiquetado se plantea una nueva forma de reconocimiento de patrones en MATLAB, el método *K-NN* o de los *k*-vecinos más cercanos (Capítulo 2). Se trata de clasificar las muestras del paciente actual basándose en la clasificación conocida de sus vecinos (bloque unificado de pacientes previos).

Asimismo, para nuestro caso de estudio, la *k* utilizada es de los 500 vecinos más próximos. Con la información extraída a partir de este método se realiza el etiquetado de las muestras quirúrgicas del paciente actual. Para el entrenamiento se emplea el mismo conjunto de datos y los mismos porcentajes del paciente actual que en las versiones anteriores.

5.3. Resultados

Por último, una vez presentada la metodología aplicada para este nuevo caso de estudio se muestran los resultados obtenidos. Se evalúan las métricas de *accuracy*, de especificidad y de sensibilidad obtenidas a partir de la matriz de confusión para cada una de las técnicas nombradas anteriormente.

A continuación, se muestran los resultados obtenidos en una tabla comparativa del caso de estudio CS3, escenario que más se ajusta a la realidad de una operación quirúrgica y de CS4, caso en el que se añade hasta el 80% de los datos del paciente actual con etiquetas ya conocidas en la clasificación. Primero, se presentará el resultado del *accuracy* junto con los valores obtenidos de la matriz de confusión de sensibilidad y especificidad de cada uno de los pacientes seleccionados para formar parte de una nueva base de datos, realizada de manera aleatoria a excepción, de dos pacientes que se corresponden con los que obtuvieron la mayor y la menor tasa de acierto en CS3 (Capítulo 4, Tabla 4.5). Estos dos pacientes son el 22, con un *accuracy* del 34,66% y el paciente 28 con una tasa del 97,20%. Los pacientes restantes son el 12, 15, 20, 25 y el 29. Por tanto, la base de datos con la que se trabajará a partir de este momento es la compuesta por los pacientes 12, 15, 20, 22, 25, 28 y 29.

Como se observa en la Tabla 5.1 y en la Tabla 5.2 del CS3 al CS4, solo añadiendo un pequeño porcentaje de muestras del paciente actual, como por ejemplo el 10% de los datos, se logra una mejora genérica en la tasa de acierto de aproximadamente el 2%. Asimismo, para el paciente 29 esta mejora es del 32,70%.

Tabla 5.1. Tabla comparativa CS3 y CS4 con los datos del paciente actual con etiquetas conocidas de los Pacientes 12, 15, y 20.

| ID | CS | | O. A. (%) | Specificity (%) | | | | Sensitivity (%) | | | |
|-----|---------------|--------|---------------|-----------------|---------|--------|--------|-----------------|---------|--------|---------|
| | | | | N | T | BV | B | N | T | BV | B |
| 12 | CS3 | - | 82,41% | 85,78% | 99,65% | 87,24% | 98,72% | 97,21% | 1,68% | 88,58% | 88,90% |
| | | 10% | 84,39% | 88,90% | 99,72% | 87,14% | 98,89% | 97,53% | 6,29% | 91,59% | 90,20% |
| | CS4 | 20% | 86,26% | 91,16% | 99,77% | 87,85% | 99,04% | 97,80% | 14,08% | 93,46% | 91,48% |
| | | 30% | 88,41% | 92,82% | 99,80% | 89,77% | 99,15% | 98,01% | 28,15% | 94,75% | 92,34% |
| | | 40% | 91,17% | 93,96% | 99,84% | 93,26% | 99,25% | 98,16% | 50,74% | 95,51% | 93,11% |
| | | 50% | 92,66% | 94,67% | 99,88% | 94,95% | 99,32% | 98,30% | 61,97% | 95,80% | 94,01% |
| | | 60% | 93,79% | 95,26% | 99,89% | 96,15% | 99,36% | 98,38% | 70,01% | 96,27% | 94,53% |
| | | 70% | 94,57% | 95,76% | 99,90% | 96,85% | 99,40% | 98,46% | 74,63% | 96,60% | 95,22% |
| 80% | 95,11% | 96,13% | 99,91% | 97,29% | 99,42% | 98,51% | 77,50% | 96,86% | 95,78% | | |
| 15 | CS3 | - | 72,70% | 69,26% | 100,00% | 99,85% | 97,74% | 94,48% | 6,35% | 94,96% | 97,84% |
| | | 10% | 74,50% | 71,16% | 100,00% | 99,90% | 98,12% | 95,38% | 12,21% | 95,35% | 97,60% |
| | CS4 | 20% | 76,67% | 73,75% | 100,00% | 99,81% | 98,22% | 95,38% | 20,36% | 95,57% | 97,60% |
| | | 30% | 80,09% | 77,69% | 100,00% | 99,83% | 98,49% | 95,65% | 33,12% | 95,87% | 97,60% |
| | | 40% | 83,21% | 81,34% | 100,00% | 99,84% | 98,62% | 95,74% | 45,01% | 96,06% | 97,60% |
| | | 50% | 85,91% | 84,46% | 100,00% | 99,85% | 98,77% | 95,91% | 55,10% | 96,28% | 97,60% |
| | | 60% | 87,63% | 86,44% | 100,00% | 99,86% | 98,87% | 96,09% | 61,45% | 96,41% | 97,76% |
| | | 70% | 88,67% | 87,71% | 100,00% | 99,76% | 98,90% | 96,27% | 65,47% | 96,41% | 97,76% |
| 80% | 89,73% | 88,97% | 100,00% | 99,77% | 98,91% | 96,27% | 69,49% | 96,49% | 97,76% | | |
| 20 | CS3 | - | 58,33% | 69,32% | 100,00% | 98,71% | 57,17% | 95,06% | 3,53% | 73,69% | 100,00% |
| | | 10% | 63,34% | 82,07% | 100,00% | 98,81% | 57,97% | 94,93% | 16,84% | 73,62% | 100,00% |
| | CS4 | 20% | 75,03% | 89,99% | 100,00% | 99,01% | 72,64% | 94,87% | 47,60% | 73,84% | 100,00% |
| | | 30% | 86,79% | 92,84% | 100,00% | 99,16% | 89,09% | 94,87% | 78,51% | 73,99% | 100,00% |
| | | 40% | 92,09% | 93,88% | 100,00% | 99,19% | 96,38% | 94,75% | 92,52% | 74,06% | 100,00% |
| | | 50% | 93,96% | 94,40% | 100,00% | 99,21% | 98,69% | 94,75% | 97,33% | 74,36% | 100,00% |
| | | 60% | 94,49% | 94,60% | 100,00% | 99,21% | 99,27% | 94,75% | 98,72% | 74,36% | 100,00% |
| | | 70% | 94,59% | 94,73% | 100,00% | 99,19% | 99,30% | 94,63% | 99,00% | 74,50% | 100,00% |
| 80% | 94,73% | 94,82% | 100,00% | 99,19% | 99,41% | 94,63% | 99,30% | 74,65% | 100,00% | | |

Tabla 5.2. Tabla comparativa CS3 y CS4 con los datos del paciente actual con etiquetas conocidas de los Pacientes 22, 25, 28 y 29.

| ID | CS | | O. A. (%) | Specificity (%) | | | | Sensitivity (%) | | | |
|-----|---------------|--------|---------------|-----------------|---------|---------|--------|-----------------|--------|---------|---------|
| | | | | N | T | BV | B | N | T | BV | B |
| 22 | CS3 | - | 34,66% | 99,72% | 77,44% | 98,61% | 19,33% | 3,84% | 0,00% | 100,00% | 96,60% |
| | | 10% | 74,31% | 99,69% | 92,80% | 99,78% | 72,83% | 63,42% | 0,00% | 100,00% | 96,59% |
| | | 20% | 88,63% | 99,56% | 97,37% | 99,99% | 88,38% | 84,99% | 0,00% | 100,00% | 96,44% |
| | | 30% | 93,34% | 99,50% | 98,42% | 100,00% | 93,49% | 92,04% | 0,00% | 100,00% | 96,53% |
| | CS4 | 40% | 95,28% | 99,48% | 98,83% | 100,00% | 95,56% | 94,90% | 0,00% | 100,00% | 96,68% |
| | | 50% | 96,23% | 99,46% | 99,04% | 100,00% | 96,56% | 96,30% | 0,00% | 100,00% | 96,77% |
| | | 60% | 96,86% | 99,44% | 99,14% | 100,00% | 97,26% | 97,24% | 0,00% | 100,00% | 96,77% |
| | | 70% | 97,29% | 95,77% | 99,40% | 100,00% | 99,08% | 99,72% | 0,00% | 100,00% | 92,37% |
| 25 | CS3 | - | 70,84% | 99,92% | 75,97% | 100,00% | 73,79% | 94,78% | 91,19% | 26,35% | 68,38% |
| | | 10% | 72,33% | 99,94% | 76,02% | 100,00% | 77,49% | 96,25% | 94,36% | 33,29% | 67,93% |
| | | 20% | 73,64% | 99,95% | 76,27% | 100,00% | 80,41% | 97,84% | 96,79% | 38,31% | 67,87% |
| | | 30% | 74,14% | 99,92% | 76,36% | 100,00% | 81,56% | 98,30% | 97,66% | 40,51% | 67,84% |
| | CS4 | 40% | 75,51% | 99,92% | 76,45% | 100,00% | 82,37% | 98,75% | 98,27% | 41,98% | 67,84% |
| | | 50% | 74,94% | 99,89% | 76,56% | 100,00% | 83,27% | 98,98% | 98,96% | 43,82% | 67,87% |
| | | 60% | 75,24% | 99,89% | 76,64% | 100,00% | 83,94% | 99,32% | 99,13% | 45,53% | 67,87% |
| | | 70% | 75,62% | 99,89% | 76,74% | 100,00% | 84,75% | 99,55% | 99,48% | 47,61% | 67,87% |
| 28 | CS3 | - | 97,20% | 99,68% | 100,00% | 97,98% | 96,51% | 80,13% | 88,23% | 100,00% | 100,00% |
| | | 10% | 99,21% | 99,71% | 100,00% | 99,97% | 96,98% | 99,73% | 88,83% | 98,48% | 100,00% |
| | | 20% | 99,22% | 99,76% | 100,00% | 100,00% | 96,67% | 100,00% | 89,70% | 71,21% | 100,00% |
| | | 30% | 99,23% | 99,80% | 100,00% | 100,00% | 96,51% | 100,00% | 90,51% | 51,52% | 100,00% |
| | CS4 | 40% | 99,20% | 99,82% | 100,00% | 100,00% | 96,22% | 100,00% | 90,97% | 27,27% | 100,00% |
| | | 50% | 99,20% | 99,83% | 100,00% | 100,00% | 96,20% | 100,00% | 91,38% | 19,70% | 100,00% |
| | | 60% | 99,22% | 99,85% | 100,00% | 100,00% | 96,20% | 100,00% | 91,78% | 15,15% | 100,00% |
| | | 70% | 99,24% | 99,87% | 100,00% | 100,00% | 96,23% | 100,00% | 92,19% | 13,64% | 100,00% |
| 29 | CS3 | - | 59,76% | 92,01% | 98,29% | 62,11% | 76,97% | 84,32% | 18,94% | 97,61% | 52,68% |
| | | 10% | 92,46% | 98,76% | 99,73% | 99,80% | 81,02% | 91,27% | 30,96% | 99,50% | 98,21% |
| | | 20% | 94,08% | 99,23% | 99,88% | 99,91% | 84,21% | 92,96% | 43,04% | 99,67% | 98,92% |
| | | 30% | 95,34% | 99,47% | 99,92% | 99,96% | 87,31% | 94,12% | 54,48% | 99,80% | 99,26% |
| | CS4 | 40% | 96,53% | 99,61% | 99,94% | 99,96% | 90,59% | 94,65% | 67,39% | 99,83% | 99,45% |
| | | 50% | 97,60% | 99,69% | 99,95% | 99,97% | 93,64% | 95,02% | 79,53% | 99,87% | 99,55% |
| | | 60% | 98,29% | 99,70% | 99,96% | 99,97% | 95,71% | 95,29% | 87,79% | 99,90% | 99,57% |
| | | 70% | 98,65% | 99,74% | 99,97% | 99,97% | 96,69% | 95,50% | 91,61% | 99,90% | 99,62% |
| 80% | 98,87% | 99,76% | 99,97% | 99,97% | 97,32% | 95,71% | 93,90% | 99,90% | 99,65% | | |

Si se comparan los resultados obtenidos en CS3 con los de CS4 añadiendo el 80 por ciento de los datos del paciente actual, se producen unas mejoras más considerables. El paciente 22 mejora en CS4 un 62,90% con respecto a CS3. No obstante, aunque la tasa de acierto obtenida del 97,56% es elevada, en este paciente en concreto no se logra identificar ningún píxel de la clase tumor. Se

alcanza una notable mejora en la clasificación del paciente 29 del 39,11%. Para este paciente, en CS3 se logra una tasa de acierto del 59,76% y en CS4, al entrenar el clasificador con el bloque unificado de pacientes y el 80% de las muestras del paciente 29, se consigue un *accuracy* del 98,87%. Por otro lado, en las muestras de tumor esta mejora también es significativa, pasando del 18,94% en CS3 al 93,90% en CS4.

A partir de este momento, para la aplicación de las técnicas semi-supervisadas presentadas anteriormente (ss1, ss2 y ss3) los porcentajes de datos del paciente actual que se añaden para entrenar el clasificador se reducen. Esta reducción se debe a que si se realiza un análisis más exhaustivo de los resultados obtenidos en las Tabla 5.1 y Tabla 5.2 para el CS4 a partir del 40% las mejoras del *accuracy*, tal y como se muestra en la gráfica de la Figura 5.5. Además, los tiempos de simulación requeridos son elevados.

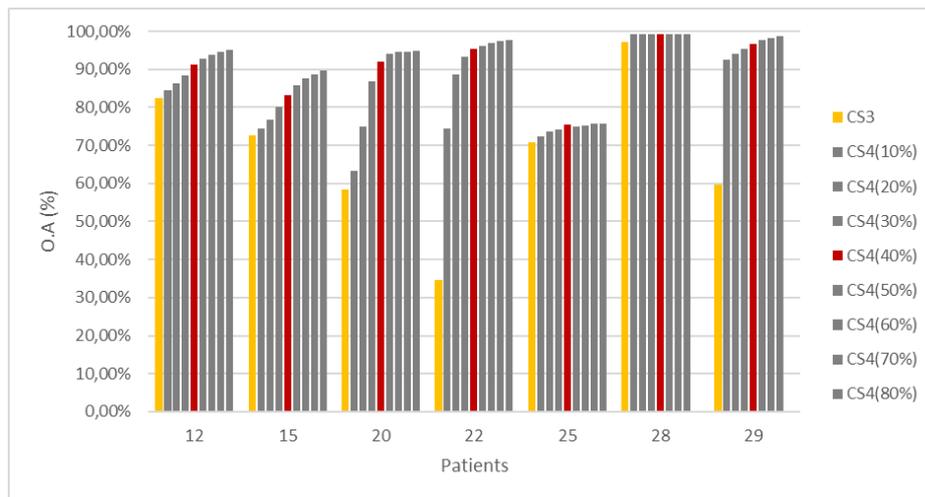


Figura 5.5. Gráfica comparativa del overall accuracy para el CS3 y CS4 con sus respectivos porcentajes.

A continuación, se muestran los resultados obtenidos del entrenamiento del clasificador a partir de las muestras del paciente actual con una generación automática de etiquetas, realizado de las formas anteriormente mencionadas.

La primera técnica propuesta es ss1 donde para realizar el etiquetado se calculan primero las firmas medias de cada clase del bloque unificado de pacientes. Posteriormente, se halla la distancia por píxel entre la media de las firmas de cada clase (F1, F2, F3 y F4) y los datos del paciente actual. El cálculo de las distancias se efectúa con dos métricas diferentes: La distancia Euclídea y la distancia Coseno (Tabla 5.3 y Tabla 5.4).

Tabla 5.3. Tabla de los resultados obtenidos en ss1 con cálculo de distancia Euclídea.

| Experiment Type | ID | O. A. (%) | Specificity (%) | | | | Sensitivity (%) | | | |
|-----------------|----|----------------|-----------------|---------|---------|--------|-----------------|--------|---------|---------|
| | | | N | T | BV | B | N | T | BV | B |
| SS1 (Euclídea) | 12 | 82,69% | 86,60% | 99,39% | 87,15% | 98,68% | 97,10% | 1,73% | 89,74% | 88,43% |
| | | 82,84% | 87,03% | 99,30% | 87,10% | 98,58% | 96,88% | 1,23% | 90,74% | 88,03% |
| | | 82,87% | 87,37% | 99,25% | 87,05% | 98,33% | 96,34% | 0,80% | 91,65% | 87,60% |
| | | 82,94% | 87,71% | 99,16% | 87,01% | 98,18% | 96,00% | 0,50% | 92,52% | 87,11% |
| | 15 | 72,95% | 69,54% | 100,00% | 99,95% | 97,75% | 94,40% | 7,28% | 95,01% | 97,84% |
| | | 73,22% | 69,97% | 100,00% | 99,90% | 97,63% | 94,00% | 8,65% | 94,99% | 97,84% |
| | | 73,47% | 70,27% | 100,00% | 99,90% | 97,64% | 94,00% | 9,58% | 94,99% | 97,99% |
| | | 73,695% | 70,57% | 100,00% | 99,90% | 97,59% | 93,92% | 10,56% | 94,96% | 97,99% |
| | 20 | 57,92% | 68,15% | 100,00% | 98,70% | 57,28% | 95,06% | 2,46% | 73,69% | 100,00% |
| | | 57,59% | 66,74% | 100,00% | 98,69% | 57,82% | 94,90% | 1,67% | 73,69% | 100,00% |
| | | 57,39% | 65,69% | 100,00% | 98,68% | 58,38% | 94,90% | 1,15% | 73,69% | 100,00% |
| | | 57,22% | 64,55% | 100,00% | 98,68% | 59,14% | 94,90% | 0,57% | 73,96% | 100,00% |
| | 22 | 34,93% | 99,72% | 74,71% | 98,63% | 20,28% | 4,30% | 0,00% | 100,00% | 96,46% |
| | | 35,33% | 99,70% | 69,29% | 99,25% | 22,13% | 4,92% | 0,00% | 100,00% | 96,38% |
| | | 35,76% | 99,74% | 77,92% | 99,93% | 20,81% | 5,44% | 0,00% | 100,00% | 96,79% |
| | | 36,10% | 99,72% | 86,03% | 99,95% | 20,03% | 5,92% | 0,00% | 100,00% | 96,87% |
| | 25 | 71,44% | 99,92% | 76,53% | 100,00% | 75,09% | 96,11% | 85,34% | 37,71% | 68,38% |
| | | 70,73% | 99,57% | 77,08% | 100,00% | 73,86% | 97,75% | 72,15% | 49,17% | 68,38% |
| | | 69,34% | 98,83% | 77,39% | 100,00% | 71,48% | 98,46% | 59,28% | 56,12% | 68,38% |
| | | 68,06% | 97,75% | 77,47% | 100,00% | 69,52% | 98,57% | 51,25% | 57,55% | 68,40% |
| | 28 | 98,72% | 99,64% | 100,00% | 99,63% | 96,36% | 96,37% | 86,51% | 100,00% | 100,00% |
| | | 98,89% | 99,50% | 100,00% | 100,00% | 96,03% | 100,00% | 83,65% | 100,00% | 100,00% |
| | | 98,70% | 99,35% | 100,00% | 100,00% | 95,63% | 100,00% | 80,99% | 97,26% | 100,00% |
| | | 98,71% | 99,25% | 100,00% | 100,00% | 96,26% | 100,00% | 81,30% | 100,00% | 99,98% |
| | 29 | 61,31% | 94,59% | 98,68% | 62,93% | 76,50% | 89,42% | 12,47% | 97,79% | 54,96% |
| | | 64,39% | 97,93% | 99,26% | 65,29% | 76,23% | 91,56% | 10,93% | 98,17% | 59,32% |
| | | 66,63% | 99,01% | 99,55% | 67,89% | 75,10% | 88,80% | 10,87% | 98,32% | 62,98% |
| | | 66,30% | 99,12% | 99,58% | 67,91% | 73,27% | 81,79% | 12,36% | 98,05% | 63,35% |

De la Tabla 5.3, se observa que a medida que aumenta el porcentaje de muestras del paciente actual que se añade al clasificador, se alcanzan unos valores mayores en la métrica de especificidad. Sin embargo, esto no ocurre con las probabilidades de que un píxel correspondiente a una clase sea identificado como de ella. Por tanto, los valores de sensibilidad disminuyen cuando se aumenta el porcentaje de muestras del paciente añadido. A excepción, del paciente 15 que no cumple con el criterio anterior, donde se obtienen mejores resultados de *accuracy* y de sensibilidad en la clase tumor al añadir un 40% del paciente actual con las nuevas etiquetas generadas con esta técnica.

Tabla 5.4. Tabla de resultados obtenidos en ss1 con cálculo de distancia Coseno.

| Experiment Type | ID | O. A. (%) | Specificity (%) | | | | Sensitivity (%) | | | |
|-----------------|----|---------------|-----------------|---------|---------|--------|-----------------|--------|---------|---------|
| | | | N | T | BV | B | N | T | BV | B |
| SS1 (Cosine) | 12 | 82,11% | 85,30% | 99,63% | 87,18% | 98,74% | 97,24% | 1,30% | 88,83% | 87,52% |
| | | 82,28% | 85,50% | 99,61% | 87,16% | 98,80% | 97,37% | 0,95% | 89,85% | 86,71% |
| | | 82,51% | 85,81% | 99,58% | 87,17% | 98,85% | 97,47% | 0,55% | 90,86% | 86,22% |
| | | 82,89% | 86,34% | 99,58% | 87,19% | 98,90% | 97,56% | 0,45% | 91,96% | 86,06% |
| | 15 | 72,72% | 69,30% | 100,00% | 99,95% | 97,69% | 94,24% | 6,55% | 94,96% | 97,84% |
| | | 72,66% | 69,26% | 100,00% | 100,00% | 97,63% | 94,08% | 6,45% | 94,94% | 97,84% |
| | | 72,56% | 69,17% | 100,00% | 100,00% | 97,59% | 93,84% | 6,16% | 94,96% | 97,84% |
| | | 72,46% | 69,10% | 100,00% | 100,00% | 97,53% | 93,69% | 5,87% | 94,96% | 97,84% |
| | 20 | 57,59% | 68,54% | 100,00% | 98,69% | 56,16% | 95,01% | 1,61% | 73,69% | 100,00% |
| | | 57,18% | 67,52% | 100,00% | 98,68% | 56,09% | 94,95% | 0,55% | 73,69% | 100,00% |
| | | 94,52% | 94,97% | 100,00% | 98,87% | 99,31% | 92,78% | 99,18% | 75,88% | 100,00% |
| | | 56,98% | 66,80% | 100,00% | 98,49% | 56,41% | 94,41% | 0,03% | 74,36% | 100,00% |
| | 22 | 35,09% | 99,72% | 65,92% | 98,63% | 22,58% | 4,42% | 0,00% | 100,00% | 96,82% |
| | | 35,66% | 99,74% | 56,49% | 98,67% | 27,82% | 5,23% | 0,00% | 100,00% | 96,95% |
| | | 36,36% | 99,74% | 56,49% | 98,67% | 27,82% | 5,23% | 0,00% | 100,00% | 96,95% |
| | | 36,58% | 99,70% | 52,27% | 98,24% | 33,58% | 6,49% | 0,00% | 100,00% | 97,28% |
| | 25 | 71,95% | 99,85% | 76,55% | 100,00% | 76,33% | 97,34% | 87,29% | 37,71% | 68,32% |
| | | 70,98% | 99,16% | 77,08% | 100,00% | 74,85% | 98,46% | 73,09% | 49,17% | 68,32% |
| | | 69,44% | 98,39% | 77,40% | 100,00% | 72,10% | 98,57% | 59,75% | 56,12% | 68,38% |
| | | 68,28% | 97,48% | 77,51% | 100,00% | 70,26% | 98,77% | 51,72% | 58,32% | 68,40% |
| | 28 | 98,63% | 99,64% | 100,00% | 99,52% | 96,46% | 95,28% | 86,82% | 100,00% | 100,00% |
| | | 98,63% | 99,50% | 100,00% | 100,00% | 95,81% | 100,00% | 83,18% | 100,00% | 100,00% |
| | | 98,69% | 99,34% | 100,00% | 100,00% | 95,61% | 100,00% | 80,94% | 94,52% | 100,00% |
| | | 98,70% | 99,25% | 100,00% | 100,00% | 96,21% | 100,00% | 81,15% | 100,00% | 99,98% |
| | 29 | 60,77% | 92,98% | 98,93% | 62,68% | 77,10% | 90,85% | 13,84% | 98,38% | 53,67% |
| | | 61,22% | 93,48% | 99,41% | 63,15% | 75,99% | 94,66% | 7,44% | 98,29% | 54,57% |
| | | 61,69% | 93,62% | 99,52% | 63,88% | 75,34% | 95,76% | 3,95% | 98,23% | 55,53% |
| | | 66,28% | 98,22% | 99,67% | 68,06% | 74,10% | 92,18% | 3,09% | 98,50% | 62,85% |

En los pacientes 12, 22, 28 y 29 se consigue un valor mayor de tasa de acierto al añadir el 40% del paciente actual (ver Tabla 5.4). No obstante, esto no ocurre con el parámetro sensibilidad de la clase tumor. Esto se debe a que los porcentajes del resto de clases y los valores de especificidad compensan la baja probabilidad de etiquetar un píxel de tumor correctamente. Para el resto de los casos no se asocia un patrón de resultados.

En el caso del segundo algoritmo semi-supervisado ss2, se utilizan 10 clasificadores en paralelo para realizar la generación automática de las etiquetas del paciente actual. En la Tabla 5.5 se muestran los resultados de la tasa de acierto y de los valores de sensibilidad y especificidad.

Tabla 5.5. Tabla de resultados obtenidos en ss2.

| Experiment Type | ID | O. A. (%) | Specificity (%) | | | | Sensitivity (%) | | | |
|-----------------|----|-----------|-----------------|---------|---------|--------|-----------------|--------|---------|---------|
| | | | N | T | BV | B | N | T | BV | B |
| SS2 | 12 | 81,24% | 83,68% | 99,67% | 87,73% | 98,50% | 96,81% | 0,33% | 85,91% | 89,13% |
| | | 78,94% | 80,25% | 99,68% | 87,91% | 98,11% | 96,12% | 0,28% | 80,30% | 88,94% |
| | | 77,51% | 78,22% | 99,70% | 87,89% | 97,77% | 95,47% | 0,10% | 78,16% | 87,20% |
| | | 75,98% | 76,07% | 99,71% | 87,80% | 97,48% | 94,97% | 0,08% | 75,15% | 86,10% |
| | 15 | 72,94% | 69,57% | 100,00% | 100,00% | 97,68% | 94,24% | 6,79% | 95,28% | 97,84% |
| | | 72,96% | 69,63% | 100,00% | 100,00% | 97,64% | 94,08% | 6,84% | 95,35% | 97,84% |
| | | 72,84% | 69,64% | 100,00% | 99,85% | 97,42% | 94,00% | 6,70% | 95,21% | 97,84% |
| | | 72,77% | 69,63% | 100,00% | 99,70% | 97,32% | 94,00% | 6,55% | 95,11% | 97,99% |
| | 20 | 58,45% | 75,05% | 100,00% | 98,86% | 53,03% | 95,39% | 3,34% | 74,55% | 100,00% |
| | | 58,71% | 79,92% | 100,00% | 99,12% | 50,59% | 95,98% | 3,34% | 75,48% | 100,00% |
| | | 94,91% | 95,10% | 100,00% | 99,19% | 99,34% | 94,30% | 98,36% | 78,52% | 100,00% |
| | | 59,12% | 87,71% | 100,00% | 99,41% | 47,74% | 96,58% | 3,37% | 77,33% | 99,96% |
| | 22 | 35,25% | 99,70% | 94,69% | 94,08% | 18,22% | 4,58% | 0,00% | 100,00% | 97,04% |
| | | 36,67% | 99,68% | 94,27% | 76,96% | 22,07% | 6,75% | 0,00% | 100,00% | 96,95% |
| | | 38,81% | 99,64% | 84,52% | 51,21% | 38,98% | 10,08% | 0,00% | 100,00% | 96,60% |
| | | 43,84% | 99,59% | 81,77% | 54,34% | 54,98% | 17,68% | 0,00% | 100,00% | 96,49% |
| | 25 | 71,95% | 99,95% | 76,42% | 100,00% | 76,17% | 96,72% | 89,86% | 34,51% | 68,38% |
| | | 70,03% | 99,97% | 77,33% | 100,00% | 70,52% | 98,36% | 76,29% | 32,30% | 69,62% |
| | | 67,91% | 99,97% | 79,06% | 100,00% | 63,10% | 98,77% | 59,75% | 29,33% | 72,06% |
| | | 65,93% | 99,97% | 83,36% | 100,00% | 52,07% | 98,36% | 33,07% | 29,00% | 77,84% |
| | 28 | 63,19% | 68,05% | 99,57% | 88,04% | 91,93% | 57,34% | 87,45% | 8,22% | 62,07% |
| | | 58,24% | 64,67% | 98,74% | 86,50% | 78,14% | 55,09% | 87,40% | 1,37% | 56,41% |
| | | 70,75% | 77,92% | 99,41% | 88,66% | 89,76% | 53,19% | 87,55% | 21,92% | 71,65% |
| | | 76,60% | 83,50% | 99,21% | 90,35% | 95,02% | 53,54% | 87,92% | 100,00% | 78,40% |
| | 29 | 46,86% | 86,10% | 94,52% | 48,37% | 71,29% | 75,74% | 5,26% | 90,30% | 38,01% |
| | | 44,06% | 72,02% | 93,82% | 50,43% | 70,60% | 74,17% | 3,15% | 90,09% | 34,39% |
| | | 42,90% | 71,97% | 93,68% | 48,07% | 71,16% | 78,31% | 2,69% | 88,96% | 32,40% |
| | | 41,61% | 63,23% | 93,52% | 51,50% | 70,00% | 74,17% | 2,75% | 89,22% | 31,01% |

El paciente 29 obtiene una tasa inferior al 50%. Asimismo, en el paciente 28 la clase tumor fue mejor identificada, sin embargo, el porcentaje del *accuracy* disminuye por los valores de sensibilidad y de especificidad del resto de clases.

En los pacientes 15 y 25 se mantiene la tasa de acierto, pero el valor de sensibilidad de la clase tumor mejora. No se establece un patrón fijo, además el *accuracy* del paciente 22 alcanza el 43,84%.

Por último, se presentan los valores obtenidos con las diferentes métricas de evaluación de la técnica ss3. Donde, se utiliza la técnica de los k-vecinos más cercanos o K-NN, con un k de 500.

Tabla 5.6. Tabla de resultados obtenidos en ss3.

| Experiment Type | ID | O. A. (%) | Specificity (%) | | | | Sensitivity (%) | | | |
|-----------------|----|---------------|-----------------|---------|---------|--------|-----------------|--------|---------|---------|
| | | | N | T | BV | B | N | T | BV | B |
| SS3 (K-NN) | 12 | 82,84% | 86,69% | 99,49% | 87,14% | 98,74% | 97,24% | 1,88% | 89,82% | 88,71% |
| | | 83,09% | 87,09% | 99,50% | 87,11% | 98,78% | 97,33% | 1,83% | 90,13% | 89,17% |
| | | 83,33% | 87,41% | 99,50% | 87,17% | 98,85% | 97,47% | 1,83% | 90,00% | 90,11% |
| | | 83,78% | 88,11% | 99,50% | 87,17% | 98,86% | 97,49% | 1,70% | 91,06% | 90,38% |
| | 15 | 72,40% | 68,86% | 100,00% | 99,90% | 97,77% | 94,48% | 5,03% | 95,01% | 97,84% |
| | | 72,26% | 68,70% | 100,00% | 99,90% | 97,76% | 94,48% | 4,50% | 95,01% | 97,84% |
| | | 71,70% | 68,07% | 100,00% | 100,00% | 97,65% | 94,48% | 2,54% | 94,89% | 97,84% |
| | | 71,46% | 67,77% | 100,00% | 100,00% | 97,64% | 94,48% | 1,52% | 94,91% | 97,84% |
| | 20 | 57,47% | 60,34% | 100,00% | 98,68% | 65,25% | 95,06% | 1,26% | 73,69% | 100,00% |
| | | 57,07% | 52,89% | 100,00% | 98,60% | 79,72% | 94,79% | 0,19% | 74,09% | 100,00% |
| | | 94,74% | 95,21% | 99,98% | 98,83% | 99,40% | 92,83% | 99,45% | 76,54% | 100,00% |
| | | 56,96% | 48,77% | 100,00% | 98,49% | 95,24% | 94,46% | 0,00% | 74,22% | 100,00% |
| | 22 | 34,96% | 99,72% | 56,30% | 64,62% | 35,53% | 4,37% | 0,00% | 100,00% | 96,36% |
| | | 35,43% | 99,72% | 51,47% | 68,04% | 41,83% | 5,07% | 0,00% | 100,00% | 96,38% |
| | | 35,79% | 99,68% | 48,22% | 67,98% | 51,00% | 5,69% | 0,00% | 100,00% | 96,14% |
| | | 35,79% | 99,68% | 44,86% | 72,41% | 57,72% | 5,69% | 0,00% | 100,00% | 96,14% |
| | 25 | 73,12% | 99,85% | 76,64% | 100,00% | 78,86% | 97,44% | 91,89% | 39,91% | 68,32% |
| | | 74,49% | 99,83% | 77,08% | 100,00% | 81,86% | 98,77% | 91,89% | 48,84% | 68,32% |
| | | 74,62% | 99,83% | 77,12% | 100,00% | 82,15% | 98,98% | 91,89% | 49,61% | 68,32% |
| | | 74,70% | 99,78% | 77,14% | 100,00% | 82,36% | 99,49% | 91,89% | 49,61% | 68,32% |
| | 28 | 99,31% | 99,75% | 100,00% | 100,00% | 97,23% | 100,00% | 89,84% | 100,00% | 100,00% |
| | | 99,34% | 99,76% | 100,00% | 100,00% | 97,40% | 100,00% | 90,36% | 100,00% | 100,00% |
| | | 99,34% | 99,75% | 100,00% | 100,00% | 97,44% | 100,00% | 90,36% | 100,00% | 100,00% |
| | | 99,34% | 99,71% | 100,00% | 100,00% | 97,63% | 100,00% | 90,36% | 100,00% | 99,99% |
| | 29 | 55,35% | 65,66% | 84,94% | 96,15% | 74,74% | 51,57% | 20,88% | 96,32% | 50,78% |
| | | 51,74% | 65,13% | 78,29% | 97,92% | 73,33% | 8,06% | 23,97% | 98,77% | 50,61% |
| | | 53,82% | 67,40% | 78,86% | 98,26% | 75,04% | 6,01% | 27,69% | 99,55% | 53,37% |
| | | 57,24% | 70,96% | 80,44% | 98,36% | 76,52% | 6,24% | 31,58% | 99,85% | 57,87% |

En general, los resultados mostrados en la Tabla 5.6 de los porcentajes de sensibilidad en la clase tumor aumentan con respecto a las otras técnicas de estudio. El paciente 29 mejora con respecto a ss2, el 25 obtiene un porcentaje del 91,89% para la sensibilidad de la clase tumor. No obstante, se mantiene la media del *accuracy* con respecto al método ss1 y ss2. Finalmente, para los pacientes 15, 20 y 22 los valores de la tasa de acierto son similares a los alcanzados en las Tabla 5.3, Tabla 5.4 y Tabla 5.5.

5.3.1. Comparativa

A continuación, se muestran unas tablas comparativas con los resultados obtenidos en las diferentes técnicas propuestas de especificidad y sensibilidad de cada una de las clases.

Para la clase tumor, en el caso de estudio 3 (CS3), se obtienen unos valores bajos de sensibilidad. Sin embargo, esta métrica se logra mejorar con alguna de las técnicas de clasificación semi-supervisada planteadas.

En la Tabla 5.7, se observa cómo la técnica que mejor resultados alcanza para esta clase es la denominada CS4, donde los datos del paciente actual se añaden con etiquetas ya conocidas. Si se analizan los resultados de CS4, se concluye que a medida que se aumenta el porcentaje de muestras del paciente actual en la clasificación el valor de sensibilidad para esta clase también aumenta. Por tanto, los mejores resultados se logran cuando se añade el máximo de datos.

Para cuando los datos del paciente actual son añadidos con un enfoque semi-supervisado, las mejoras no tienen un patrón tan definido. No obstante, con alguno de los métodos propuestos se consiguen mejores resultados que los conseguidos en CS3. En el paciente 20, se pasa de una sensibilidad del 3,53% obtenida en CS3 a una sensibilidad del 99,18% en ss1 (*Cosine*), del 98,36% en ss2 y del 99,45% en ss3. En ss1 con distancia Euclídea, no se consigue mejorar el porcentaje de sensibilidad de la clase tumor para este paciente.

En particular con la técnica ss1, el incremento de la sensibilidad para la clase tumor solo se consigue aplicando la distancia Euclídea con el 10% en el paciente 12 y con el 40% en el 15. Mientras que, con la distancia del coseno, las mejoras se logran para los porcentajes del 10% y 20% del paciente 15 y del 30% del paciente 20.

Con ss2, ocurre que en los pacientes 12, 15, 28 y 29 no se consigue un aumento de la sensibilidad con ninguno de los porcentajes seleccionados. Sin embargo, en el paciente 15 y 20 si se alcanzan valores más altos. En esta técnica al igual que ss1, no se cumple que al añadir un mayor porcentaje del paciente actual se progrese en los valores de sensibilidad.

Tabla 5.7. Tabla comparativa resultados especificidad y sensibilidad clase Tumor (CS3, CS4, ss1, ss2 y ss3).

| Patient ID | Method | Tumour Specificity | | | | Tumour Sensitivity | | | |
|------------|----------------|------------------------------|---------|---------|---------|------------------------------|--------|--------|--------|
| | | Samples from current patient | | | | Samples from current patient | | | |
| | | 10% | 20% | 30% | 40% | 10% | 20% | 30% | 40% |
| 12 | CS3 | 99,65% | | | | 1,68% | | | |
| | CS4 | 99,72% | 99,77% | 99,80% | 99,84% | 6,29% | 14,08% | 28,15% | 50,74% |
| | ss1(Cosine) | 99,63% | 99,61% | 99,58% | 99,58% | 1,30% | 0,95% | 0,55% | 0,45% |
| | ss1(Euclidea) | 99,39% | 99,30% | 99,25% | 99,16% | 1,73% | 1,23% | 0,80% | 0,50% |
| | ss2 | 99,67% | 99,68% | 99,70% | 99,71% | 0,33% | 0,28% | 0,10% | 0,08% |
| | ss3 | 99,49% | 99,50% | 99,50% | 99,50% | 1,88% | 1,83% | 1,83% | 1,70% |
| 15 | CS3 | 100,00% | | | | 6,35% | | | |
| | CS4 | 100,00% | 100,00% | 100,00% | 100,00% | 12,21% | 20,36% | 33,12% | 45,01% |
| | ss1(Cosine) | 100,00% | 100,00% | 100,00% | 100,00% | 6,55% | 6,45% | 6,16% | 5,87% |
| | ss1(Euclidean) | 100,00% | 100,00% | 100,00% | 100,00% | 7,28% | 8,65% | 9,58% | 10,56% |
| | ss2 | 100,00% | 100,00% | 100,00% | 100,00% | 6,79% | 6,84% | 6,70% | 6,55% |
| | ss3 | 100,00% | 100,00% | 100,00% | 100,00% | 5,03% | 4,50% | 2,54% | 1,52% |
| 20 | CS3 | 100,00% | | | | 3,53% | | | |
| | CS4 | 100,00% | 100,00% | 100,00% | 100,00% | 16,84% | 47,60% | 78,51% | 92,52% |
| | ss1 (Cosine) | 100,00% | 100,00% | 100,00% | 100,00% | 1,61% | 0,55% | 99,18% | 0,03% |
| | ss1 (Euclidea) | 100,00% | 100,00% | 100,00% | 100,00% | 2,46% | 1,67% | 1,15% | 0,57% |
| | ss2 | 100,00% | 100,00% | 100,00% | 100,00% | 3,34% | 3,34% | 98,36% | 3,37% |
| | ss3 | 100,00% | 100,00% | 99,98% | 100,00% | 1,26% | 0,19% | 99,45% | 0,00% |
| 22 | CS3 | 77,44% | | | | 0,00% | | | |
| | CS4 | 92,80% | 97,37% | 98,42% | 98,83% | 0,00% | 0,00% | 0,00% | 0,00% |
| | ss1(Cosine) | 65,92% | 56,49% | 56,49% | 52,27% | 0,00% | 0,00% | 0,00% | 0,00% |
| | ss1(Euclidea) | 74,71% | 69,29% | 77,92% | 86,03% | 0,00% | 0,00% | 0,00% | 0,00% |
| | ss2 | 94,69% | 94,27% | 84,52% | 81,77% | 0,00% | 0,00% | 0,00% | 0,00% |
| | ss3 | 56,30% | 51,47% | 48,22% | 44,86% | 0,00% | 0,00% | 0,00% | 0,00% |
| 25 | CS3 | 75,97% | | | | 91,19% | | | |
| | CS4 | 76,02% | 76,27% | 76,36% | 76,45% | 94,36% | 96,79% | 97,66% | 98,27% |
| | ss1(Cosine) | 76,55% | 77,08% | 77,40% | 77,51% | 87,29% | 73,09% | 59,75% | 51,72% |
| | ss1(Euclidea) | 76,53% | 77,08% | 77,39% | 77,47% | 85,34% | 72,15% | 59,28% | 51,25% |
| | ss2 | 76,42% | 77,33% | 79,06% | 83,36% | 89,86% | 76,29% | 59,75% | 33,07% |
| | ss3 | 76,64% | 77,08% | 77,12% | 77,14% | 91,89% | 91,89% | 91,89% | 91,89% |
| 28 | CS3 | 100,00% | | | | 88,23% | | | |
| | CS4 | 100,00% | 100,00% | 100,00% | 100,00% | 88,83% | 89,70% | 90,51% | 90,97% |
| | ss1(Cosine) | 100,00% | 100,00% | 100,00% | 100,00% | 86,82% | 83,18% | 80,94% | 81,15% |
| | ss1(Euclidea) | 100,00% | 100,00% | 100,00% | 100,00% | 86,51% | 83,65% | 80,99% | 81,30% |
| | ss2 | 99,57% | 98,74% | 99,41% | 99,21% | 87,45% | 87,40% | 87,55% | 87,92% |
| | ss3 | 100,00% | 100,00% | 100,00% | 100,00% | 89,84% | 90,36% | 90,36% | 90,36% |
| 29 | CS3 | 98,29% | | | | 18,94% | | | |
| | CS4 | 99,73% | 99,88% | 99,92% | 99,94% | 30,96% | 43,04% | 54,48% | 67,39% |
| | ss1(Cosine) | 98,93% | 99,41% | 99,52% | 99,67% | 13,84% | 7,44% | 3,95% | 3,09% |
| | ss1(Euclidea) | 98,68% | 99,26% | 99,55% | 99,58% | 12,47% | 10,93% | 10,87% | 12,36% |
| | ss2 | 94,52% | 93,82% | 93,68% | 93,52% | 5,26% | 3,15% | 2,69% | 2,75% |
| | ss3 | 84,94% | 78,29% | 78,86% | 80,44% | 20,88% | 23,97% | 27,69% | 31,58% |

Por último, con la técnica de ss3 las mejoras se obtienen al incrementar los porcentajes en el paciente 28 y 29. En el 25 se mantiene la sensibilidad para cada uno de los porcentajes. En el paciente 20, ocurre un suceso aislado donde con el 20% se obtiene una sensibilidad del 0,19% pero con el 30% del paciente actual se alcanza un 99,45%, cayendo esta probabilidad con el 40% a una sensibilidad de 0.

En el resto de los pacientes se obtienen los mejores resultados al añadir al clasificador el porcentaje más bajo del paciente actual, si se incrementa este porcentaje, la sensibilidad para esta clase también disminuye. Esto se debe a que al realizar la generación automática de etiquetas con la técnica de semi-supervisado, los píxeles fueron erróneamente identificados. Siendo por consiguiente las muestras mal etiquetadas. Es por ello, por lo que, al añadir más porcentaje del paciente actual en la clasificación, la sensibilidad de la clase tumor empeora.

A modo de comparativa en la Figura 5.6 y Figura 5.7 se muestran los resultados de especificidad y sensibilidad de la clase tumor con el 40% de los datos del paciente actual para cada una de las técnicas aplicadas.

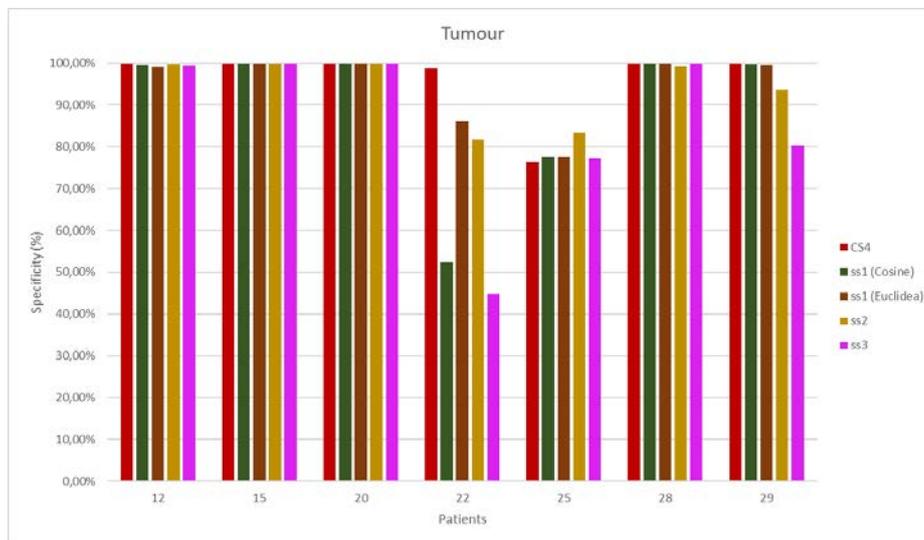


Figura 5.6. Gráfica comparativa de especificidad de la clase tumor con el 40% de los datos del paciente actual para CS4, ss1 (Cosine), ss1 (Euclidea), ss2 y ss3.

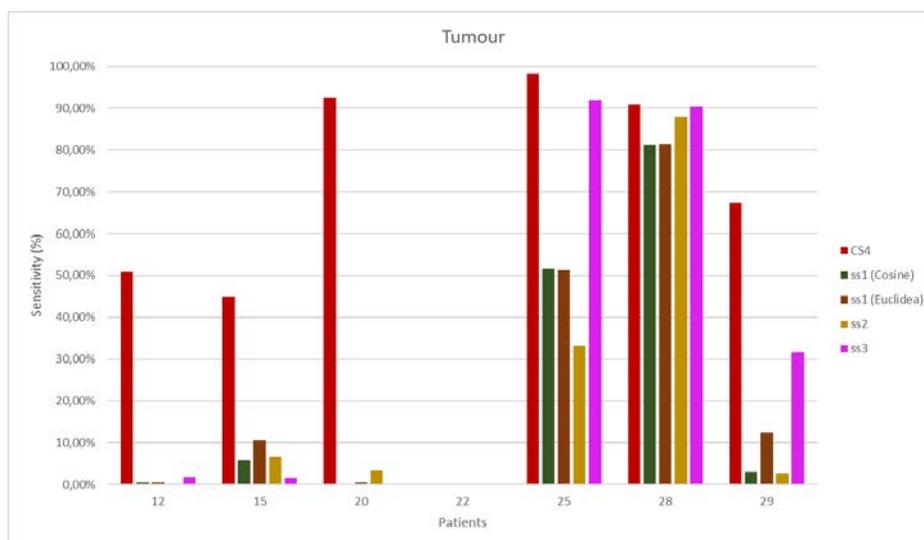


Figura 5.7. Gráfica comparativa de sensibilidad de la clase tumor con el 40% de los datos del paciente actual para CS4, ss1 (Cosine), ss1 (Euclidea), ss2 y ss3.

Por otro lado, en la Tabla 5.8, se muestran los resultados para la clase tejido normal sano, donde casi todas las técnicas logran mejorar los valores de sensibilidad. En los pacientes 22, 25 y 28, a medida que se aumentan los porcentajes del paciente actual se mejoran los resultados de sensibilidad. Sin embargo, para el resto de las pacientes no ocurren lo mismo, aunque se logra mejorar los porcentajes obtenidos con esta métrica de evaluación.

Con respecto a los valores de especificidad para las clases tumor y tejido normal, se puede observar que los resultados dependen de numerosos factores como de la técnica aplicada o del paciente objeto de estudio.

Finalmente, en las Tabla 5.9 y Tabla 5.10 se muestran los valores obtenidos para la clase *blood vessel* y *background*.

Tabla 5.8. Tabla comparativa resultados especificidad y sensibilidad clase Tejido normal (CS3, CS4, ss1, ss2 y ss3).

| Patient ID | Method | Normal Specificity | | | | Normal Sensitivity | | | |
|------------|----------------|------------------------------|--------|--------|--------|------------------------------|---------|---------|---------|
| | | Samples from current patient | | | | Samples from current patient | | | |
| | | 10% | 20% | 30% | 40% | 10% | 20% | 30% | 40% |
| 12 | CS3 | 85,78% | | | | 97,21% | | | |
| | CS4 | 88,90% | 91,16% | 92,82% | 93,96% | 97,53% | 97,80% | 98,01% | 98,16% |
| | ss1(Cosine) | 85,30% | 85,50% | 85,81% | 86,34% | 97,24% | 97,37% | 97,47% | 97,56% |
| | ss1(Euclidean) | 86,60% | 87,03% | 87,71% | 87,71% | 97,10% | 96,88% | 96,00% | 96,00% |
| | ss2 | 83,68% | 80,25% | 78,22% | 76,07% | 96,81% | 96,12% | 95,47% | 94,97% |
| | ss3 | 86,69% | 87,09% | 87,41% | 88,11% | 97,24% | 97,33% | 97,47% | 97,49% |
| 15 | CS3 | 69,26% | | | | 94,48% | | | |
| | CS4 | 71,16% | 73,75% | 77,69% | 81,34% | 95,38% | 95,38% | 95,65% | 95,74% |
| | ss1(Cosine) | 69,30% | 69,26% | 69,17% | 69,10% | 94,24% | 94,08% | 93,84% | 93,69% |
| | ss1(Euclidean) | 69,54% | 69,97% | 70,27% | 70,57% | 94,40% | 94,00% | 94,00% | 93,92% |
| | ss2 | 69,57% | 69,63% | 69,64% | 69,63% | 94,24% | 94,08% | 94,00% | 94,00% |
| | ss3 | 68,86% | 68,70% | 68,07% | 67,77% | 94,48% | 94,48% | 94,48% | 94,48% |
| 20 | CS3 | 69,32% | | | | 95,06% | | | |
| | CS4 | 82,07% | 89,99% | 92,84% | 93,88% | 94,93% | 94,87% | 94,87% | 94,75% |
| | ss1 (Cosine) | 68,54% | 67,52% | 94,97% | 66,80% | 95,01% | 94,95% | 92,78% | 94,41% |
| | ss1(Euclidean) | 68,15% | 66,74% | 65,69% | 64,55% | 95,06% | 94,90% | 94,90% | 94,90% |
| | ss2 | 75,05% | 79,92% | 95,10% | 87,71% | 95,39% | 95,98% | 94,30% | 96,58% |
| | ss3 | 60,34% | 52,89% | 95,21% | 48,77% | 95,06% | 94,79% | 92,83% | 94,46% |
| 22 | CS3 | 99,72% | | | | 3,84% | | | |
| | CS4 | 99,69% | 99,56% | 99,50% | 99,48% | 63,42% | 84,99% | 92,04% | 94,90% |
| | ss1(Cosine) | 99,72% | 99,74% | 99,74% | 99,70% | 4,42% | 5,23% | 5,23% | 6,49% |
| | ss1(Euclidean) | 99,72% | 99,70% | 99,74% | 99,72% | 4,30% | 4,92% | 5,44% | 5,92% |
| | ss2 | 99,70% | 99,68% | 99,64% | 99,59% | 4,58% | 6,75% | 10,08% | 17,68% |
| | ss3 | 99,72% | 99,72% | 99,68% | 99,68% | 4,37% | 5,07% | 5,69% | 5,69% |
| 25 | CS3 | 99,92% | | | | 94,78% | | | |
| | CS4 | 99,94% | 99,95% | 99,92% | 99,92% | 96,25% | 97,84% | 98,30% | 98,75% |
| | ss1(Cosine) | 99,85% | 99,16% | 98,39% | 97,48% | 97,34% | 98,46% | 98,57% | 98,77% |
| | ss1(Euclidean) | 99,92% | 99,57% | 98,83% | 97,75% | 96,11% | 97,75% | 98,46% | 98,57% |
| | ss2 | 99,95% | 99,97% | 99,97% | 99,97% | 96,72% | 98,36% | 98,77% | 98,36% |
| | ss3 | 99,85% | 99,83% | 99,83% | 99,78% | 97,44% | 98,77% | 98,98% | 99,49% |
| 28 | CS3 | 99,68% | | | | 80,13% | | | |
| | CS4 | 99,71% | 99,76% | 99,80% | 99,82% | 99,73% | 100,00% | 100,00% | 100,00% |
| | ss1(Cosine) | 99,64% | 99,50% | 99,34% | 99,25% | 95,28% | 100,00% | 100,00% | 100,00% |
| | ss1(Euclidean) | 99,64% | 99,50% | 99,35% | 99,25% | 96,37% | 100,00% | 100,00% | 100,00% |
| | ss2 | 68,05% | 64,67% | 77,92% | 83,50% | 57,34% | 55,09% | 53,19% | 53,54% |
| | ss3 | 99,75% | 99,76% | 99,75% | 99,71% | 100,00% | 100,00% | 100,00% | 100,00% |
| 29 | CS3 | 92,01% | | | | 84,32% | | | |
| | CS4 | 98,76% | 99,23% | 99,47% | 99,61% | 91,27% | 92,96% | 94,12% | 94,65% |
| | ss1(Cosine) | 92,98% | 93,48% | 93,62% | 98,22% | 90,85% | 94,66% | 95,76% | 92,18% |
| | ss1(Euclidean) | 94,59% | 97,93% | 99,01% | 99,12% | 89,42% | 91,56% | 88,80% | 81,79% |
| | ss2 | 86,10% | 72,02% | 71,97% | 63,23% | 75,74% | 74,17% | 78,31% | 74,17% |
| | ss3 | 65,66% | 65,13% | 67,40% | 70,96% | 51,57% | 8,06% | 6,01% | 6,24% |

Tabla 5.9. Tabla comparativa resultados especificidad y sensibilidad clase Blood Vessel (CS3, CS4, ss1, ss2 y ss3).

| Patient ID | Method | Blood Vessel Specificity | | | | Blood Vessel Sensitivity | | | |
|------------|---------------|------------------------------|---------|---------|---------|------------------------------|---------|---------|---------|
| | | Samples from current patient | | | | Samples from current patient | | | |
| | | 10% | 20% | 30% | 40% | 10% | 20% | 30% | 40% |
| 12 | CS3 | 87,24% | | | | 88,58% | | | |
| | CS4 | 87,14% | 87,85% | 89,77% | 93,26% | 91,59% | 93,46% | 94,75% | 95,51% |
| | ss1(Cosine) | 87,18% | 87,16% | 87,17% | 87,19% | 88,83% | 89,85% | 90,86% | 91,96% |
| | ss1(Euclidea) | 87,15% | 87,10% | 87,05% | 87,01% | 89,74% | 90,74% | 91,65% | 92,52% |
| | ss2 | 87,73% | 87,91% | 87,89% | 87,80% | 85,91% | 80,30% | 78,16% | 75,15% |
| | ss3 | 87,14% | 87,11% | 87,17% | 87,17% | 89,82% | 90,13% | 90,00% | 91,06% |
| 15 | CS3 | 99,85% | | | | 94,96% | | | |
| | CS4 | 99,90% | 99,81% | 99,83% | 99,84% | 95,35% | 95,57% | 95,87% | 96,06% |
| | ss1(Cosine) | 99,95% | 100,00% | 100,00% | 100,00% | 94,96% | 94,94% | 94,96% | 94,96% |
| | ss1(Euclidea) | 99,95% | 99,90% | 99,90% | 99,90% | 95,01% | 94,99% | 94,99% | 94,96% |
| | ss2 | 100,00% | 100,00% | 99,85% | 99,70% | 95,28% | 95,35% | 95,21% | 95,11% |
| | ss3 | 99,90% | 99,90% | 100,00% | 100,00% | 95,01% | 95,01% | 94,89% | 94,91% |
| 20 | CS3 | 98,71% | | | | 73,69% | | | |
| | CS4 | 98,81% | 99,01% | 99,16% | 99,19% | 73,62% | 73,84% | 73,99% | 74,06% |
| | ss1(Cosine) | 98,69% | 98,68% | 98,87% | 98,49% | 73,69% | 73,69% | 75,88% | 74,36% |
| | ss1(Euclidea) | 98,70% | 98,69% | 98,68% | 98,68% | 73,69% | 73,69% | 73,69% | 73,96% |
| | ss2 | 98,86% | 99,12% | 99,19% | 99,41% | 74,55% | 75,48% | 78,52% | 77,33% |
| | ss3 | 98,68% | 98,60% | 98,83% | 98,49% | 73,69% | 74,09% | 76,54% | 74,22% |
| 22 | CS3 | 98,61% | | | | 100,00% | | | |
| | CS4 | 99,78% | 99,99% | 100,00% | 100,00% | 100,00% | 100,00% | 100,00% | 100,00% |
| | ss1(Cosine) | 98,63% | 98,67% | 98,67% | 98,24% | 100,00% | 100,00% | 100,00% | 100,00% |
| | ss1(Euclidea) | 98,63% | 99,25% | 99,93% | 99,95% | 100,00% | 100,00% | 100,00% | 100,00% |
| | ss2 | 94,08% | 76,96% | 51,21% | 54,34% | 100,00% | 100,00% | 100,00% | 100,00% |
| | ss3 | 64,62% | 68,04% | 67,98% | 72,41% | 100,00% | 100,00% | 100,00% | 100,00% |
| 25 | CS3 | 100,00% | | | | 26,35% | | | |
| | CS4 | 100,00% | 100,00% | 100,00% | 100,00% | 33,29% | 38,31% | 40,51% | 41,98% |
| | ss1(Cosine) | 100,00% | 100,00% | 100,00% | 100,00% | 37,71% | 49,17% | 56,12% | 58,32% |
| | ss1(Euclidea) | 100,00% | 100,00% | 100,00% | 100,00% | 37,71% | 49,17% | 56,12% | 57,55% |
| | ss2 | 100,00% | 100,00% | 100,00% | 100,00% | 34,51% | 32,30% | 29,33% | 29,00% |
| | ss3 | 100,00% | 100,00% | 100,00% | 100,00% | 39,91% | 48,84% | 49,61% | 49,61% |
| 28 | CS3 | 97,98% | | | | 100,00% | | | |
| | CS4 | 99,97% | 100,00% | 100,00% | 100,00% | 98,48% | 71,21% | 51,52% | 27,27% |
| | ss1(Cosine) | 99,52% | 100,00% | 100,00% | 100,00% | 100,00% | 100,00% | 94,52% | 100,00% |
| | ss1(Euclidea) | 99,63% | 100,00% | 100,00% | 100,00% | 100,00% | 100,00% | 97,26% | 100,00% |
| | ss2 | 88,04% | 86,50% | 88,66% | 90,35% | 8,22% | 1,37% | 21,92% | 100,00% |
| | ss3 | 100,00% | 100,00% | 100,00% | 100,00% | 100,00% | 100,00% | 100,00% | 100,00% |
| 29 | CS3 | 62,11% | | | | 97,61% | | | |
| | CS4 | 99,80% | 99,91% | 99,96% | 99,96% | 99,50% | 99,67% | 99,80% | 99,83% |
| | ss1(Cosine) | 62,68% | 63,15% | 63,88% | 68,06% | 98,38% | 98,29% | 98,23% | 98,50% |
| | ss1(Euclidea) | 62,93% | 65,29% | 67,89% | 67,91% | 97,79% | 98,17% | 98,32% | 98,05% |
| | ss2 | 48,37% | 50,43% | 48,07% | 51,50% | 90,30% | 90,09% | 88,96% | 89,22% |
| | ss3 | 96,15% | 97,92% | 98,26% | 98,36% | 96,32% | 98,77% | 99,55% | 99,85% |

Tabla 5.10. Tabla comparativa resultados especificidad y sensibilidad clase Background (CS3, CS4, ss1, ss2 y ss3).

| Patient ID | Method | Background Specificity | | | | Background Sensitivity | | | |
|------------|----------------|------------------------------|--------|--------|--------|------------------------------|---------|---------|---------|
| | | Samples from current patient | | | | Samples from current patient | | | |
| | | 10% | 20% | 30% | 40% | 10% | 20% | 30% | 40% |
| 12 | CS3 | 98,72% | | | | 88,90% | | | |
| | CS4 | 98,89% | 99,04% | 99,15% | 99,25% | 90,20% | 91,48% | 92,34% | 93,11% |
| | ss1(Cosine) | 98,74% | 98,80% | 98,85% | 98,90% | 87,52% | 86,71% | 86,22% | 86,06% |
| | ss1(Euclidean) | 98,68% | 98,58% | 98,33% | 98,18% | 88,43% | 88,03% | 87,60% | 87,11% |
| | ss2 | 98,50% | 98,11% | 97,77% | 97,48% | 89,13% | 88,94% | 87,20% | 86,10% |
| | ss3 | 98,74% | 98,78% | 98,85% | 98,86% | 88,71% | 89,17% | 90,11% | 90,38% |
| 15 | CS3 | 97,74% | | | | 97,84% | | | |
| | CS4 | 98,12% | 98,22% | 98,49% | 98,62% | 97,60% | 97,60% | 97,60% | 97,60% |
| | ss1(Cosine) | 97,69% | 97,63% | 97,59% | 97,53% | 97,84% | 97,84% | 97,84% | 97,84% |
| | ss1(Euclidean) | 97,75% | 97,63% | 97,64% | 97,59% | 97,84% | 97,84% | 97,99% | 97,99% |
| | ss2 | 97,68% | 97,64% | 97,42% | 97,32% | 97,84% | 97,84% | 97,84% | 97,99% |
| | ss3 | 97,77% | 97,76% | 97,65% | 97,64% | 97,84% | 97,84% | 97,84% | 97,84% |
| 20 | CS3 | 57,17% | | | | 100,00% | | | |
| | CS4 | 57,97% | 72,64% | 89,09% | 96,38% | 100,00% | 100,00% | 100,00% | 100,00% |
| | ss1(Cosine) | 56,16% | 56,09% | 99,31% | 56,41% | 100,00% | 100,00% | 100,00% | 100,00% |
| | ss1(Euclidean) | 57,28% | 57,82% | 58,38% | 59,14% | 100,00% | 100,00% | 100,00% | 100,00% |
| | ss2 | 53,03% | 50,59% | 99,34% | 47,74% | 100,00% | 100,00% | 100,00% | 99,96% |
| | ss3 | 65,25% | 79,72% | 99,40% | 95,24% | 100,00% | 100,00% | 100,00% | 100,00% |
| 22 | CS3 | 19,33% | | | | 96,60% | | | |
| | CS4 | 72,83% | 88,38% | 93,49% | 95,56% | 96,59% | 96,44% | 96,53% | 96,68% |
| | ss1(Cosine) | 22,58% | 27,82% | 27,82% | 33,58% | 96,82% | 96,95% | 96,95% | 97,28% |
| | ss1(Euclidean) | 20,28% | 22,13% | 20,81% | 20,03% | 96,46% | 96,38% | 96,79% | 96,87% |
| | ss2 | 18,22% | 22,07% | 38,98% | 54,98% | 97,04% | 96,95% | 96,60% | 96,49% |
| | ss3 | 35,53% | 41,83% | 51,00% | 57,72% | 96,36% | 96,38% | 96,14% | 96,14% |
| 25 | CS3 | 73,79% | | | | 68,38% | | | |
| | CS4 | 77,49% | 80,41% | 81,56% | 82,37% | 67,93% | 67,87% | 67,84% | 67,84% |
| | ss1(Cosine) | 76,33% | 74,85% | 72,10% | 70,26% | 68,32% | 68,32% | 68,38% | 68,40% |
| | ss1(Euclidean) | 75,09% | 73,86% | 71,48% | 69,52% | 68,38% | 68,38% | 68,38% | 68,40% |
| | ss2 | 76,17% | 70,52% | 63,10% | 52,07% | 68,38% | 69,62% | 72,06% | 77,84% |
| | ss3 | 78,86% | 81,86% | 82,15% | 82,36% | 68,32% | 68,32% | 68,32% | 68,32% |
| 28 | CS3 | 96,51% | | | | 100,00% | | | |
| | CS4 | 96,98% | 96,67% | 96,51% | 96,22% | 100,00% | 100,00% | 100,00% | 100,00% |
| | ss1(Cosine) | 96,46% | 95,81% | 95,61% | 96,21% | 100,00% | 100,00% | 100,00% | 99,98% |
| | ss1(Euclidean) | 96,36% | 96,03% | 95,63% | 96,26% | 100,00% | 100,00% | 100,00% | 99,98% |
| | ss2 | 91,93% | 78,14% | 89,76% | 95,02% | 62,07% | 56,41% | 71,65% | 78,40% |
| | ss3 | 97,23% | 97,40% | 97,44% | 97,63% | 100,00% | 100,00% | 100,00% | 99,99% |
| 29 | CS3 | 76,97% | | | | 52,68% | | | |
| | CS4 | 81,02% | 84,21% | 87,31% | 90,59% | 98,21% | 98,92% | 99,26% | 99,45% |
| | ss1(Cosine) | 77,10% | 75,99% | 75,34% | 74,10% | 53,67% | 54,57% | 55,53% | 62,85% |
| | ss1(Euclidean) | 76,50% | 76,23% | 75,10% | 73,27% | 54,96% | 59,32% | 62,98% | 63,35% |
| | ss2 | 71,29% | 70,60% | 71,16% | 70,00% | 38,01% | 34,39% | 32,40% | 31,01% |
| | ss3 | 74,74% | 73,33% | 75,04% | 76,52% | 50,78% | 50,61% | 53,37% | 57,87% |

5.4. Resumen

En este capítulo, se parte del caso CS3, el cual se intenta mejorar aplicando técnicas de clasificación semi-supervisada. Para ello, se plantearon dos métodos distintos: añadir los datos del paciente actual con etiquetas conocidas o con una generación automática de ellas. Este último método fue probado con tres formas distintas de generar etiquetas de manera automática ss1, ss2 y ss3.

Tras realizar un análisis de los datos obtenidos se obtuvo que, si a CS3 se le añadían los datos del paciente actual con etiquetas conocidas (nuevo caso de estudio planteado denominado CS4) se mejoraban los datos en la clasificación. Si los datos del paciente actual eran añadidos con una generación automática de etiquetas estos resultados mejoraban, pero no con una gran diferencia.

CAPÍTULO 6.

6. CONCLUSIONES Y LÍNEAS FUTURAS

Acorde al problema expuesto, el objetivo de este Trabajo Fin de Grado era el diseñar un sistema de clasificación semi-supervisado. Para ello, se utilizaron una serie de muestras de pacientes aleatorios ya clasificadas (Capítulo 3), donde se cuantificaron las mejoras de cada técnica propuesta. Asimismo, anteriormente se realizó un estudio de los diferentes escenarios propuestos.

Para la evaluación se ha empleado el clasificador SVM. Los casos de estudio que se analizaron son el CS1, caso en el que se evita la variabilidad-inter paciente, el CS2, donde se parte de un bloque de datos únicos y el CS3, caso que más se ajusta a la realidad de una operación quirúrgica, pues se entrena el clasificador con un bloque de pacientes y se testea con un paciente que el modelo generado desconoce. Posteriormente, en busca de la mejora de este último escenario, se plantean dos formas distintas de llevar a cabo la clasificación. Por un lado, se entrena el clasificador con los datos del paciente actual con etiquetas ya conocidas. Por otro lado, se proponen tres métodos distintos para la generación automática de dichas etiquetas a partir de los datos espectrales del paciente actual.

6.1. Conclusiones

En los capítulos 4 y 5 tras analizar los resultados con las diferentes métricas de evaluación se concluye que, el CS1 es el escenario que tiene las tasas de acierto más elevadas, esto se debe a que al evaluar el clasificador con los pacientes de forma independiente se evita la variabilidad inter-paciente. El caso contrario, ocurre para CS2 y CS3, donde en CS3 se disminuían considerablemente los valores del *accuracy*. El peor resultado fue el obtenido en el paciente 22, con una tasa del 34,66%. Sin embargo, esta tasa se mejoró al añadir tan solo el 10% de los datos del paciente actual con etiquetas conocidas, donde se logra una tasa de acierto del 71,31%.

En el cuarto caso de estudio, CS4, los resultados obtenidos mejoraban con respecto a los otros tres casos de estudio, al añadir muestras del propio paciente a la clasificación.

En los métodos propuestos denominados, ss1, ss2 y ss3 al generar las etiquetas del paciente actual de forma automática, podía ocurrir que las muestras fueran mal etiquetadas. De forma que, al añadir un mayor porcentaje del paciente actual a la clasificación, los valores de la sensibilidad o la tasa de acierto empeoraban, siendo difícil encontrar un patrón definido entre los distintos métodos aplicados.

A continuación, en la Tabla 6.1, se muestran los valores del *accuracy* obtenidos para cada paciente en los diferentes casos de estudio. El CS4, es el que alcanza mejores porcentajes con esta métrica.

En cuanto a los clasificadores semi-supervisados, se puede deducir que para el método de ss1, la distancia con la que se obtienen mejores resultados de tasa de acierto es la Euclídea. Con este cálculo de distancia el paciente 15 y 29 logran mejorar su tasa de acierto del 72,70% en CS3 al 73,69% y del 59,76% al 66,63% respectivamente.

Los mejores resultados para los pacientes 12, 25 y 28 se obtienen con la técnica de ss3, con unos porcentajes del 73,69%, del 74,70% y finalmente, del 99,34%. Si estos valores se comparan con los obtenidos para el caso de CS3 que fueron un 72,70%, un 70,84% y un 97,20%, se comprueba que efectivamente se ha conseguido mejorar ese tercer escenario de estudio.

Para los pacientes 20 y 22 los mejores resultados se producen en ss2, logrando pasar del 58,33% en CS3 al 94,91% y de un 34,66% a un 43,84%. Para el método de ss1 con cálculo de distancia coseno, aunque se producen unas mejoras con respecto a CS3, el resto de las técnicas supera su porcentaje.

En el capítulo 5, se identificó además una peculiaridad en el paciente 22 y es que con ninguno de los métodos nombrados anteriormente se consiguió identificar la clase tumor, siendo el porcentaje de sensibilidad del 0%.

Tras detectar este caso particular se hizo un análisis más exhaustivo de este paciente. Se deduce, que esto podría ocurrir porque el número de píxeles correspondientes a esta clase tumor eran de menor cantidad con respecto al resto de clases. Siendo solo 96 píxeles para esta clase.

Tabla 6.1. Tabla comparativa Overall Accuracy de CS3, CS4, ss1, ss2 y ss3.

| Patient ID | Method | Overall Accuracy | | | |
|------------|-----------------|------------------------------|--------|--------|--------|
| | | Samples from current patient | | | |
| | | 10% | 40% | 60% | 80% |
| 12 | CS3 | 82,41% | | | |
| | CS4 | 84,39% | 86,26% | 88,41% | 91,17% |
| | ss1(Cosine) | 82,11% | 82,28% | 82,51% | 82,89% |
| | ss1(Euclidean) | 82,69% | 82,84% | 82,87% | 82,94% |
| | ss2 | 81,24% | 78,94% | 77,51% | 72,84% |
| | ss3 | 82,84% | 83,09% | 83,33% | 83,78% |
| 15 | CS3 | 72,70% | | | |
| | CS4 | 74,50% | 76,67% | 80,09% | 83,21% |
| | ss1(Cosine) | 72,72% | 72,66% | 72,56% | 72,46% |
| | ss1(Euclidean) | 72,95% | 73,22% | 73,47% | 73,69% |
| | ss2 | 72,94% | 72,96% | 72,84% | 72,77% |
| | ss3 | 72,40% | 72,26% | 71,70% | 71,46% |
| 20 | CS3 | 58,33% | | | |
| | CS4 | 63,34% | 92,09% | 94,49% | 94,73% |
| | ss1(Cosine) | 57,59% | 57,18% | 94,52% | 56,98% |
| | ss1(Euclidean) | 57,92% | 57,59% | 57,39% | 57,22% |
| | ss2 | 58,45% | 58,71% | 94,91% | 59,12% |
| | ss3 | 57,47% | 57,07% | 94,74% | 56,96% |
| 22 | CS3 | 34,66% | | | |
| | CS4 | 74,31% | 95,28% | 96,86% | 97,56% |
| | ss1 (Cosine) | 35,09% | 35,66% | 36,36% | 36,58% |
| | ss1 (Euclidean) | 34,93% | 35,33% | 35,76% | 36,10% |
| | ss2 | 35,25% | 36,67% | 38,81% | 43,84% |
| | ss3 | 34,96% | 35,43% | 35,79% | 35,79% |
| 25 | CS3 | 70,84% | | | |
| | CS4 | 72,33% | 75,51% | 75,24% | 75,78% |
| | ss1 (Cosine) | 71,95% | 70,98% | 69,44% | 68,28% |
| | ss1 (Euclidean) | 71,44% | 70,73% | 69,34% | 68,06% |
| | ss2 | 71,95% | 70,03% | 67,91% | 65,93% |
| | ss3 | 73,12% | 74,49% | 74,62% | 74,70% |
| 28 | CS3 | 97,20% | | | |
| | CS4 | 99,21% | 99,20% | 99,22% | 99,26% |
| | ss1 (Cosine) | 98,63% | 98,63% | 98,69% | 98,70% |
| | ss1 (Euclidean) | 98,72% | 98,89% | 98,70% | 98,71% |
| | ss2 | 63,19% | 58,24% | 70,75% | 76,60% |
| | ss3 | 99,31% | 99,34% | 99,34% | 99,34% |
| 29 | CS3 | 59,76% | | | |
| | CS4 | 92,46% | 96,53% | 98,29% | 98,87% |
| | ss1 (Cosine) | 60,77% | 61,22% | 61,69% | 66,28% |
| | ss1 (Euclidean) | 61,31% | 64,39% | 66,63% | 66,30% |
| | ss2 | 46,86% | 44,06% | 42,90% | 41,61% |
| | ss3 | 55,35% | 51,74% | 53,82% | 57,24% |

Los resultados comentados anteriormente se presentan de forma gráfica en la Figura 7.1.

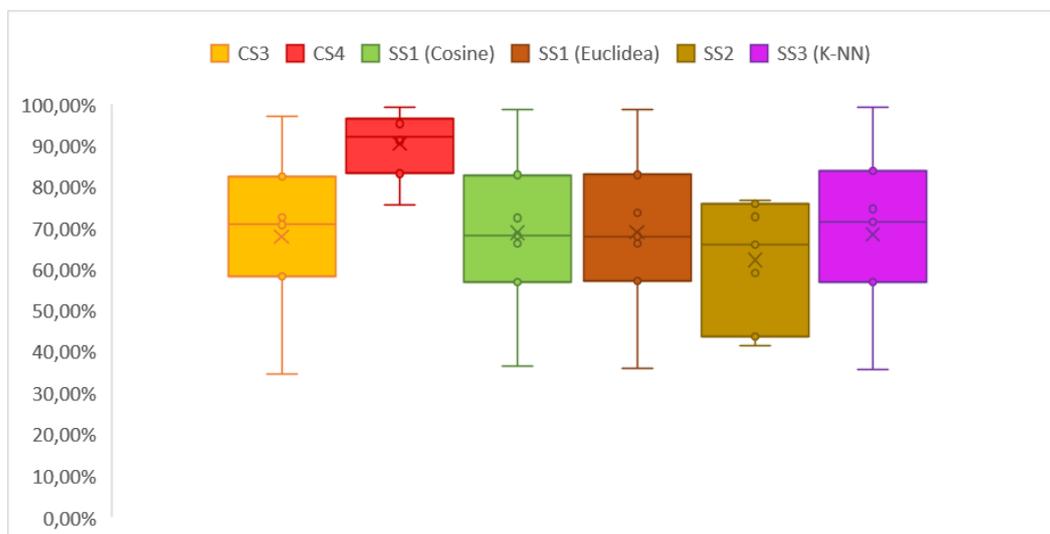


Figura 7.1. Diagrama de caja para la tasa de acierto de CS3, CS4, ss1 (Cosine), ss1(Euclidea), ss2 y ss3 (K-NN).

Además, para los resultados obtenidos en la clasificación, por ejemplo, para este mismo paciente (paciente 22) de toda la base de datos solo hay otro paciente diagnosticado con el mismo tipo de tumor, *Anaplastic oligodendroglioma (Grade III)*. Ese paciente es el 29, ambos con un tumor primario. No obstante, la diferencia del número de píxeles de la clase tumor es alta, el paciente 22 constaba solo con 96 píxeles de tumor mientras que el paciente 29 poseía un total de 1748, por lo que identificar la clase tumor en este paciente alcanzó porcentajes más altos.

También las capturas realizadas al inicio de este proceso jugaban un importante papel, donde al paciente 22 se le realizaron un total de 3 capturas. Si se observa la Figura 6.1, en la primera captura que se realizó es difícil identificar la zona del tumor debido a que se encuentra la zona cubierta por la membrana aracnoidea cerebral.

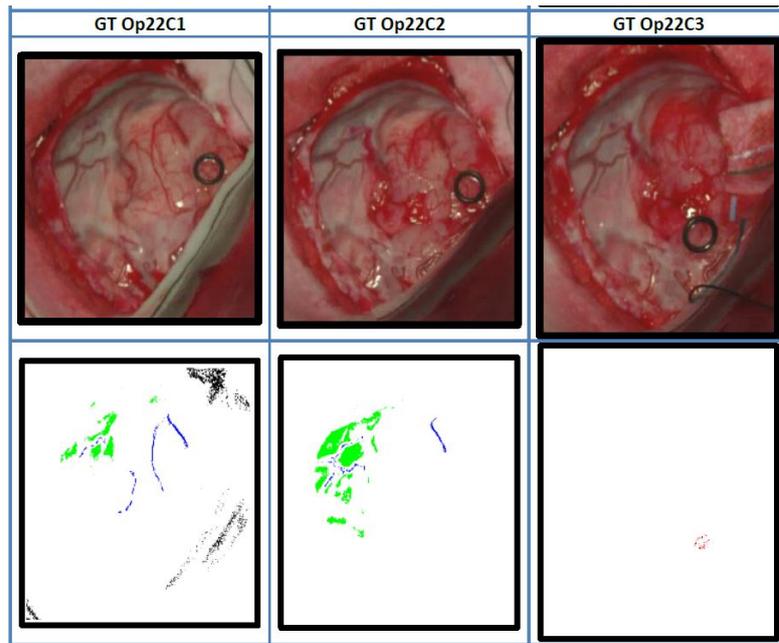


Figura 6.1. Capturas y ground truth maps correspondientes al paciente 22.

Por otro lado, en esta misma imagen se puede observar el *ground Truth Map* generado para cada una de las capturas. Tal y como se puede ver, los píxeles de tumor son los identificados en color rojo (Op22C3, parte inferior). Esta identificación se hace casi despreciable si se compara, por ejemplo, con el *ground truth map* del paciente 29 (ver Figura 6.2), donde los píxeles de tumor (color rojo) se encuentran en una mayor cantidad y por lo tanto la sensibilidad para dicho paciente aumenta.

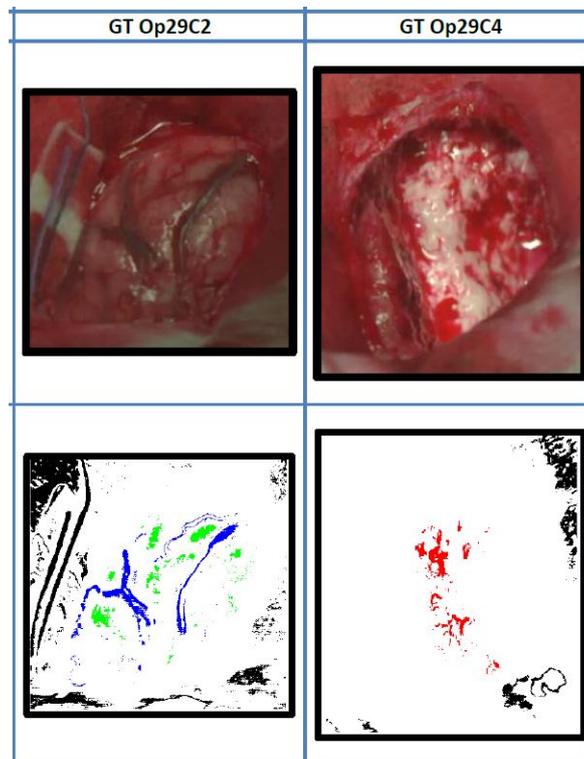


Figura 6.2. Capturas y ground truth maps correspondientes al paciente 29.

6.2. Líneas futuras

Se proponen varias líneas futuras para este TFG. Por un lado, se propone la posibilidad de realizar una búsqueda más exhaustiva de un algoritmo semi-supervisado más robusto, de tal forma que se consiga una mejora en la identificación del tejido tumoral.

Otra línea es seguir con el trabajo de mejorar las técnicas ya propuestas en este TFG para el apartado en el que se propone la generación automática de etiquetas.

Asimismo, sería de especial interés ampliar la base de datos empleada, es decir, probar las técnicas aplicadas con nuevas muestras de pacientes para así analizar los resultados obtenidos para estas nuevas muestras quirúrgicas.

Finalmente, se plantea evaluar estas técnicas con diferentes tipos de clasificadores, como por ejemplo las ANN, de tal forma, que se puedan estudiar las variaciones de los resultados obtenidos al cambiar el clasificador.

PARTE II:
BIBLIOGRAFÍA

BIBLIOGRAFÍA

- [1] Pedro Pérez Segura, "Tumores Cerebrales," *SEOM (Sociedad Española de Oncología Médica)*, 2017. [Online]. Available: <https://www.seom.org/es/info-sobre-el-cancer/tumores-cerebrales?showall=1>. [Accessed: 28-Jan-2018].
- [2] N. I. of Health, "Tumores Cerebrales," *MedlinePlus*, 2018. [Online]. Available: <https://medlineplus.gov/spanish/braintumors.html>. [Accessed: 28-Jan-2018].
- [3] "REDECAN - Estimaciones de la Incidencia y la Supervivencia del Cáncer en España y su Situación en Europa." [Online]. Available: <http://redcan.org/es/page.cfm?id=196&title=estimaciones-de-la-incidencia-y-la-supervivencia-del-cancer-en-espana-y-su-situacion-en-europa>. [Accessed: 28-Jan-2018].
- [4] "Canarias registra cada año 6.868 nuevos casos de cáncer," *Diario de Avisos*, 2017. [Online]. Available: <http://diariodeavisos.elespanol.com/2017/02/canarias-registra-ano-6-868-nuevos-casos-cancer/>. [Accessed: 28-Jan-2018].
- [5] "En Canarias se detectan cada año casi 7.000 tumores malignos - La Provincia - Diario de Las Palmas," *La Provincia, Diario de Las Palmas*, 2017. [Online]. Available: <http://www.laprovincia.es/sociedad/2017/02/03/canarias-detectan-ano-7000-tumores/905509.html>. [Accessed: 28-Jan-2018].
- [6] "Detectar tumores cerebrales - OCPL NIH," *NIH, National Institutes of Health*, 2017. [Online]. Available: <https://salud.nih.gov/articulo/detectar-tumores-cerebrales/>. [Accessed: 28-Jan-2018].
- [7] Tom Halkin, "A New "America's Neuro-Oncologist" at the National Cancer Institute - News & Blog | National Brain Tumor Society," *National Brain Tumor Society*, 2014. [Online]. Available: <http://blog.braintumor.org/new-americas-neuro-oncologist-national-cancer-institute/>. [Accessed: 28-Jan-2018].
- [8] H. Li, H. Zheng, C. Han, H. Wang, and M. Min, "Spectral and Spatial Cloud Detection Onboard for Hyperspectral Remote Sensing Image," no. May, pp.

- 1–19, 2017.
- [9] T. Grippa, M. Lennert, B. Beaumont, S. Vanhuysse, N. Stephenne, and E. Wolff, “An open-source semi-automated processing chain for urban object-based classification,” *Remote Sens.*, vol. 9, no. 4, 2017.
- [10] Y. Fu *et al.*, “An Improved Combination of Spectral and Spatial Features for Vegetation Classification in Hyperspectral Images,” *Remote Sens.*, vol. 9, no. 12, p. 261, Mar. 2017.
- [11] S. Schneider, R. J. Murphy, and A. Melkumyan, “Evaluating the performance of a new classifier – the GP-OAD: A comparison with existing methods for classifying rock type and mineralogy from hyperspectral imagery,” *ISPRS J. Photogramm. Remote Sens.*, vol. 98, pp. 145–156, Dec. 2014.
- [12] “Hyperspectral image maps | Business Queensland.” [Online]. Available: <https://www.business.qld.gov.au/industries/mining-energy-water/resources/geoscience-information/digital-data/hyperspectral-image-maps>. [Accessed: 25-Feb-2018].
- [13] A. Ramoelo and M. Cho, “Explaining Leaf Nitrogen Distribution in a Semi-Arid Environment Predicted on Sentinel-2 Imagery Using a Field Spectroscopy Derived Model,” *Remote Sens.*, vol. 10, no. 2, p. 269, 2018.
- [14] Z. He, Y. Wang, and J. Hu, “Joint Sparse and Low-Rank Multitask Learning with Laplacian-Like Regularization for Hyperspectral Classification,” *Remote Sens.*, vol. 10, no. 2, p. 322, 2018.
- [15] S. Salehi *et al.*, “Integration of Vessel-Based Hyperspectral Scanning and 3D-Photogrammetry for Mobile Mapping of Steep Coastal Cliffs in the Arctic,” *Remote Sens.*, vol. 10, no. 2, p. 175, 2018.
- [16] M. Larnicol, P. Launeau, and P. Gernez, “Using High-Resolution Airborne Data to Evaluate MERIS Atmospheric Correction and Intra-Pixel Variability in Nearshore Turbid Waters,” *Remote Sens.*, vol. 10, no. 2, p. 274, 2018.
- [17] “Conservemos nuestro litoral | Programa "Educación ambiental" |

- Consejería de Educación y Universidades | Gobierno de Canarias.” [Online]. Available: <http://www.gobiernodecanarias.org/educacion/web/programas-redes-educativas/programas-educativos/educa-ambiental/medio-natural-canario/nuestrolitoral.html>. [Accessed: 25-Feb-2018].
- [18] “Aplicaciones de la visión hiperespectral en la industria cárnica - Envase y embalaje.” [Online]. Available: <https://www.interempresas.net/Envase/Articulos/149980-Aplicaciones-en-la-industria-carnica-de-la-vision-hiperespectral.html>. [Accessed: 25-Feb-2018].
- [19] M. Kamruzzaman, Y. Makino, and S. Oshita, “Online monitoring of red meat color using hyperspectral imaging,” *Meat Sci.*, vol. 116, pp. 110–117, 2016.
- [20] H. Jiang, W. Wang, H. Zhuang, S. Yoon, Y. Li, and Y. Yang, “Visible and Near-Infrared Hyperspectral Imaging for Cooking Loss Classification of Fresh Broiler Breast Fillets,” *Appl. Sci.*, vol. 8, no. 2, p. 256, 2018.
- [21] T.-L. Kammies, M. Manley, P. A. Gouws, and P. J. Williams, “Differentiation of foodborne bacteria using NIR hyperspectral imaging and multivariate data analysis,” *Appl. Microbiol. Biotechnol.*, vol. 100, no. 21, pp. 9305–9320, 2016.
- [22] N. Caporaso, M. B. Whitworth, and I. D. Fisk, “Protein content prediction in single wheat kernels using hyperspectral imaging,” *Food Chem.*, vol. 240, pp. 32–42, 2018.
- [23] H. Eksi-Kocak, O. Menten-Yilmaz, and I. H. Boyaci, “Detection of green pea adulteration in pistachio nut granules by using Raman hyperspectral imaging,” *Eur. Food Res. Technol.*, vol. 242, no. 2, pp. 271–277, 2016.
- [24] D. A. P. Forchetti and R. J. Poppi, “Use of NIR hyperspectral imaging and multivariate curve resolution (MCR) for detection and quantification of adulterants in milk powder,” *LWT - Food Sci. Technol.*, vol. 76, pp. 337–343, 2017.
- [25] W. Hong *et al.*, “In situ Detection of a Single Bacterium in Complex Environment by Hyperspectral CARS Imaging,” *ChemistrySelect*, vol. 1, no. 3, pp. 513–517, 2016.

- [26] S. Zhu *et al.*, "Identification of cancerous gastric cells based on common features extracted from hyperspectral microscopic images," *Biomed. Opt. Express*, vol. 6, no. 4, p. 1135, 2015.
- [27] C. Wang, W. Zheng, Y. Bu, S. Chang, S. Zhang, and R. X. Xu, "Multi-scale hyperspectral imaging of cervical neoplasia," *Arch. Gynecol. Obstet.*, vol. 293, no. 6, pp. 1309–1317, 2016.
- [28] H.-M. Chen *et al.*, "A Hyperspectral Imaging Approach to White Matter Hyperintensities Detection in Brain Magnetic Resonance Images," *Remote Sens.*, vol. 9, no. 12, p. 1174, 2017.
- [29] G. R. EDOARDO RAPOSIO, WALTER PATERNICH and P. S. CLAUDIA PORZIO, ILARIA BALDELLI, MAURO TRUINI, "Quali-Quantitative analysis in the spectrophotometric diagnosis of cutaneo melanoma."
- [30] Y.-M. Chen *et al.*, "Non-invasive assessment of cellulitis from snapshot hyperspectral imaging - A primary study," *Ski. Res. Technol.*, no. January, pp. 1–4, 2018.
- [31] M. A. Calin, S. V. Parasca, M. R. Calin, and E. Petrescu, "An Analysis of Human Dorsal Hand Skin Texture Using Hyperspectral Imaging Technique for Assessing the Skin Aging Process," *Appl. Spectrosc.*, vol. 0, no. 0, pp. 1–10, 2016.
- [32] Gary Shaw and Dimitris Manolakis, "Signal Processing for Hyperespectral Image Exploitation," pp. 12–16, 2002.
- [33] D.-W. Sun, *Hyperspectral imaging for food quality analysis and control*. Academic, 2010.
- [34] A. Roman-Gonzalez and N. I. Vargas-Cuentas, "Análisis de imágenes hiperespectrales."
- [35] "La resolución espacial." [Online]. Available: <http://www.teledet.com.uy/tutorial-imagenes-satelitales/satelites-resolucion-espacial.htm>. [Accessed: 03-Dec-2018].

- [36] “QUE ES MACHINE LEARNING - Definición y características - IIEMD.” [Online]. Available: <https://iiemd.com/machine-learning/que-es-machine-learning>. [Accessed: 03-Dec-2018].
- [37] S. Shalev-Shwartz and S. Ben-David, *Understanding Machine Learning*. Cambridge: Cambridge University Press, 2014.
- [38] “Aprendizaje Supervisado - MATLAB & Simulink.” [Online]. Available: <https://es.mathworks.com/discovery/aprendizaje-supervisado.html>. [Accessed: 03-Dec-2018].
- [39] A. Pedro Duarte Silva, “Optimization approaches to Supervised Classification,” *Eur. J. Oper. Res.*, vol. 261, no. 2, pp. 772–788, Sep. 2017.
- [40] “Weblet Importer.” [Online]. Available: <https://www.deeplearningbook.org/contents/ml.html>. [Accessed: 03-Dec-2018].
- [41] M. P. S. Brown *et al.*, “Knowledge-based analysis of microarray gene expression data by using support vector machines.”
- [42] R. por, J. José Martín Guareño Supervisado por, and R. DE Blanquero Bravo Emilio Carrizosa Priego FACULTAD MATEMÁTICAS, “TRABAJO FIN DE GRADO SUPPORT VECTOR REGRESSION: PROPIEDADES Y APLICACIONES.”
- [43] “Máquina de vectores de soporte (SVM) - MATLAB & Simulink.” [Online]. Available: <https://es.mathworks.com/discovery/svm-maquina-vectores-soporte.html>. [Accessed: 03-Dec-2018].
- [44] D. Bertsimas and J. Dunn, “Optimal classification trees,” *Mach. Learn.*, vol. 106, no. 7, pp. 1039–1082, Jul. 2017.
- [45] W. Buntine, “Learning classification trees,” *Stat. Comput.*, vol. 2, no. 2, pp. 63–73, Jun. 1992.
- [46] H. Galán and A. Martínez, “Inteligencia artificial . Redes neuronales y aplicaciones,” p. 8, 2006.

-
- [47] P. Kim, *MATLAB Deep Learning*. Berkeley, CA: Apress, 2017.
- [48] T. Robles, V. Ramón, A. Garrido, D. Martín, A. Borja, and B. Sánchez, “MATLAB aplicado a la ingeniería telemática MATLAB aplicado al Big Data.”
- [49] A. Mucherino, P. J. Papajorgji, and P. M. Pardalos, “k-Nearest Neighbor Classification,” 2009, pp. 83–106.
- [50] Z.-H. Zhou and M. Li, “Semi-supervised learning by disagreement,” *Knowl Inf Syst*, vol. 24, pp. 415–439, 2010.
- [51] A. Z. Olivier Chapelle, Bernhard Schölkopf, *A semi-supervised learning*, vol. 1, no. 2. 2009.
- [52] H. Fabelo *et al.*, “An intraoperative visualization system using hyperspectral imaging to aid in brain tumor delineation,” *Sensors (Switzerland)*, vol. 18, no. 2, 2018.
- [53] T. Fin and A. H. Guedes, “Máster en Tecnologías de Telecomunicación Trabajo Fin de Máster.”
- [54] P. Algorithms, C. Detection, and H. I. Deliverable, “Figure 4-1: Data capture and labelling process.,” vol. 2, pp. 33–52, 2016.
- [55] H. Fabelo *et al.*, “Spatio-spectral classification of hyperspectral images for brain cancer detection during surgical operations,” *PLoS One*, vol. 13, no. 3, p. e0193721, Mar. 2018.
- [56] “LIBSVM -- A Library for Support Vector Machines.” [Online]. Available: <https://www.csie.ntu.edu.tw/~cjlin/libsvm/>. [Accessed: 03-Dec-2018].
- [57] J. A. Westerhuis *et al.*, “Assessment of PLS-DA cross validation,” *Metabolomics*, vol. 4, no. 1, pp. 81–89, Mar. 2008.
- [58] *Data Mining: Practical Machine Learning Tools and Techniques*. Elsevier, 2011.
- [59] R. Kohavi, “A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection,” 1995.

- [60] O. Caelen, "A Bayesian interpretation of the confusion matrix," *Ann. Math. Artif. Intell.*, vol. 81, no. 3–4, pp. 429–450, Dec. 2017.
- [61] S. Ruuska, W. Hämmäläinen, S. Kajava, M. Mughal, P. Matilainen, and J. Mononen, "Evaluation of the confusion matrix method in the validation of an automated system for measuring feeding behaviour of cattle," *Behav. Processes*, vol. 148, pp. 56–62, Mar. 2018.
- [62] H. Imaging and C. Detection, "6-1: c," vol. 2, pp. 99–104, 2016.
- [63] X. Wang, S. Yang, Y. Zhao, and Y. Wang, "Lithology identification using an optimized KNN clustering method based on entropy-weighted cosine distance in Mesozoic strata of Gaoqing field, Jiyang depression," *J. Pet. Sci. Eng.*, vol. 166, pp. 157–174, Jul. 2018.
- [64] A. Akusok *et al.*, "ELMVIS+: Fast nonlinear visualization technique based on cosine distance and extreme learning machines," *Neurocomputing*, vol. 205, pp. 247–263, Sep. 2016.

PARTE III:
PLIEGO DE CONDICIONES

PLIEGO DE CONDICIONES

En este pliego de condiciones se presentan las condiciones necesarias para replicar los resultados de este Trabajo Fin de Grado. Se describe el conjunto de componentes tanto *software* como *hardware* que se necesitaron para el desarrollo del TFG.

PI.1 Recursos hardware

- Hyperspec VNIR A-Series: cubre el rango espectral que va desde 400 a 1000 nm. Es capaz de capturar 826 bandas espectrales y 1004 píxeles espaciales.
- Hyperspec NIR 100/U: cubre el rango espectral de 900 a 1700 nm., posee 172 canales espectrales y 320 píxeles espaciales.
- Ordenador de sobremesa (DESKTOP-II2N35): con un procesador Intel Core i5-800K, 16 GB de RAM y 6 núcleos.
- Ordenador portátil (LAPTOP-U91C0M06): con un procesador Intel Core i5-7200U, 8GB de RAM y 2 núcleos.
- Ordenador de sobremesa (gtx760): con un procesador Intel Core i7-4770K, 16 GB de RAM y 6 núcleos.

PI.2 Recursos software

- Matlab 2015b: Herramienta de *software* matemática un lenguaje de programación propio que permite el análisis y la visualización de datos.
- Microsoft Office 2018: paquete informático empleado para la redacción del TFG.

PARTE IV:
PRESUPUESTO

PRESUPUESTO

El presupuesto para este Trabajo Fin de Grado ha sido valorado en función de la lista de Honorarios Orientativos publicada por el Colegio Oficial de Ingenieros Técnicos de Telecomunicación (COITT en el año 2008). El presupuesto se ha estructurado en las siguientes secciones:

1. Trabajo tarifado por tiempo empleado
2. Amortización del inmovilizado material
3. Redacción del TFG
4. Derechos de visado del COITT
5. Gastos de tramitación y envío

Una vez concluido cada uno de los criterios establecidos, se aplicarán los impuestos vigentes y se procederá a la obtención del coste total de este trabajo.

P.1. Trabajo tarifado por tiempo empleado

En esta sección se cubren los gastos de la mano de obra según el salario correspondiente a la hora de trabajo de un graduado en ingeniería en telecomunicación y siguiendo las recomendaciones del COITT. Se propone emplear la ecuación (P.1).

$$\text{Honorarios(€)} = H_n \cdot 14,48 + H_e \cdot 20,27 \quad (\text{P.1})$$

Donde:

- H_n son las horas realizadas en jornada laboral.
- H_e son las horas extra trabajadas.

Para la realización de este TFG se han invertido un total de 300 horas, y todas ellas realizadas dentro de la jornada laboral, por lo que el número de horas extra es cero. Los honorarios totales se calcularon de la forma mostrada en la ecuación (P.2).

$$\text{Honorarios(€)} = 300 \cdot 14,48 + 0 \cdot 20,27 = 4344,00€ \quad (\text{P.2})$$

Finalmente, el trabajo tarifado por tiempo empleado asciende a *cuatro mil trescientos cuarenta y cuatro euros*.

P.2. Amortización del inmovilizado material

En este concepto se tienen en cuenta tanto los recursos hardware como los recursos software empleados para la realización del TFG. Se estipula el coste de amortización para un período de 5 años utilizando un sistema de amortización lineal, en el que se supone que el inmovilizado material se desprecia de forma constante a lo largo de su vida útil. La cuota de amortización anual se calcula mediante la expresión (P.3).

$$Cuota\ anual = \frac{Valor\ de\ adquisición - Valor\ residual}{Años\ de\ vida\ útil} \quad (P.3)$$

P.2.1. Amortización del material hardware

Dado que la duración de este TFG es de 4 meses y es inferior al período de 3 años estipulado para el coste de amortización, los costes serán los derivados de los primeros 4 meses. En la Tabla P.1 se muestra el *hardware* necesario para la realización de este trabajo, indicando para cada elemento su valor de adquisición, valor residual y el coste de amortización.

Tabla P.1. Amortización del material hardware.

| Elemento Hardware | Valor de adquisición | Valor residual | Coste de amortización para el periodo del TFG |
|-------------------------|----------------------|----------------|---|
| Hyperspec VNIR A-Series | 40.000,00 € | 20.000,00 € | 1.666,67 € |
| Hyperspec NIR 100/U | 80.000,00 € | 40.000,00 € | 3.333,33 € |
| LAPTOP-U91C0M06 | 600,86 € | 150,00 € | 38,00€ |
| DESKTOP-I12N35 | 1.386,96 € | 347,00 € | 87,00 € |
| Ordenador GTX760 | 1.386,96 € | 347,00 € | 87,00€ |
| Lenovo G510 | 600,00 € | 150,00 € | 38,00€ |
| Total | | | 5.248,42 € |

El coste total del material *hardware* es de *cinco mil doscientos cuarenta y ocho euros con cuarenta y dos céntimos*.

P.2.2. Amortización del material software

Para el cálculo de los costes de amortización del material *software* también se tendrán en consideración los costes derivados de los primeros cuatro meses. En la Tabla P.2 se presentan los elementos *software* necesarios para la realización de

este trabajo, así como su valor de adquisición, el valor residual y el coste de amortización.

Tabla P.2. Amortización del material software.

| Elemento Software | Valor de adquisición | Valor residual | Coste de amortización para el periodo del TFG |
|------------------------------|----------------------|----------------|---|
| Sistema operativo Windows 10 | 0 € | 0 € | 0 € |
| Matlab 2015b | 2.000,00 € | 0 € | 166,67€ |
| Microsoft Word 2018 | 0 € | 0 € | 0 € |
| Total | | | 166,67 € |

Por tanto, el coste total del material *software* asciende a la cantidad es de *ciento sesenta y seis euros con sesenta y siete céntimos*.

P.3. Redacción del proyecto

Los costes de redacción de la memoria de este trabajo se determinan mediante la ecuación (P.4).

$$R = 0.05 \cdot P \cdot C_n \quad (P.4)$$

Donde:

- R son los honorarios para la redacción del trabajo.
- P es el presupuesto.
- C_n el coeficiente de ponderación en función del coste del presupuesto.

En cuanto al coeficiente de ponderación C_n , debido a que el TFG no supera los 30.050,00€, tiene el valor unidad.

El valor del presupuesto P se calcula sumando los costes de las secciones anteriores correspondientes al trabajo tarifado por tiempo empleado y a la amortización del inmovilizado material, tanto del hardware como del software. Esta suma de los costes se presenta en la Tabla P.3.

Tabla P.3. Presupuesto total de los costes de redacción del TFG.

| Concepto | Coste |
|--|------------|
| Trabajo tarifado por tiempo empleado (H) | 4.344,00 € |
| Amortización del material Hardware | 5.248,42 € |
| Amortización del material Software | 166,67 € |
| P | 9.759,09 € |
| Redacción del trabajo (R) | 487,95 € |

El coste correspondiente a la redacción del proyecto asciende a *cuatrocientos ochenta y siete euros con noventa y cinco céntimos*.

P.4. Derechos de visado del COITT

El COITT establece que, para los proyectos técnicas de carácter general, los derechos de visado en el 2017 se calculan mediante la expresión (P.5).

$$V = 0.0035 \cdot P \cdot C \quad (P.5)$$

Donde V es el coste de visado por trabajo, P se corresponde con el presupuesto del proyecto y C es el coeficiente reductor en función del presupuesto, cuyo valor es igual a la unidad debido a que el presente trabajo no supera los 30.050,00€. Por tanto, el presupuesto del visado del COITT para este TFG se muestra en la Tabla P.4.

Tabla P.4. Presupuesto con los derechos de visado del COITT.

| Concepto | Coste |
|--|------------|
| Trabajo tarifado por tiempo empleado (H) | 4.344,00 € |
| Amortización del material Hardware | 5.248,42 € |
| Amortización del material Software | 166,67 € |
| Redacción del trabajo (R) | 487,95 € |
| P | 10.247,04€ |
| Derechos de visado del COITT (V) | 35,86 € |

Los costes por derechos del visado de COITT ascienden a *treinta y cinco euros con ochenta y seis céntimos*

P.5. Gastos de tramitación y envío

Los gastos de envío y tramitación están estipulados en *seis euros (6,00€)* por cada documento visado de forma telemática.

P.6. Material fungible

Además de los materiales *hardware* y *software*, también se han empleado otros materiales como folios, impresora, cd, etc. que quedan englobados como material fungible. En la Tabla P.5 se muestran los costes de estos recursos.

Tabla P.5. Presupuesto del material fungible.

| Concepto | Unidades | Precio/unidad | Total |
|--|----------|---------------|---------|
| Fotocopias a color DinA4 | 39 | 0,15 | 5,85 € |
| Fotocopias en blanco y negro DinA4 | 110 | 0,25 | 27,50 € |
| Encuadernación | 1 | 5 | 5,00 € |
| Impresión etiqueta de CD | 3 | 1 | 3,00 € |
| Copia CD | 3 | 3 | 9,00 € |
| CDs | 3 | 1 | 3,00 € |
| Total de los costes de material fungible | | | 53,35 € |

El coste del material fungible es de *cincuenta y tres euros con treinta y cinco céntimos*.

P.7. Aplicación de impuestos y coste total

A la actividad económica de este proyecto se le debe aplicar el Impuesto General Indirecto Canario (IGIC), el cuál grava el presupuesto con un 7%. El coste total del proyecto se muestra en la Tabla P.6.

Tabla P.6. Aplicación de impuestos y coste total.

| Concepto | Coste |
|--|-------------|
| Trabajo tarifado por tiempo empleado (H) | 4.344,00 € |
| Amortización del material Hardware | 5.248,42 € |
| Amortización del material Software | 166,67 € |
| Redacción del trabajo (R) | 487,95 € |
| Derechos de visado del COITT (V) | 35,86 € |
| Gastos de tramitación y envío | 6,00 € |
| Costes de material fungible | 53,35 € |
| Total sin IGIC | 10.342,26 € |
| IGIC (7%) | 723,96 € |
| Total con IGIC | 11.066,22 € |

D^a Patricia Beltrán Alonso declara que el presupuesto total del proyecto “Análisis del efecto de la variabilidad inter-paciente en la clasificación supervisada de tumores cerebrales usando imágenes hiperespectrales. Mejora de prestaciones mediante algoritmos semi-supervisados” asciende a *once mil sesenta y seis euros con veintidós céntimos*.

Fdo: Patricia Beltrán Alonso

En Las Palmas de Gran Canaria a 13 de diciembre de 2018