



UNIVERSIDAD DE GUANAJUATO

CAMPUS IRAPUATO - SALAMANCA
DIVISIÓN DE INGENIERÍAS

*"Hacia una Detección Más Precisa de la Enfermedad de
Parkinson: Comparativa de Algoritmos de Aprendizaje
Automático"*

TESIS

Que para obtener el Grado de
Maestría en Ingeniería Eléctrica

PRESENTA:

Ing. Francisco Javier Castro Sánchez

DIRECTORES:

Dr. Mario Alberto Ibarra Manzano

Dra. Dora Luz Almanza Ojeda

Salamanca, Guanajuato,

Diciembre, 2024

Dedicatoria

A mi madre y padre por apoyarme en mi educación y crecimiento profesional y en especial a mi querida abuela Rosa Alicia Gracias por tu paciencia, por enseñarme el camino de la vida, gracias por tus consejos, por el amor que me diste y por tu apoyo incondicional.

Agradecimientos

Primeramente doy gracias a Dios y a la Virgen por permitirme llegar tan lejos, brindarme salud y siempre guiarme en momentos difíciles, a mi familia que siempre han seguido mi camino en el trascender de esta vida, mis padres Nubia Esperanza y José Esteban los cuales siempre han sido fuente de fortaleza y Constancia, a mis hermanos Leidy Tibisay, Abel Esteban, Maryori Nohelia e Indira Roselin por su apoyo y enseñanzas, a mis sobrinos Javier Esteban, Dylan Isaac y Samanara Sofia por siempre ser ser inspiración y motivación para seguir adelante, por recordarme que la vida es un regalo. Su deseo de aprender y valentía me han recordado la belleza de la vida.

De igual manera quiero agradecer a las personas que me motivaron en esta nueva etapa de mi vida Vianney Guerra, Ing. Yefferson Correa y en especial a la Mtra. Grecia Carolina Duque Jiménez, a mis compañeros de estudio, Salvador Ramos, Areli Oros, Julissa Ramírez, Diego, Michael Chacon, Jesús Parada. Para finalizar a mis asesores Dr. Mario Ibarra Manzano y la Dra. Dora Luz Almanza por darme su confianza y siempre brindarme su conocimiento.

Agradecimientos Institucionales

Expreso mi más sincera gratitud hacia la Universidad de Guanajuato, especialmente a la División de Ingenierías del Campus Irapuato-Salamanca (DICIS) por la formación académica y por el apoyo financiero que he recibido durante mis estudios en esta institución.



Este trabajo de tesis fue realizado gracias al apoyo invaluable recibido a través del Consejo Nacional de Humanidades, Ciencias y Tecnologías, CONAHCYT de México, bajo el número de becario CVU 1275739.



CONAHCYT
CONSEJO NACIONAL DE HUMANIDADES
CIENCIAS Y TECNOLOGÍAS

Índice General

Dedicatoria	i
Agradecimientos	ii
Agradecimientos institucionales	iii
Índice de Figuras	vii
Índice de Tablas	x
Resumen	x
Abstract	xiii
1 Introducción	2
1.1 Planteamiento del problema	2

1.2	Justificación	4
1.3	Antecedentes	5
1.4	Objetivos	6
1.4.1	Objetivos específicos	6
1.5	Hipótesis	6
1.6	Organización de la tesis	7
2	Estado del Arte	8
2.1	Métodos de detección de la Enfermedad de Parkinson	8
2.2	Diagnósticos por imágenes	10
2.3	Detección del Parkinson Pre-motor	12
2.4	Detección de la PD por transformaciones locales no paramétricas	15
3	Metodología	17
3.1	Introducción	17
3.2	Base de datos	19
3.3	Procesamiento de imágenes	21
3.4	Extracción de características	24
3.5	Selección de características	26
3.5.1	Datos de prueba y entrenamiento	26
3.5.2	Entrenamiento de modelos	27
3.5.3	Evaluación de desempeño	28
3.5.4	Generación de resultados	30

4 Pruebas y Resultados	31
4.1 Introducción	31
4.2 Resultados de aplicar múltiples ventanas con 9 cortes	32
4.3 Resultados de aplicar múltiples ventanas con 15 cortes	39
4.4 Resultados de combinación de ventanas	44
4.5 Unión de la clase de control y prodromal	48
5 Conclusiones y perspectivas	54
5.1 Conclusiones	54
5.2 Perspectivas	55
Referencias	57

Índice de Figuras

2.1	Metodología [Khalid and Ehsan, 2024]	9
2.2	Imágenes de Resonancia Magnética con corte <i>(a)</i> Axial. <i>(b)</i> Coronal. <i>(c)</i> Sagital. [Sriramakrishnan et al., 2019]	10
2.3	Escáner de transportadores de dopamina [Parkinson’s Foundation, 2025]	10
3.1	Metodología general diseñado para la clasificación de la PD.	18
3.2	Distribución de la base de datos por grupos del cohorte 2022	20
3.3	Imagen por resonancia magnética de un paciente de la clase control	21
3.4	Cortes fMRI de un paciente de control: <i>(a)</i> Normal. <i>(b)</i> Umbralizado con un umbral de 0.2. <i>(c)</i> Erosionado con una estructura cubica.	23
3.5	Ventana de la transformada Census	25
3.6	Movimiento de la ventana Census a través de la fMRI sin sobreposición	26
3.7	Proceso de evaluación de desempeño de los clasificadores jerárquicos	29

4.1	Resultados de 9 cortes de fMRI con ventana 3×3	32
4.2	Resultados de 9 cortes de fMRI con ventana 5×5	33
4.3	Resultados de 9 cortes de fMRI con ventana 7×7	34
4.4	Resultados de 9 cortes de fMRI con ventana 9×9	34
4.5	Resultados de 9 cortes de fMRI con ventana 11×11	35
4.6	Resultados de 9 cortes de fMRI con ventana 13×13	35
4.7	Resultados de 9 cortes de fMRI con ventana 15×15	36
4.8	Resultados de 9 cortes de fMRI con ventana 17×17	36
4.9	Resultados de 9 cortes de fMRI con ventana 19×19	37
4.10	Resultados de 9 cortes de fMRI con ventana 21×21	37
4.11	Resultados de 15 cortes de fMRI con ventana 3×3	39
4.12	Resultados de 15 cortes de fMRI con ventana 5×5	40
4.13	Resultados de 15 cortes de fMRI con ventana 7×7	40
4.14	Resultados de 15 cortes de fMRI con ventana 9×9	41
4.15	Resultados de 15 cortes de fMRI con ventana 11×11	41
4.16	Resultados de 15 cortes de fMRI con ventana 13×13	42
4.17	Resultados de 15 cortes de fMRI con ventana 15×15	42
4.18	Resultados de 15 cortes de fMRI con ventana 17×17	43
4.19	Resultados de combinar las ventanas 15×15 y 17×17 con diferentes cortes 9 cortes fMRI.	45
4.20	Resultados de combinar las ventanas 15×15 y 17×17 con diferentes cortes 11 cortes fMRI.	45

4.21 Resultados de combinar las ventanas 15×15 y 17×17 con diferentes cortes 13 cortes fMRI.	46
4.22 Resultados de combinar las ventanas 15×15 y 17×17 con diferentes cortes 15 cortes fMRI.	46
4.23 Resultados de combinar las ventanas 15×15 y 17×17 con diferentes cortes 15 cortes fMRI.	47
4.24 Resultados de combinar las ventanas 15×15 17×17 con 15 cortes de fMRI uniendo las clases de control y prodromal.	49
4.25 Resultados de combinar las ventanas 15×15 17×17 con 15 cortes de fMRI uniendo las clases de control y prodromal.	49
4.26 Resultados de combinar las ventanas 17×17 15×15 con 15 cortes de fMRI uniendo las clases de control y prodromal.	50
4.27 Resultados de combinar las ventanas 17×17 15×15 con 15 cortes de fMRI uniendo las clases de control y prodromal.	50

Índice de Tablas

4.1	Tabla comparativa del desempeño de los clasificadores a medida que aumenta el número de ventana con 9 cortes.	38
4.2	Tabla comparativa del desempeño de los clasificadores a medida que aumenta el número de ventana con 15 cortes	44
4.3	Tabla comparativa del desempeño de los clasificadores a medida que aumenta el número de cortes con ventajas fijas de 15×15 y 17×17	48
4.4	Tabla comparativa del desempeño de los clasificadores con ventajas fijas de 15×15 y 17×17 , y 17×17 y 15×15	52
4.5	Detección Temprana de la enfermedad de Parkinson usando la base de datos PPML.	53

Resumen

En la actualidad la Enfermedad de Parkinson (EP o PD por sus siglas en inglés para Parkinson Disease), es una enfermedad neurodegenerativa que no tiene cura. El tiempo de vida y la calidad de los que padecen esta afección solo se puede prolongar mediante la detección temprana, para empezar con tratamientos clínicos y reducir la velocidad a la que avanza esta enfermedad. Considerando que, resulta una tarea complicada diferenciar un paciente con enfermedad de Parkinson en etapa inicial de uno sano, este trabajo propone una metodología que utiliza imágenes de resonancia magnética de funciones (fMRI) extraídas de la base de datos Iniciativa de Marcadores de Progresión del Parkinson (PPMI). Para llevar a cabo esta tarea, se definen las clases de control prodromal y PD, y se aplican métodos de umbralización y erosión en las imágenes de resonancia, para reducir costos computacionales y centrarse en las zonas de interés. Una vez identificadas estas zonas, se extraen características estadísticas con transformadas lineales no paramétricas. El conjunto de características se separa en dos grupos de 96.66 % y 3.34 % respectivamente para el entrenamiento y prueba de clasificadores jerárquicos utilizando el método de retención (holdout). Con esta configuración se obtuvo que la exactitud del modelo multiclase propuesto está en el rango de 99.53 % y 100 %, distribuyendo el desempeño entre clases de la siguiente manera. La clase de control alcanza una precisión de 99.58 % y una especificidad de 99.72 %, de forma similar, la clase Prodromal logra una precisión de 99.17 % y una especificidad de 99.46 %, y por último la clase PD una precisión de 99.72 % y una especificidad de 99.47 %. Con este modelo propuesto se busca brindar una herramienta que sea un auxiliar clínico para los especialistas en la detección temprana de la Enfermedad

de Parkinson.

Abstract

Currently, Parkinson's Disease (PD) is a neurodegenerative disorder with no known cure. The lifespan and quality of life of individuals affected by this condition can only be extended through early detection, enabling the initiation of clinical treatments to slow the progression of the disease. Given that distinguishing between an early-stage Parkinson's patient and a healthy individual remains a challenging task, this work proposes a methodology that employs functional magnetic resonance imaging (fMRI) data extracted from the Parkinson's Progression Markers Initiative (PPMI) database. To accomplish this task, the prodromal and PD control classes are defined, and thresholding and erosion methods are applied to the MRI images to reduce computational costs and focus on regions of interest. Once these regions are identified, statistical features are extracted using non-parametric linear transforms. The feature set is divided into two groups, with 96.66

Glosario

ep2d-bold-rest Es una secuencia de imágenes por resonancia magnética funcional utilizando las técnicas eco-planar 2D (ep2d) y técnica de contraste dependiente del nivel de oxígeno en sangre (Blood-Oxygen-Level Dependent) en estado de reposo

ep2d-RESTING-STATE Es una secuencia de imágenes por resonancia magnética funcional utilizando la técnica eco-planar 2D (ep2d), en estado de reposo

rsfMRI-LR imagen por resonancia magnética funcional en estado de reposo de izquierda a derecha

rsfMRI-RL imagen por resonancia magnética funcional en estado de reposo de derecha a izquierda

CAPÍTULO 1

Introducción

1.1. Planteamiento del problema

La enfermedad de Parkinson (PD por sus siglas en inglés para Parkinson Disease) es la segunda enfermedad neurodegenerativa más común en el mundo después del Alzheimer. El Parkinson afecta principalmente la movilidad del individuo causando temblor, rigidez y ralentización del movimiento, reducción progresiva de la velocidad del movimiento o vacilación progresiva en los movimientos, padecimiento conocido como bradicinesia. Esto se debe a la falta de secreción de un neurotransmisor conocido como dopamina, la cual es generada por las terminaciones nerviosas de la sustancia negra. No obstante, a pesar de ser una enfermedad de trastorno del movimiento también puede llegar a producir alteraciones en las funciones cognitivas, depresión, ansiedad, anosmia (pérdida del sentido del olfato) y dolor afectando al sistema nervioso autónomo.

Los biomarcadores son indicadores de procesos biológicos, afecciones o enfermedades que pueden detectarse en la sangre, tejidos u otros fluidos corporales. En el caso de la PD, no se ha identificado un biomarcador confiable que permita diagnosticar la enfermedad. Debido a esta ausencia, no existe una prueba clínica o de laboratorio específica para diagnosticar esta

enfermedad. Por ello, el diagnóstico se basa en exámenes neurológicos y en la evaluación del historial clínico del paciente. La PD afecta a nivel mundial, con una prevalencia del 1 % al 2 % en población mayor de 60 años y casi el 5 % en personas mayores de 65 años. Sin embargo, también puede manifestarse a partir de los 40 años, siendo más común en el sexo masculino [Han et al., 2018].

Las enfermedades neurodegenerativas se caracterizan por provocar la muerte progresiva de neuronas [NeuronUP, 2025], lo que empeora la condición con el tiempo. En el caso de la PD, esta presenta una gran variabilidad entre las personas. En sus etapas iniciales suelen pasar desapercibida, ya que los síntomas pueden ser sutiles. A medida que las neuronas empiezan a morir, también se ven afectadas funciones corporales como la digestión y la regulación de la presión arterial, síntomas que frecuentemente no se asocian con la enfermedad. Cuando los primeros síntomas físicos característicos de la PD se manifiestan, es posible que hasta un 80 % de los neurotransmisores de la dopamina ya hayan muerto [Blakemore, 2025]. En la actualidad, el diagnóstico de esta enfermedad puede tardar entre 1 y 3 años, lo que reduce significativamente la esperanza de vida [Marín M et al., 2018].

Por otra parte, muchas enfermedades neurodegenerativas son difíciles de diagnosticar en una etapa temprana debido a la similitud de sus síntomas con otras afecciones. Esto obliga a los pacientes, sin un diagnóstico concluyente, a acudir constantemente a consultas para monitorear la evolución de la enfermedad o la aparición de nuevos síntomas. Este retraso en el diagnóstico no solo incrementa la incertidumbre, sino que también afecta gravemente la calidad de vida de los paciente [Instituto Mexicano del Seguro Social, 2024].

Según datos publicados por la Organización Mundial de la Salud (OMS), actualmente hay alrededor de 8.5 millones de personas diagnosticadas con esta enfermedad. En el 2019, la PD fue responsable de 5.8 millones de años de vida ajustados por discapacidad (AVAD [Wikipedia, 2023]), lo que representa un aumento del 81 % desde el año 2000. Además, causó 329,000 fallecimientos, un incremento de más del 100 % desde el mismo año ([OMS, 2023]). Estudios recientes sugieren que el número de pacientes con esta enfermedad continuará aumentando, en parte debido al incremento en la esperanza de vida a nivel global.

1.2. Justificación

Como se mencionó anteriormente, la enfermedad de Parkinson es la segunda enfermedad neurodegenerativa con mayor prevalencia en adultos mayores, afectando predominantemente la función motora de los individuos, además de causar trastornos cognitivos, alteraciones del sueño, dolor y desequilibrio, entre otros síntomas [Playfer, 1997].

La incidencia de la PD aumenta con la edad, siendo más evidente en personas mayores de 55 años. El diagnóstico se realiza principalmente a través de criterios clínicos y la prevalencia alcanza su punto máximo en el grupo de edad de 85 a 89 años [García, 2020]. Pese a que en la actualidad no existe una cura para la PD, estudios han indicado que la detección temprana puede permitir un manejo más efectivo de las distintas etapas de la enfermedad, mejorando así la calidad de vida de los pacientes.

En la etapa inicial de la enfermedad de Parkinson, conocida como prodrómica, se manifiestan síntomas no físicos como depresión, trastornos del sueño, cambios en la memoria y el pensamiento, hipotensión, anosmia, estreñimiento o problemas urinarios. Estos síntomas no motores pueden aparecer de 10 a 20 años antes que aparezcan los primeros síntomas motores que se relacionan directamente a la PD, cuando estos se detectan se diagnostica al paciente en una etapa avanzada de esta enfermedad. Al realizar una detección temprana se puede frenar la progresión de esta, logrando que los síntomas motores como el temblor no se desarrollen completamente. De igual manera, con un diagnóstico temprano se puede implementar estrategias para reducir el riesgo de problemas cognitivos en etapas avanzadas de la enfermedad, así mismo, se logran controlar mejor los síntomas no motores mencionados anteriormente.

Dada la importancia de la detección precoz de la PD, este proyecto propone desarrollar una metodología que utiliza imágenes de resonancia magnética funcionales (fMRI) para detectar la PD en sus etapas iniciales, utilizando algoritmos de aprendizaje automático (ML por sus siglas en inglés para Machine learning) y aprendizaje profundo (DL por sus siglas en inglés para Deep Learning). Por ende, se empleará la base de datos del Parkinson's Progression Markers Initiative (PPMI) [Marek et al., 2011], actualizada al 2022, con el fin de lograr una clasificación precisa y múltiple de la PD.

1.3. Antecedentes

Diversos autores han aplicado técnicas para la detección de la PD. Por ejemplo, Fnu Asaduzzaman [ASADUZZAMAN et al., 2020] ha utilizado arquitecturas de aprendizaje profundo ya establecidas, como InceptionV3, VGG16 y VGG19. En 2020, Ahmed Hasin Neehal [Neehal et al., 2020] presentó un algoritmo basado en aprendizaje automático denominado Support Vector Machine (SVM) para la clasificación y predicción de la PD, logrando obtener buenos resultados en las métricas de especificidad y precisión.

Un estudio destacado de Luca Parisi [Parisi et al., 2018] revela que la combinación de distintas técnicas de clasificación puede facilitar la detección temprana de la PD. En esta investigación se empleó un perceptrón multicapa (MLP) para la extracción de características de fMRI y un Lagrangian Support Vector Machine para la clasificación de estas características. En una línea similar, Wu Wang [Wang et al., 2020] propuso comparar un modelo de aprendizaje profundo con doce métodos de aprendizaje automático, utilizando indicadores como el movimiento ocular rápido, datos del líquido cefalorraquídeo, pérdida olfativa y marcadores de imágenes dopaminérgicas.

La aplicación de técnicas de aprendizaje automático y aprendizaje profundo para la detección de la PD se ha revelado como una tecnología con gran potencial en el ámbito de la salud. Un claro ejemplo es el estudio referenciado en [Prashanth and Roy, 2018c], que utiliza SVM para desarrollar modelos predictivos capaces de detectar la PD en etapas tempranas, alcanzando una curva ROC superior al 95% con datos de fMRI de la base de datos Iniciativa de Marcadores de Progresión de Parkinson (Parkinson's Progression Markers Initiative, PPMI) del año 2018.

Es importante señalar que resulta complejo realizar comparativas directas entre los trabajos mencionados, ya que cada uno utiliza bases de datos distintas.

1.4. Objetivos

El objetivo principal de este trabajo es detectar en etapas tempranas la Enfermedad de Parkinson utilizando diversas técnicas de extracción de características paramétricas. Dichas características serán evaluadas mediante 25 métodos de clasificación basados en aprendizaje automático (Machine Learning) y aprendizaje profundo (Deep Learning). Los clasificadores serán evaluados mediante las métricas de exactitud, la precisión y especificidad.

1.4.1. Objetivos específicos

- Probar diferentes métodos de extracción de características en la base de datos de la Iniciativa de Marcadores de Progresión del Parkinson (Parkinson's Progression Markers Initiative, PPMI).
- Seleccionar el método de extracción de características más adecuado, asegurándose de que proporcione un mínimo de características distintivas por imagen para cada clase.
- Experimentar con diversos modelos de aprendizaje automático y aprendizaje profundo, incluyendo Bayes ingenuo (Naïve Bayes), k-vecino más cercano (K-Nearest Neighbor, k-NN), Árboles de Decisión (Decision Trees), Regresión Logística (Logistic Regression), Máquinas de Vectores de Soporte (Support Vector Machines, SVM) y redes recursivas.
- Evaluar la eficiencia del clasificador elegido utilizando métricas derivadas de la matriz de confusión, comparándolo con el estado del arte en el área.

1.5. Hipótesis

Las imágenes de resonancia magnética funcionales como medio de extracción de características para la detección temprana de la Enfermedad de Parkinson. Si las características son lo suficientemente separables se podrá realizar una detección temprana precisa de esta enfermedad.

1.6. Organización de la tesis

Este trabajo de investigación se divide en 5 capítulos, como pudimos notar, en el primer capítulo se realiza una introducción sobre la problemática que se ha detectado y el porqué es importante realizar acciones con respecto a esto. De igual manera, se presentan antecedentes, objetivos e hipótesis.

Capítulo 2: Estado del arte. En esta segunda parte, encontraremos una recapitulación de diferentes formas para detectar la PD. Seguidamente, se irá focalizando hacia temas más relacionados con nuestro trabajo de investigación como lo son la detección por imágenes, Prodrómala y utilizando transformaciones locales no paramétricas.

Capítulo 3: Metodología. En este capítulo, se realiza una descripción detallada de los métodos y técnicas utilizadas para alcanzar el objetivo de la investigación, de igual manera, se muestran aspectos de la base de datos, como se entrenaron los modelos y las métricas que se usaron para evaluar el desempeño.

Capítulo 4: Pruebas y resultados. Se muestran las diferentes pruebas que se realizaron con sus respectivos resultados, cada uno de estos se dan con una breve explicación de la prueba y los resultados como se muestran en forma de diagramas de cajas. De igual manera, se muestra una tabla comparativa con los diferentes trabajos relacionados.

Capítulo 5: Conclusiones y perspectivas. Este último capítulo nos muestra una síntesis de nuestros resultados al desarrollar este tema de investigación. También, una parte sobre las cosas que se esperan a futuro.

2.1. Métodos de detección de la Enfermedad de Parkinson

Como se mencionó en el capítulo anterior, la enfermedad de Parkinson es la segunda enfermedad neurodegenerativa más común, con prevalencia en todo el mundo, afectando principalmente a la población con edad mayor de 65 años. Esta enfermedad fue mencionada por primera vez por el neurólogo británico James Parkinson en 1817, en el trabajo *An Essay on the Shaking Palsy* (Ensayo sobre la Parálisis Agitante). Desde su descubrimiento han habido muchos avances de los padecimientos que provoca así como diversas forma de detectar esta enfermedad. Como se demuestra en [\[Rastegari et al., 2022\]](#), con ayuda de tecnologías portátiles, en este caso un acelerometro, se puede aumentar el tiempo de monitorio del paciente y de esa manera obtener patrones de movimiento a lo largo del tiempo. Con estos datos y utilizando ingeniería de características se logró un porcentaje de precisión de 85 %.

Asi como [\[Khalid and Ehsan, 2024\]](#) explica una metodología para detectar la PD, en la cual utiliza sub-bandas de electroencefalograma (EEG) y una unidad recurrente sincronizada

(GRU) para el análisis de ondas cerebrales. Utilizando la metodología mostrada en la figura 2.1 se consiguen valores de exactitud, precisión, sensibilidad y F1 score en un rango de 90 % a 98 % en esta clasificación binaria.

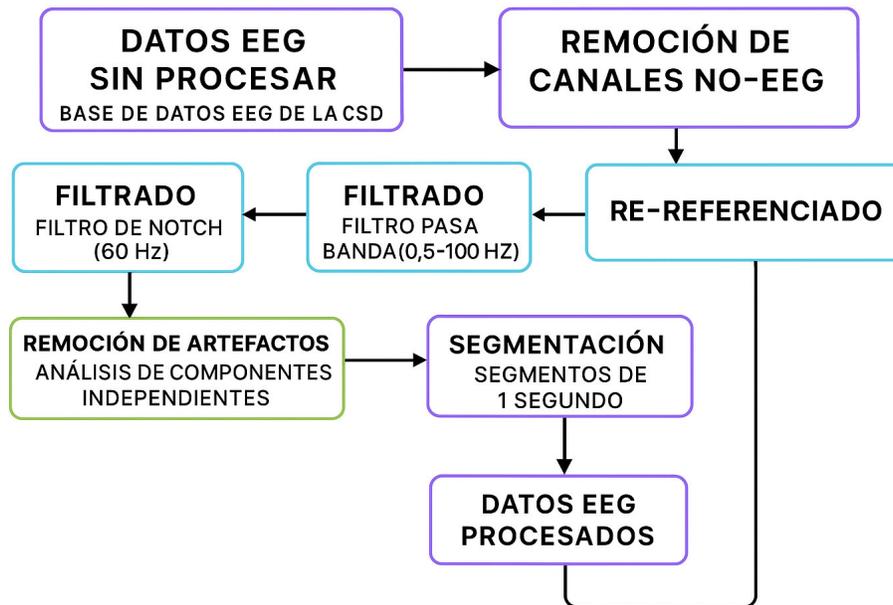


Figura 2.1. Metodología [Khalid and Ehsan, 2024]

Se ha dejado en evidencia que existen diversas técnicas y métodos para detectar la PD, [Deepa and Khilar, 2024] resalta que más del 90 % de las personas diagnosticadas con las PD experimentan problemas al hablar, lo cual lo hace una característica importante para identificar esta enfermedad. Utilizando clasificadores de árboles extremadamente aleatorios (ERT), y al combinarse con el Operador de Selección y Contracción Mínima Absoluta (LASSO), logra una precisión del 87 % el cual será orientado en un futuro a la detección temprana de esta enfermedad.

Así mismo, [Ravanidis et al., 2020] trabaja con plasmas sanguíneo que puede ser una fuente de biomarcadores. Explica que al realizar una prueba mínimamente invasiva puede obtener una detección temprana y un seguimiento de la PD, esto se logra utilizando microARN (miARN), son moléculas de ARN no codificantes conservadas que actúan como reguladores postranscripcionales de la expresión génica. Los miARN enriquecidos ayudan a regular diferentes aspectos del desarrollo y función de las neuronas. Al seleccionar los miARN enriquecidos en el cerebro se realiza una reacción en cadena de la polimerasa con transcripción inversa en tiempo real en el plasma de 100 controles sanos, 99 pacientes idiopáticos y 53

genéticos (26 alfa-*sinucleína*^{A53T} y 27 glucocerebrosidasa), obteniendo como resultado una huella molecular que puede usarse para la detección de diferentes subtipos de la PD.

2.2. Diagnósticos por imágenes

En la sección anterior se mencionan diversos trabajos sobre la detección de la PD, los cuales tienen diferentes enfoques de investigación, en esta sección se describe la detección de la PD basado en imágenes. En los tipos de imágenes que se trabajan más comúnmente para la detección de la PD tenemos las Imágenes de Resonancia Magnética (MRI), entre las cuales podemos encontrar diferentes cortes como: axial, sagital y coronal, y el escáner de transportadores de dopamina (DatScan). Las imágenes MRI y DatScan se muestran a continuación en la figura 2.2 y 2.3

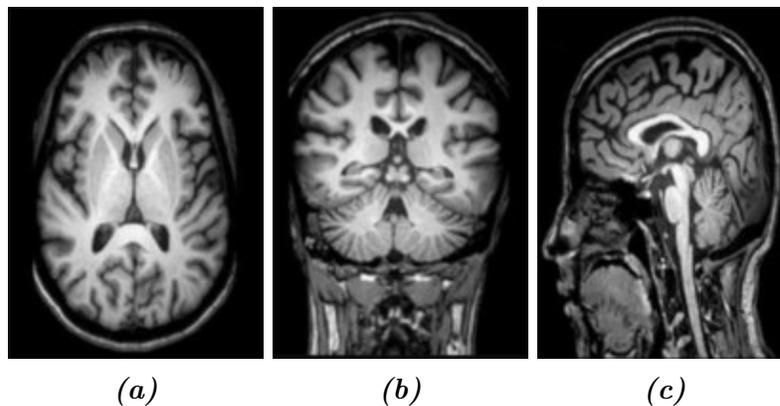


Figura 2.2. Imágenes de Resonancia Magnética con corte (a) Axial. (b) Coronal. (c) Sagital. [Sriramakrishnan et al., 2019]

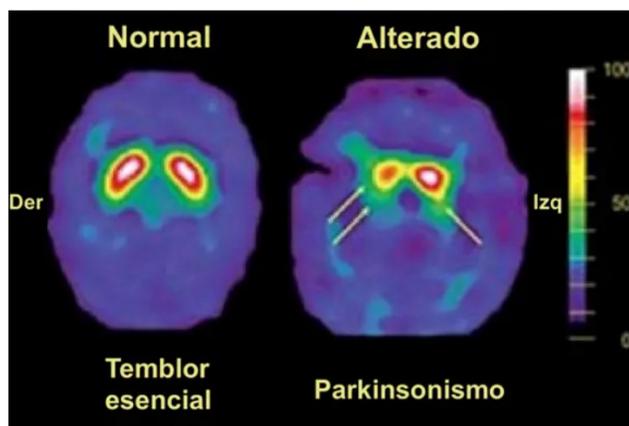


Figura 2.3. Escáner de transportadores de dopamina [Parkinson's Foundation, 2025]

Un claro ejemplo del diagnóstico por imágenes es [Tassew et al., 2023] en la que proponen un Software de Diagnósticos de la Enfermedad de Parkinson (PDDS). Este software utiliza imágenes de resonancia magnética y DaTscan [contributors, 2024], misma que ayudan a diagnosticar la PD al mostrar cambios en las estructuras cerebrales relacionados con la enfermedad. El software PDDS utiliza modelos de aprendizaje profundo los cuales permiten detectar y segmentar regiones profundas del cerebro. Además, utiliza la red neuronal UNET para localizar las regiones de interés (ROI). Para evaluar el desempeño de esta configuración se utilizó la métrica Precisión media promedio (mAP), obteniendo resultados de detección mAP 0.5:0.95 de 70.30 % para imágenes DatScan y mAP 0.5:0.95 de 64.15 % para imágenes MRI.

De igual forma, en el trabajo de [Pragadeeswaran and Kannimuthu, 2024], se utilizan imágenes de espirales dibujadas a mano. Estas imágenes son monitoreadas en tiempo real utilizando tecnologías recientes como el internet de las cosas (IoT), logrando así dar un diagnóstico de manera remota. Para realizar la detección de la PD desarrollaron un clasificador híbrido el cual combina aprendizaje profundo y aprendizaje automático llamado Red neuronal convolucional profunda de coseno (CosineDCNN), logrando una precisión del 89.98 % en la detección de la PD.

Recientemente, un trabajo de gran aporte para esta área es el de [Sangeetha and Umarani, 2025]. Este trabajo utiliza imágenes MRI de 3 tipos: sagital, coronal y axial, las cuales son pre-procesadas con un filtro gaussiano y técnicas de aumento. Posteriormente, para la detección se realizó la combinación de 3 redes neuronales: red neuronal convolucional de Shepard, Fuzzy Zeiler y la red Fergus (ShCNN-Fuzzy-ZFNet). Por último, en la tarea de clasificación de la PD se combinan las redes Deep Maxout Network (DMN) y EfficientNet-B3 Red Neuronal Convolucional (CNN) preentrenada mejorada con un mecanismo de atención (EfficientNet-B3-Attn-2) con concepto difuso consiguiendo una precisión del 92.6 %.

Por otra parte, existen trabajos que no solo se basan en la detección de la PD sino también ayudan a diferenciar de esta enfermedad con respecto a otras, como es el caso de [Aggarwal et al., 2024]. En su trabajo se analizan cuatro regiones del cuerpo estriados, estos son estructuras subcortical del cerebro que juega un papel crucial en el control motor, que se obtienen de la base de datos PPMI, con la finalidad de diferenciar entre exploraciones sin evidencia de déficit de dopamina (SWEDD, por sus siglas en inglés) y la PD, se analizan las regiones estriadas para extraer características SRB y se luego combinarlas entre si hasta obtener un total de 36. Estas características derivadas se aplican a varios clasificadores supervisados y de conjunto de aprendizaje automático para tres clasificaciones binarias (PD frente a SWEDD, PD frente a saludable y saludable frente a SWEDD) obteniendo que el clasificador con mejor

desempeño fue el Bayes Ingenuo con una precisión del 98.03 % y un F1 score de 96.29 % en la tarea de diferenciar entre SWEDD y la PD.

Se puede observar que la detección binaria de la PD mediante la utilización de imágenes, es una forma efectiva de detectar esta enfermedad. Los porcentajes de precisión van de rango de 89.98 % con el uso de aprendizaje profundo y 98.03 % utilizando técnicas de aprendizaje automático.

2.3. Detección del Parkinson Pre-motor

En esta tercera sección mostraremos trabajos de investigación que realizan detección temprana de la PD. El primero que se mencionara es el trabajo de [Aversano et al., 2023]. En este construyen un modelo capaz de identificar entre un paciente sano, enfermos y prodromicos. Esto se logra utilizando los datos recopilados en la Iniciativa de Marcadores de Progresión del Parkinson de la cual se extraen 2 principales conjuntos. El primero consiste en seleccionar solo características motoras que se dividen de la siguiente manera: 582 PD, 145 sanos y 462 prodrómicos. Para el segundo grupo se considera solo características no motoras y los pacientes se dividen de la siguiente manera: 478 PD, 125 sanos y 448 prodrómicos.

Una vez se han definido los conjuntos de datos, se utiliza un algoritmo genético para crear un conjunto más reducido y entrenar los diferentes tipos de clasificadores. De los 2 conjuntos de datos, el no motor obtuvo un F1 del 99 % con 4 clasificadores, bosque aleatorio (RF), Aumento de gradiente extremo (XGBoost), Clasificador Árboles Extremadamente Aleatorizados (ERT) y CatBoost. En el grupo motor obtuvo un rendimiento del 86 %. De igual manera, explica que al aplicar el algoritmo de selección de características relevantes disminuyó el rendimiento de los clasificadores. El conjunto motor baja al 73 % y no motor al 92 %, no obstante, se reduce el costo computacional del entrenamiento de los clasificadores.

En este mismo orden de ideas, [Prashanth and Roy, 2018a] utiliza parte del cuestionario del paciente (PQ) de la Escala de Calificación Unificada de la Enfermedad de Parkinson de la Sociedad de Trastornos del Movimiento (MDS-UPDRS). La MDS-UPDRS consta de 4 partes, pero de solo se utilizaron la Parte Ib y la Parte II las cuales corresponden a las características motoras y no motoras respectivamente. De igual manera, se explica que existen múltiples ventajas en el uso de la extracción de características utilizando MDS-UPDRS, ya que este es simple de entender, no invasivo, estimación efectiva, validado ampliamente en grupos de

pacientes y los sujetos pueden completar el cuestionario ellos mismos.

Para la detección se utilizó la base de datos PPMI de la cual se extrajo la parte de PQ del MDS-UPDRS para el análisis. Una vez obtenidos los datos se realizó una validación cruzada anidada de 10 carpetas, donde la selección de características y el ajuste de parámetros se realiza en la carpeta interna y la evaluación se realiza en un conjunto (o carpeta) independiente. Con esta configuración logró obtener una curva roc mayor al 95% utilizando regresión logística, bosques aleatorios, árboles potenciados y máquina de vectores de soporte (SVM). El modelo logístico demostró un ajuste estadísticamente significativo a los datos, lo que indica su utilidad como modelo predictivo.

En términos generales su metodología se resume en 5 pasos. El primero es obtener características del cuestionario del paciente de la MDS-UPDRS, luego se hace una separación de información individual para entrenamiento y prueba. En el entrenamiento de modelos se utilizan 4 clasificadores regresión logística, bosques aleatorios, árboles potenciados y máquina de vectores de soporte, de estos se selecciona el modelo utilizando la curva roc y con este se realizan las pruebas de detección de la PD.

Es importante destacar, que existen trabajos que emplean herramientas similares a las utilizadas en este trabajo de tesis, un claro ejemplo de esto, es el trabajo de [Solana-Lavalle and Rosas-Romero, 2021], en el cual se realiza un análisis de la morfometría basada en vóxeles (VBM) aplicada a MRI. Con esta técnica se determina si existe pérdida de las células nerviosas que generan dopamina, ya que esto es un indicativo de la PD.

Para realizar este trabajo [Solana-Lavalle and Rosas-Romero, 2021] utilizó la base de datos PPMI, se seleccionó MRI ponderadas en T1, las cuales se adquirieron como una secuencia 3D de 226 pacientes hombres con PD, 86 controles varones, 104 pacientes mujeres con PD y 64 pacientes mujeres con PD. Una vez obtenidos todos los datos, su metodología se basó en cuatro etapas principales:

- Detección de regiones de interés: En este primer paso se aplica VBM a las MRI para conseguir un mapa conocido como t-map, el cual muestra diferentes concentraciones de materia gris.
- Extracción de características: Para la extracción se utilizaron estadísticas de primer orden como el histograma, y de segundo orden como la matriz de coocurrencia de niveles de gris (GLCM) y el método de textura de Haralick [Haralick et al., 2007].

- Clasificación: Para la tarea de clasificar se utilizaron diversos clasificadores como: k-Vecinos más Cercanos, Perceptrón Multi Capa, Support vector machine, Bosques aleatorios, Bayes ingenuos, Regresión logística, Red Bayesiana,

Con esta metodología se obtuvieron los siguientes resultados: en hombres es 99.01 % de precisión, 99.35 % de sensibilidad, 100 % de especificidad. El mejor rendimiento de detección logrado en mujeres es 96.97 % de precisión, 100 % de sensibilidad, 96.15 % de especificidad. Estas métricas se obtuvieron de diferentes clasificadores como lo son: Bayes ingenuo, Red bayesiana, Perceptrón multicapa (MLP), SVM.

Otro trabajo de gran interés, es el descrito en el capítulo 23 del libro [Aggarwal et al., 2025]. Se explica que se realiza un estudio con 620 entidades para la clasificación temprana de la PD empleando la base de datos PPMI en conjunto con ML y DL. En este se puede dar a notar que los clasificadores basados en DL obtuvieron una mejor clasificación que los de ML. Con este modelo de DL se obtuvieron 98.14 %, 98.9 %, 99.14 % y 98.5 % son la precisión, la puntuación F1, la sensibilidad y la especificidad, respectivamente.

A continuación, citaremos otro trabajo escrito por [Li et al., 2024], al igual que nuestro trabajo, se utiliza las imágenes fMRI en estado de reposo (rs-fMRI), extraídas de la base de datos PPMI, utilizado 145 muestras. Este estudio propone un diagnóstico utilizando PD-ARne, la cual utiliza la amplitud de las fluctuaciones de baja frecuencia y la homogeneidad regional extraídas de rs-fMRI como entrada. Luego se extraen características 3D de doble rama para emplear una extracción de características más avanzada. Asimismo, se desarrolla un módulo de Atención mejorada para fusionar de manera efectiva dos tipos de características observando que así los resultados indicaron una precisión de clasificación promedio de 91.6 % (intervalo de confianza del 95 % [IC]: 90.9 %, 92.4 %), precisión de 94.7 % (IC del 95 %: 94.2 %, 95.1 %), recuperación de 86.2 % (IC del 95 %: 84.9 %, 87.4 %), puntuación F1 de 90.2 % (IC del 95 %: 89.3 %, 91.1 %) y AUC de 92.8 % (IC del 95 %: 91.1 %, 95.0 %)

Para la detección del Parkinson pre-motor queda evidenciado que tanto las técnicas de aprendizaje profundo como las de aprendizaje automático son efectivas al momento de realizar esta tarea. Ambos métodos de aprendizaje dieron porcentajes de precisión mayor al 90 % haciendo uso de diferentes metodologías.

En los párrafos anteriores, la detección temprana se ha realizado mediante el uso de tecnologías de ML y DL pero no es la única forma de detección que existe [Russo et al., 2021], realiza una detección temprana precisa mediante la amplificación de semillas de

alfa-sinucleína(α Syn-SAA). Esta técnica permite la detección de agregados de alfa-sinucleína con capacidad de siembra en pacientes vivos y han demostrado una alta precisión diagnóstica en varias cohortes de pacientes con PD y otras sinucleinopatías. Utilizando la base de datos PPMI, específicamente las imágenes DATScan, para comparar con los resultados obtenidos. De igual manera, 3 laboratorios analizaron muestras de líquido cefalorraquídeo (LCR) de un subconjunto seleccionado al azar de la base de datos. Los resultados obtenidos fueron similares en todos los laboratorios obteniendo una sensibilidad que va del 86 % al 96 % y una especificidad del 93 % al 100 %.

Por último en esta sección [He et al., 2025], encontramos una forma de detección temprana haciendo uso de algo que se maneja cotidianamente como es el teléfono celular y el internet de las cosas. La velocidad de rotación y la aceleración durante la actividad de caminar se registran con el giroscopio y el acelerómetro, mientras que las coordenadas de ubicación y la aceleración durante la actividad de tapping (técnica de auto-ayuda que consiste en golpear suavemente puntos del cuerpo con los dedos) se recopilan a través de la pantalla táctil y el acelerómetro, y las señales de voz son capturadas por el micrófono. Con estos se pretende fusionar los datos de múltiples sensores durante una misma actividad y extrae la importancia de diferentes actividades correspondientes a síntomas del Parkinson en etapas tempranas. El marco de fusión de dos niveles propuesto logra un área bajo la curva de 0.891 (IC del 95 %, 0.860-0.921) y una sensibilidad de 0.950 (IC del 95 %, 0.888-1.000) en la detección temprana de la PD.

2.4. Detección de la PD por transformaciones locales no paramétricas

En esta última sección del capítulo 2, mencionaremos los trabajos que realizan detección de la PD con técnicas similares a la utilizada en esta investigación, la cual es conocida como Transformada Census y su publicación original fue realizada por [Zabih and Woodfill, 1994].

El primer trabajo que mencionaremos es el de [Priya et al., 2021]. En este se analizaron señales de marcha humana utilizando técnicas de patrón binario local (LBP), Patrón de Gradiente Local (LGP), el Patrón Descriptivo Vecino Local (LNDP) y el Patrón de Gradiente Vecino Local (LNGP) para extraer características de las señales de la marcha. Dichas técnicas fueron aplicadas al conjunto de datos gaitpdb extraída de PhysioNet [Hausdorff, 2008]. Esta base de datos consta de 166 pacientes de los cuales 73 son sanos y el restante ya padecen de la

enfermedad. La metodología utilizada se presenta a continuación.

En la extracción de características se utilizó el algoritmo de Patrón de gradiente vecino local ponderado simétricamente (SWLNGP), esto con la finalidad de mejorar el rendimiento de las redes neuronales. Este procedimiento de identificación de patrones abarca la transformación de una región de interés en la imagen en una representación decimal. Se aplicaron 4 algoritmos de extracción de características para verificar con cual se obtienen las más relevantes. Una vez obtenidas las mejores características se utilizó un clasificador de redes neuronales artificiales (ANN) con la cual se alcanzó un 96.28% de precisión en la clasificación de la PD.

El segundo artículo del cual se hará mención es el de [Panahi et al., 2024], en este trabajo se evalúa si existe reproducibilidad de característica radiómicas de las MRI, para la clasificación de la enfermedad de Parkinson, así como su estabilidad y rendimiento en el aprendizaje automático. Para llevar a cabo estas pruebas se extrajeron MRI de la base de datos PPMI, en las cuales se ponderaron 140 pacientes en secuencias de resonancia magnética (RM) que muestran la anatomía de los tejidos blandos y la grasa).

Para la extracción de características se analizaron 16 regiones del cerebro utilizando 6 niveles de discretización (8, 16, 32, 64, 128 y 256 bins). Se aplicó la armonización ComBat utilizando una variable de lote combinada que incorporaba tanto modelos de escáner como niveles de discretización, lo cual mejoro significativamente la reproducibilidad de las características. Esto se puede ver más claramente en la precisión que paso de un rango de 0.42-0.49 a 0,86-0,96 después de la armonización.

En este trabajo de tesis se presenta una metodología la cual utiliza la base de datos PPMI y las transformaciones locales no paramétricas para clasificar la enfermedad de Parkinson en etapa avanzada, prodromal o paciente sano.

3.1. Introducción

En este capítulo daremos a conocer los diferentes métodos y estrategias que se utilizaron para obtener los resultados mostrados en el capítulo 4. En el contenido de esta metodología se mostrarán aspectos como la base de datos, el método de extracción de características, los arreglos del clasificador jerárquico, algoritmo general utilizado, entre otros, con los cuales se podrá tener un panorama general del trabajo realizado.

A continuación, en la figura 3.1, se presenta el algoritmo general utilizado en esta metodología. Este, además de darnos información precisa sobre los pasos que se siguieron para obtener los resultados, también nos servirá de guía para presentar de forma ordenada las siguientes secciones de este capítulo.

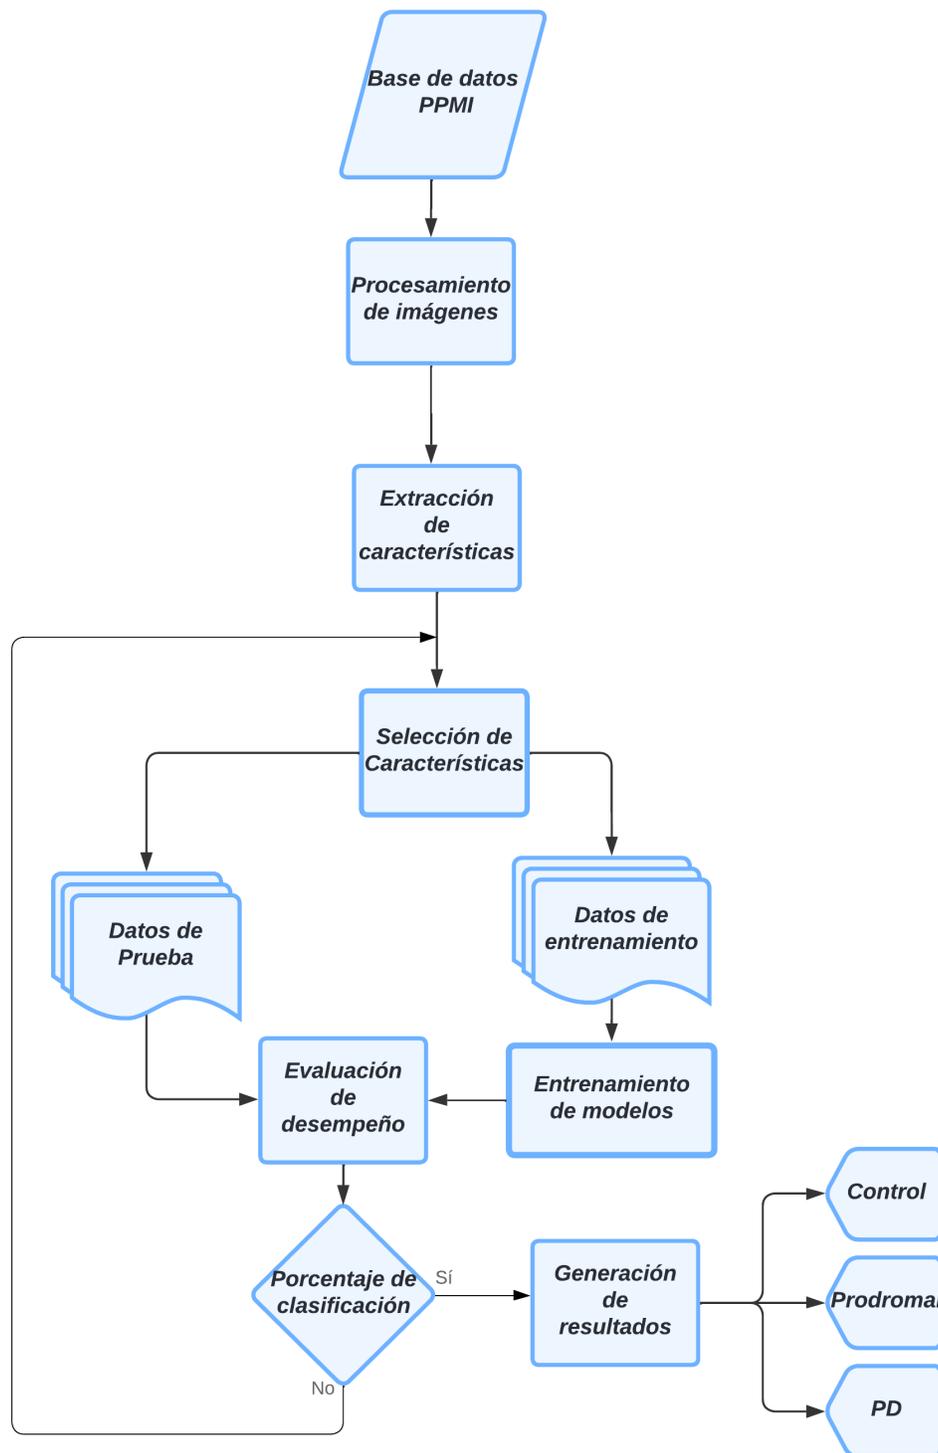


Figura 3.1. Metodología general diseñado para la clasificación de la PD.

3.2. Base de datos

La base de datos utilizada es la Iniciativa de marcadores de progresión del Parkinson (PPMI, por sus siglas en inglés) la cual, como explica [Marek et al., 2011] tiene como objetivo principal mejorar la comprensión de la etiología y la evolución de la enfermedad como para proporcionar herramientas cruciales y así aumentar la probabilidad de éxito de los ensayos terapéuticos utilizando biomarcadores de la PD. Esta iniciativa empezó en el 2010 con la fundación Michael J. Fox, grupos de científicos académicos y socios del sector industrial .

Esta base de datos es de acceso abierto y cuenta con una biblioteca de biomuestras entre las cuales podemos encontrar muestras de sangre, líquido cefalorraquídeo, orina, imágenes fMRI, entre otros. En su página oficial: <https://www.ppmi-info.org/>, encontraremos información complementaria sobre diversos aspectos como su proceso de recolección de datos, seguimiento que se le da a cada paciente, los grupos de pacientes que comparten una característica en común también conocido como cohortes, los colaboradores actuales, principales estudios publicados utilizando esta base de datos, distribución de los datos actuales, entre muchas otras, lo cual lo hace una organización muy confiable y en constante crecimiento para lograr una mejor calidad de vida a las personas con PD y poder complementar la información sobre esta enfermedad.

En nuestro caso particular usamos las imágenes fMRI del cohorte mayo-2022. Esta base de datos tiene 4 clases: control, prodromal, phantom y PD.

- Control: esta clase está constituida por 47 pacientes que presentaron síntomas similares a la PD pero su resultado final fue negativo para esta enfermedad.
- Prodromal: Son 215 pacientes que tenían una etapa temprana de la PD pero era difícil dar un diagnóstico preciso. A lo largo del tiempo mediante exámenes clínicos se confirmó la existencia de esta enfermedad.
- Phantom: Constituye una gran cantidad de pacientes pero son datos que están incompletos o corruptos, por lo cual no se pueden utilizar de manera adecuada.
- PD: Los pacientes de esta clase fueron diagnosticados con PD en etapa avanzada. Es la clase más grande con 445.

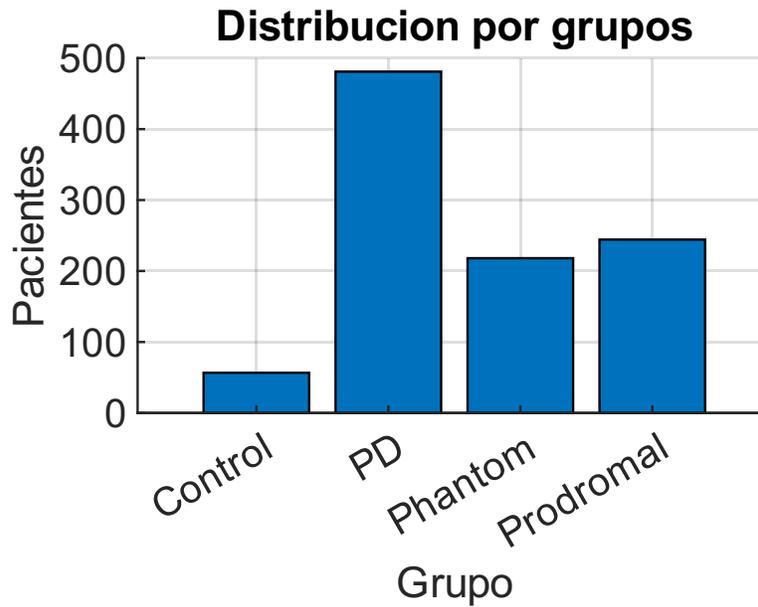


Figura 3.2. Distribución de la base de datos por grupos del cohorte 2022

Como la base de datos está constituida por fuentes de información no centralizadas, existen 31 tipos de formatos diferentes para las fMRI, entre estas se destacan ep2d-RESTING-STATE, rsfMRI-LR, rsfMRI-RL y ep2d-bold-rest, los cuales tienen la mayor cantidad de información de las clases de interés con características similares como tamaño y formato de imagen. En dicho formato se presenta una imagen con una distribución matricial de 7×7 en la que cada posición representa un segmento del cerebro, a cada una de estas secciones se le denomina corte teniendo así un total de 49, esto lo podemos observar en la figura 3.3. Cabe destacar que en la última fila no siempre se logran ver cortes ya que depende del equipo y la morfología del paciente. A cada paciente se le hacen repetidas muestras en la misma posición, normalmente son 210, no obstante, no se cumple en todos los casos.

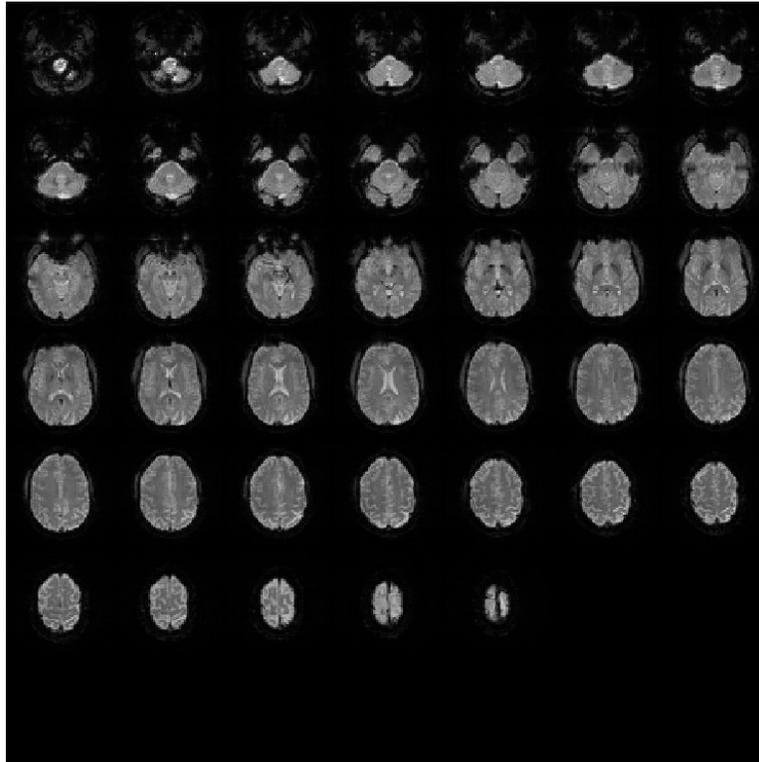


Figura 3.3. Imagen por resonancia magnética de un paciente de la clase control

3.3. Procesamiento de imágenes

Con el objetivo de procesar de mejor manera las fMRI se le realizaron tres tipos de procesamiento, el primero consiste en hacer la separaciones de los cortes de interés, esto debido a que la mayor parte de la información de las imágenes fMRI se encuentra entre la segunda y quien columna, al analizar solamente esta región podemos reducir el costo computacional y así evitar que se introduzca ruido a nuestro sistema de clasificación. La segunda parte es la normalización del corte seleccionado, con esto conseguimos rangos dinámicos reducidos y tener mas homogeneidad en la imagen que se encuentra en escala de grises y como ultima parte se realizo un análisis de los cortes para poder determinar la región central del cráneo de cada paciente.

Una vez seleccionado los elementos de interés dentro de la base de datos PPMI, los cuales corresponden a ep2d-RESTING-STATE, rsfMRI-LR, rsfMRI-RL y ep2d-bold-rest como se había mencionado anteriormente, se iniciará con la primera parte del procesamiento de imágenes que corresponde a la localización de la región central del cráneo en las fMRI. Con la

finalidad de alcanzar este objetivo se implementó el algoritmo 1 que se muestra a continuación, que, en términos generales, consisten en seleccionar un corte para luego aplicarle un umbral, erosionarlo y calcular las áreas dentro de la imagen y de estas seleccionar la mayor que corresponderá al área del cráneo. Una vez realizado este proceso se comparan todas las áreas de la región de interés para determinar en qué fila y columna se encuentra.

Algoritmo 1 Detección de área máxima en subregiones de una imagen binarizada y erosionada

Data: Imagen (Im), parámetros Paso de ancho (P_W), Paso de alto (P_H), Ventana 1 (V_W), Ventana 2 (V_H)

Result: Coordenadas (F, C) con el área máxima detectada

Crear elemento estructurante cúbico: $se \leftarrow \text{strel}('cube', 3)$

Inicializar matriz de áreas: $area1 \leftarrow \text{zeros}(5, 7)$

for $F \leftarrow 2$ **to** 5 **do**

for $C \leftarrow 1$ **to** 7 **do**

$Corte \leftarrow Im[(1 : P_W) + V_1(F), (1 : P_H) + V_2(C)]$

$Corte_N \leftarrow \text{double}(Corte) / \text{máx}(Corte)$

$img_th \leftarrow Corte_N > 0.2$

$img_erod \leftarrow \text{imerode}(img_th, se)$

$CC \leftarrow \text{bwconncomp}(img_erod)$

$lt \leftarrow \text{regionprops}('table', CC, 'Area', 'BoundingBox')$

$area1[F, C] \leftarrow \text{máx}(lt.Area)$

end

end

$a \leftarrow \text{máx}(area1)$ (F, C) $\leftarrow \text{find}(area1 == a)$

El proceso de umbralización consta, como su nombre lo indica, de colocar un umbral (TH) con el cual se crea una imagen binaria también conocida como mascara, los valores que estén por encima de este valor TH se visualizaran con el color blanco (1 lógico), por el contrario, sera de color negro (0 lógico); esto con la finalidad de calcular las áreas las regiones blancas, la cual es una suma de los pixeles tiene un valor de 1 lógico, y así localizar la región central del cráneo. Por otra parte, la erosión de la imagen umbralizada se realiza para evitar errores al calcular la áreas dentro de la imágenes, esto debido a que algunas regiones de los ojos quedaban unidas al cráneo como se observar en la figura 3.4b, y ocasionaba que dieran áreas mayores, por ende, la región central del cráneo seleccionada no correspondiera a la real. Las etapas de este procesamiento de imagen se puede apreciar más claramente en la figura 3.4. Cabe destacar que la figura 3.4c, se obtuvo con un elemento morfológico cúbico 3D con un ancho 3 píxeles.

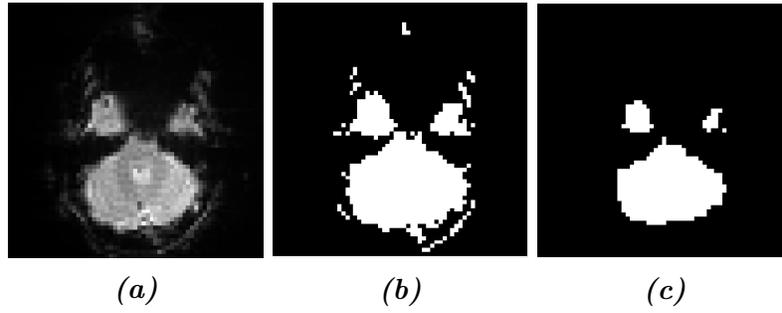


Figura 3.4. Cortes fMRI de un paciente de control: (a) Normal. (b) Umbralizado con un umbral de 0.2. (c) Erosionado con una estructura cubica.

En el proceso de seleccionar el corte se debe extraer el tamaño de la imagen(Im), que será igual la cantidad de píxeles de alto y ancho, dando como resultado una altura H y un ancho W . Estos datos nos ayudaran a elegir la cantidad de píxeles que debemos desplazarnos para seleccionar el corte de interés. Para esto nos apoyaremos de las ecuaciones 3.1 y 3.2

$$P_W = \lfloor (W/7) - 1 \rfloor \quad (3.1)$$

$$P_H = \lfloor (H/7) - 1 \rfloor \quad (3.2)$$

Cuando se haya calculado el tamaño del paso, utilizando las ecuaciones 3.3 y 3.4, para crear vectores de posiciones iniciales de cada uno de los cortes tanto vertical como horizontalmente. Cabe aclarar que se divide entre 7 porque corresponde al número de cortes tanto verticales como horizontales.

$$V_W = \text{Desde} : 1 \text{ En pasos de} : (P_W + 1) \text{ Hasta} : W \quad (3.3)$$

$$V_H = \text{Desde} : 1 \text{ En pasos de} : (P_H + 1) \text{ Hasta} : H \quad (3.4)$$

Con estos vectores definidos podemos seleccionar el corte deseado utilizando la 3.5, donde F y C son las posiciones de la fila y columna del corte que deseamos separar.

$$\text{Corte} = Im((1 : P_W) + V_W(F), (1 : P_H) + V_H(C)) \quad (3.5)$$

Finalmente cuando se haya separado el corte deseado, se procederá a normalizar a valores de 0 a 1, donde el valor máximo del Corte será 1 y el valor 0 se seguirá conservando. Esto lo

conseguimos usando la formula 3.6

$$Corte_N = \frac{Corte}{Max(Corte)} \quad (3.6)$$

3.4. Extracción de características

La extracción de características es un proceso de transformación con la cual se extraen conjuntos de datos específicos y relevantes de algo en particular, en nuestro caso imágenes, estas características pueden ser bordes, esquinas, texturas, formas, colores o patrones. Existen diferentes tipos de técnicas para llevar a cabo este proceso, dependiendo de cuál de estas características se quiera resaltar. En gran medida, estas técnicas se utilizan con la finalidad de reducir ruido, descartar redundancia de datos, mejorar imágenes, entre otros, en nuestro caso se utilizó principalmente para mejorar la eficiencia de los clasificadores, así como su precisión y especificidad.

Para extraer las características del corte normalizado ($Corte_N$), se empleó la transformada de Census [Zabih and Woodfill, 1994], que consiste esencialmente en transformar valores de píxeles a cadenas binarias. Para esto se elige una zona cuadrada o rectangular de la imagen con la condición de que la longitud de sus lados sean impares, a esta zona se le denomina comúnmente ventana, la condición sobre lados impares de la ventana se coloca para poder comparar el valor del píxel central con todos sus vecinos siguiendo la ecuación 3.7, donde p es el valor del píxel central y p' los píxeles vecinos.

$$C(p, p') = \begin{cases} 1 & Si \ p > \ p' \\ 0 & Otherwise \end{cases} \quad (3.7)$$

La longitud de esta cadena de bits depende directamente del tamaño de la ventana, por lo cual una ventana más grande otorgará una mayor resolución, pero esto no implica que se obtendrán mejores resultados. Una vez obtenida la cadena de bits, se procede a transformar ese número a decimal, normalmente esta conversión se hace con 2^i , siendo $i = (ventana)^2 - 1$. Cuando la ventana es muy grande suelen generarse número muy grandes y otros muy pequeños, lo que ocasiona que se pierda precisión al estar tan alejados unos de los otros, por esta razón se utilizó una parte de i para la parte real y otra para su parte fraccionaria como se observa en la ecuaciones 3.8 y 3.9.

$$n = \#\{Ventana\} \tag{3.8}$$

$$L(p) = \sum_{i=1, i \neq p}^n 2^{i-p} \times C(p, i) \tag{3.9}$$

El número obtenido de la conversión binario decimal (L), se guarda en la misma posición de donde se extrajo como se ve en la figura 3.5. Al completar el barrido de la transformada Census en la imagen fMRI, se obtiene una matriz cuadrada a la cual se le calcula diferentes métricas como media, varianza, kurtosis y entropía. Estas métricas serán nuestras características para clasificar, se calculan para cada uno de los cortes y se ordenan de forma que todas las características de diferentes cortes pertenecientes a una misma fMRI, estén en el mismo renglón. En su última columna está la etiqueta de la clase a la cual pertenece.

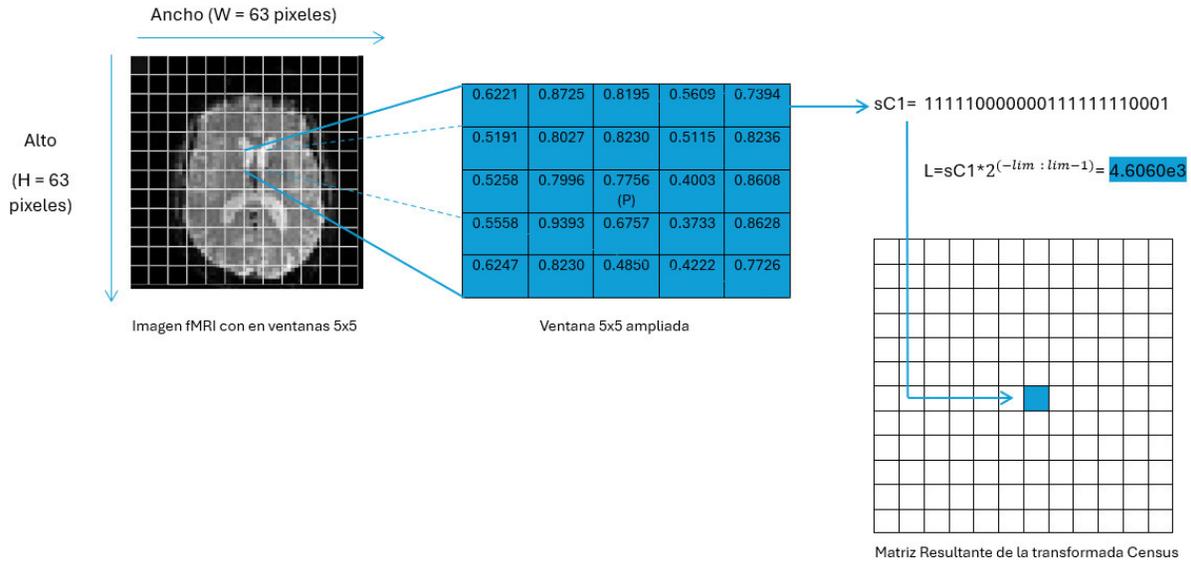


Figura 3.5. Ventana de la transformada Census

Con la finalidad de evitar filtración de conocimiento en los clasificadores se hizo un barrido denso sin sobre posición, esto quiere decir que el tamaño de paso entre cada ventana Census es del tamaño de la misma ventana, como se observa en la figura 3.6. Al realizar este barrido denso podemos extraer las características y luego separarlas entre datos de entrenamiento y

prueba para la validación del clasificador.

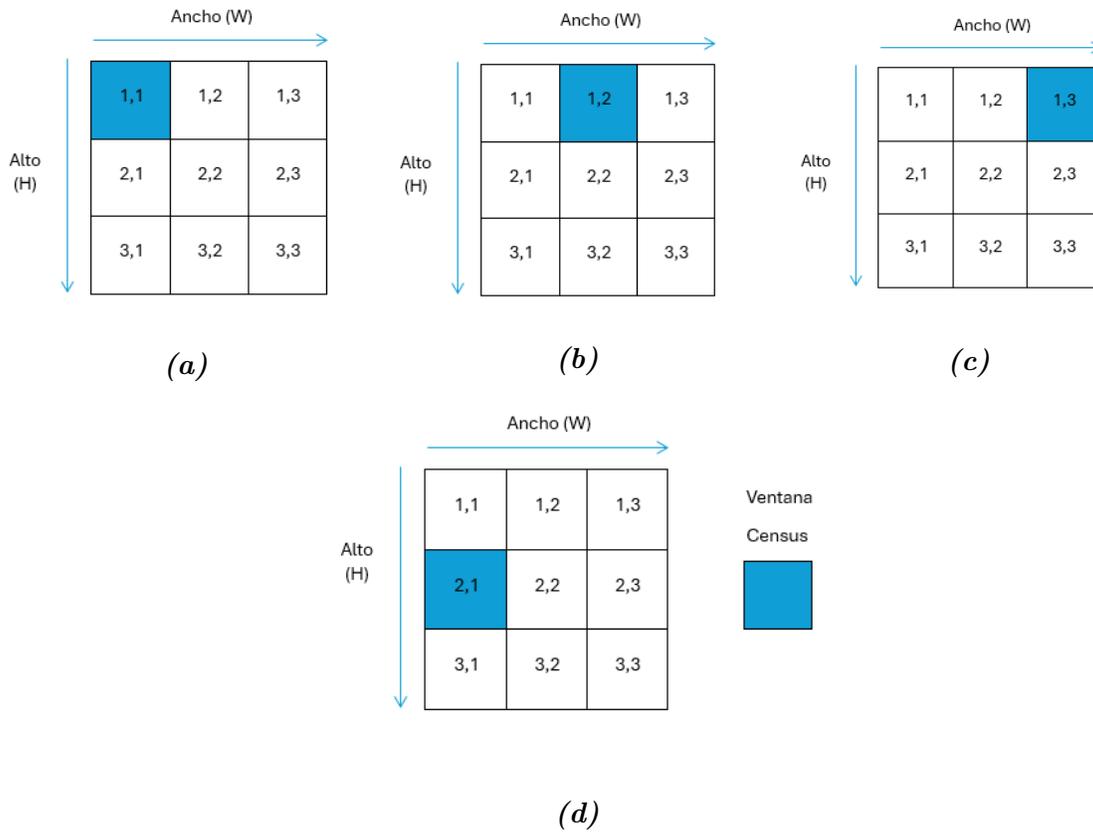


Figura 3.6. Movimiento de la ventana Census a través de la fMRI sin sobreposición

3.5. Selección de características

Con la finalidad de validar el proceso de aprendizaje del clasificador, se realiza una separación de datos en dos conjuntos conocidos como entrenamiento y validación, el primero se utiliza para construir el clasificador y el segundo para evaluar su desempeño, esta evaluación se realiza con diferentes métricas como la exactitud, precisión, especificidad, etc.

3.5.1. Datos de prueba y entrenamiento

Para realizar la separación de datos mencionada anteriormente al inicio de esta sección, se utilizó la validación hold-out, en la cual los datos se dividen en dos subconjuntos y con estos se hacen múltiples repeticiones de entrenamiento y validación para darle veracidad a este

método, en nuestro caso 30 repeticiones, es común encontrar divisiones de datos con diferentes porcentajes como 75/25, 80/20 o 90/10, los cuales varían dependiendo de la cantidad de datos que se tengan, en nuestro caso se hizo con 96.67% de datos para entrenar y el 3.33% como datos de validación.

Al tener clasificadores jerárquicos se deben hacer arreglos de los subconjuntos, estos arreglos se basan en unir dos clases para pasar de un problema ternario a uno binario, la finalidad de esto es incluir más datos de la clase con mayor número de pacientes y las clases restantes unirlas para evitar un desequilibrio evitando así un sesgo en el clasificador.

En este contexto, para la unión de los subconjuntos se realizó primero un vector que almacena las posiciones originales de los datos utilizando como referencia su clase, que en nuestro caso las clases son: PD (1), Control (2) y Prodromal (3), luego convertimos las etiquetas de la clase 3 a 2 teniendo nuestro primer clasificador binario el cual será de alto nivel. En el clasificador de nivel bajo se utilizó el vector de posiciones para separar las clases 2 y 3 de la 1 terminando así este proceso de adaptación de los datos para la clasificación jerárquica.

3.5.2. Entrenamiento de modelos

Para resolver problemas de clasificación se puede utilizar modelos de machine learning o deep learning, dichos modelos necesitan ser entrenados con datos referentes al problema a tratar, de este modo consiguen aprender patrones o generalidades del problema, logrando así que luego al tener entradas desconocidas de este problema en particular lo pueda clasificarlas correctamente.

En nuestro caso para realizar la tarea de detectar la enfermedad de parkinson se utilizaron 25 clasificadores los cuales son: Tree Fine, Tree Medium, Coarse Tree, Lineal Discriminant, Naives Bayes G, Naives Bayes K, KNN Fine, KNN Medimum, KNN Coarse, KNN Cosine, KNN Minkowski, KNN Weighted, Boosted Trees, Bagged Trees, Subspace Discriminant, SubspaceKNN, RUSBoosted Trees, Linear SVM, Quadratic SVM, Cubic SVM, Fifth SVM, Fine Gaussian SVM, Medium Gaussian SVM, Coarse Gaussian SVM, LSTM.

Al realizar el entrenamiento de estos clasificadores, se debe tener en cuenta que nuestro modelo de clasificación es jerárquico, por lo cual se deben realizar las diferentes combinaciones para determinar la mejor entre estos 25 clasificadores. Realizar la tarea de combinar los clasificadores en etapa de entrenamiento es muy costoso computacionalmente, por lo cual se

aplicó un método diferente, consiste en entrenar por separado un número determinado de veces el mismo clasificador tanto para alto como bajo nivel, esto se logró al dividir los datos como se explica en la subsección anterior, una vez terminado este proceso se procede a evaluar el clasificador y realizar las respectivas combinaciones para determinar la mejor.

3.5.3. Evaluación de desempeño

Para evaluar el desempeño de nuestros modelos entrenados primero debemos asegurar que si se hayan entrenado correctamente, para lo cual se realiza una verificación en la estructura del modelo para determinar que no esté vacío, lo que puede ocurrir debido a que el clasificador no maneja correctamente los datos de entrada y se generó algún error. Si esta vacío se descarta inmediatamente colocando un valor de 0 a todas sus métricas, sino se evalúa con los datos de prueba que fueron separados anteriormente.

Debemos tener en cuenta que es un clasificador jerárquico y es necesario hacer 2 evaluaciones las cuales corresponden al clasificador de alto y bajo nivel. Primero se evalúa el nivel alto con dos posibles respuestas, en nuestro caso 1 o 2, si la respuesta es 1 se sabe qué hace referencia a la clase PD, en caso contrario, significa que pertenece a la clase de Control o Prodromal, por lo que se transfiere esta información al clasificador de bajo nivel, el cual dará como respuesta 2 o 3 haciendo referencia a la clase de Control y Prodromal respectivamente. Al transferir la información y probar todas las combinaciones podemos tener el comportamiento de todos los clasificadores para posteriormente seleccionar la mejor.

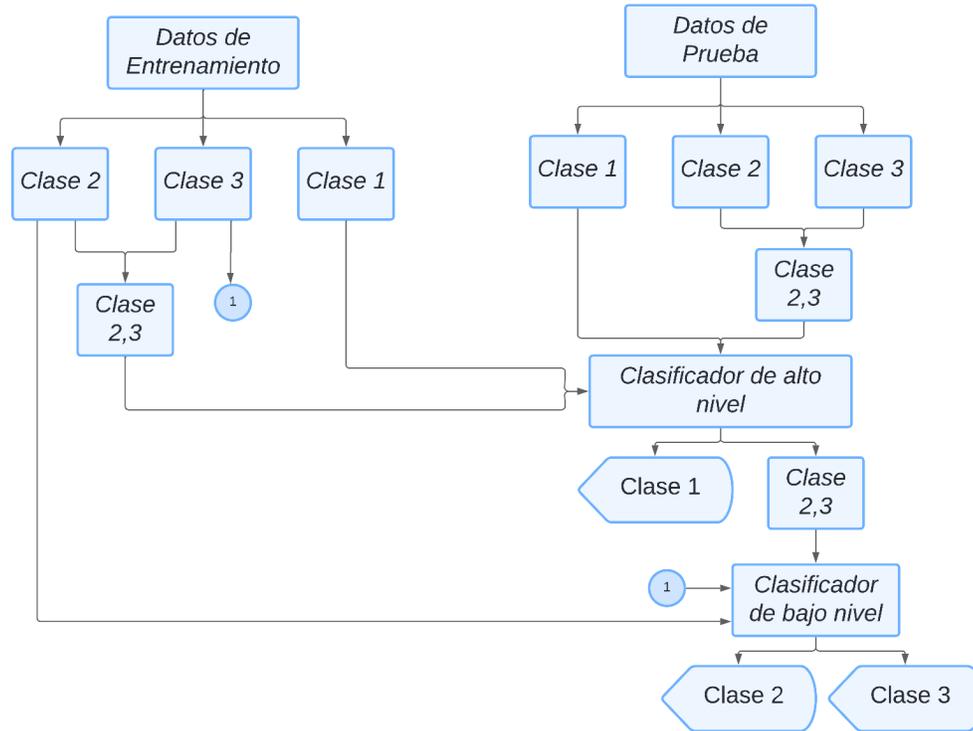


Figura 3.7. Proceso de evaluación de desempeño de los clasificadores jerárquicos

Seguidamente del proceso de evaluación, se sustituyen las predicciones de la clase 2 de clasificador de alto nivel con las predicciones 2 y 3 de clasificadores de bajo nivel, volviendo así a tener las tres clases PD (1), Control (2) y Prodromal (3). Para finalizar este proceso de evaluación, comparamos las predicciones de los clasificadores con las etiquetas originales de las clases para obtener la matriz de confusión y posteriormente sus métricas que nos proporcionan información sobre que tan buen desempeño tienen los diferentes clasificadores.

3.5.4. Generación de resultados

Una vez entrenados y evaluados cada uno de los clasificadores, seleccionamos las mejores combinaciones para representarlas gráficamente en un diagrama de caja como se observa en capítulo 4, para esto se utilizamos percentiles sobre las métricas de exactitud, precisión y especificidad.

Para calcular estos percentiles se colocaron todos los valores de estas métricas en vectores, se ordenan y se utiliza la ecuación 3.10.

$$P_k = \frac{K * n}{100} \quad \text{Para } n \text{ par.} \tag{3.10}$$

$$P_k = \frac{K * (n + 1)}{100} \quad \text{Para } n \text{ impar}$$

Donde n es el número de elementos y K el percentil que se desea calcular, este puede tomar valores desde 1 a 99. Con esta medida estadística podemos tener una idea más clara de que tan bueno fueron los resultados al clasificar y, a su vez, permite descartar todos los clasificadores que están por debajo de estas medidas haciendo que la visualización de los resultados se aprecie de mejor manera. Cabe destacar que para la exactitud se tiene un único valor, el cual se muestra en los diagramas de cajas, mientras que para la precisión y la especificidad se debe calcular para cada clase, por lo cual se tendrán 3 valores por cada una de estas 2 métricas.

Una vez designados los percentiles de las diferentes métricas, se realiza un descarte de los clasificadores que de alto y bajo nivel que cumplan con los valores de percentiles, las cuales ya se habían calculado anteriormente, de estos se guarda su tipo de clasificador y su valor de exactitud para luego ser mostrado como resultado final de la prueba.

4.1. Introducción

En este capítulo se muestran los diferentes conjuntos de pruebas que se realizaron con la finalidad de dar validez al método utilizado, para la clasificación multiclase de la Enfermedad de Parkinson utilizando la base de datos PPMI. Por lo cual se usaron clasificadores jerárquicos, en su mayoría de aprendizaje automático.

En los resultados podremos observar diagramas de cajas los cuales solo se muestra el valor de la exactitud (Accuracy) contra el clasificador jerárquico (Classifier), pero también se tiene en cuenta otras métricas como la precisión y la especificidad. En cada una de las pruebas veremos como van mejoran sus métricas de evaluación a medida que se van realizando modificaciones en sus parámetros como tamaño de ventana o número de cortes. Cabe destacar que los percentiles de las métricas tendrán un valor fijo para todo el conjunto de pruebas.

4.2. Resultados de aplicar múltiples ventanas con 9 cortes

Los resultados a mostrar se basan en el incremento del tamaño de las ventanas, las cuales van desde la más pequeña 3×3 , en aumento de números impares, hasta la más grande que para este experimento es de 21×21 . Para los valores de exactitud, precisión y especificidad se tomaron los percentiles 90%, 80% y 80% respectivamente, estos valores se utilizan como un umbral mínimo que deben cumplir los clasificadores para considerar que tienen un buen desempeño.

Cabe destacar que los resultados se presentan en forma de diagrama de cajas, estas nos ayudan a interpretar de mejor manera la distribución de los mismos. En el eje Y podemos encontrar el valor de la exactitud y en el eje X un par de números que corresponden al clasificador jerárquico, donde el primer número hace referencia al clasificador de alto nivel y el segundo al de bajo nivel. Cada clasificador se describe en la leyenda del interior de cada figura. Como ejemplo podemos observar en la figura 4.1, donde el primer par de números que encontramos es el 22-7, si observamos en la leyenda el 22 hace referencia al clasificador Fine Gaussian SVM y el 7 al KNN Fine.

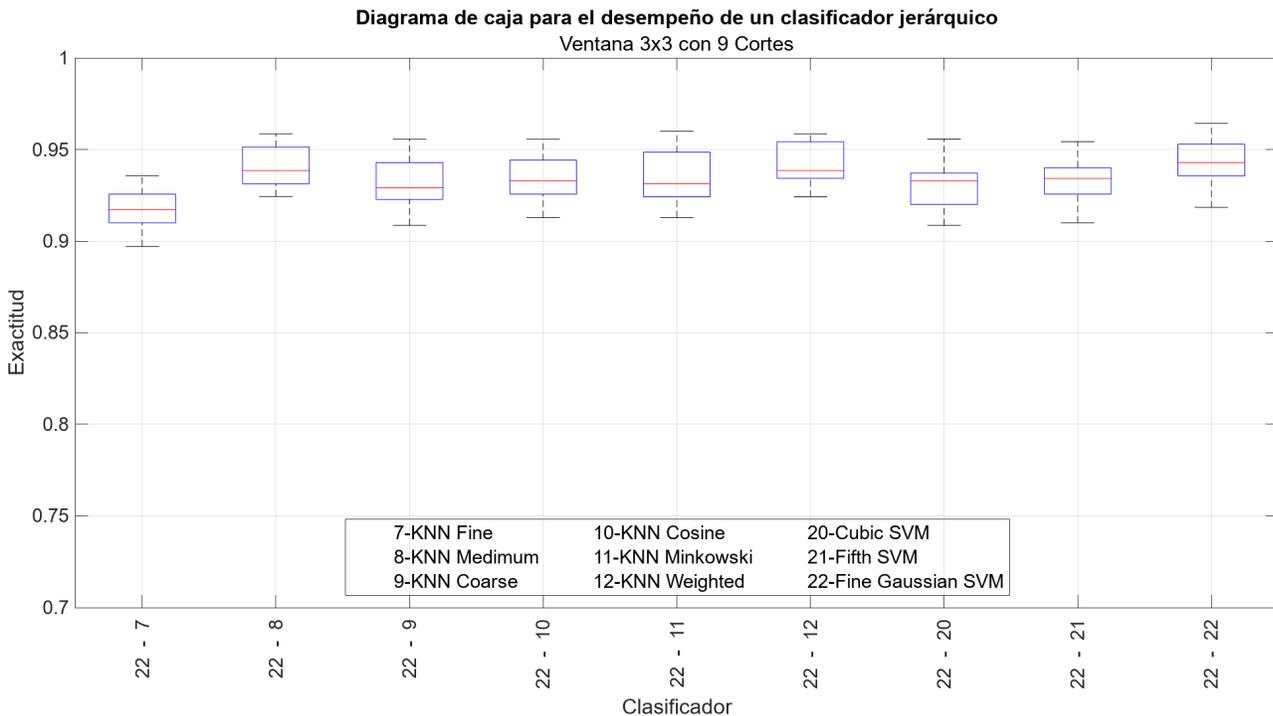


Figura 4.1. Resultados de 9 cortes de fMRI con ventana 3×3

En la figura 4.1 se puede observar que 9 clasificadores cumplen con los percentiles antes mencionados, la mayoría de estos se encuentran entre el 90% y el 95% de exactitud. Los valores de percentil 80% para la precisión son 97.74%, 79.09%, 83.12% y de especificidad 88.31%, 85.86% y 79.72% para las clases de control, prodromal y PD respectivamente. Con esto podemos afirmar que de cada 100 pacientes al menos 90 de ellos tendrán una predicción correcta. De igual manera al tener una precisión y especificidad alta podemos asegurar que no hay ningún sesgo hacia una clase en particular. Es conveniente destacar al clasificador Fine Gaussian SVM - KNN Medium de todo el conjunto de 9 clasificadores, ya que estos tienen la mejor exactitud y su IQR es menor.

A continuación se presentan las gráficas de las pruebas restantes en diagramas de caja:

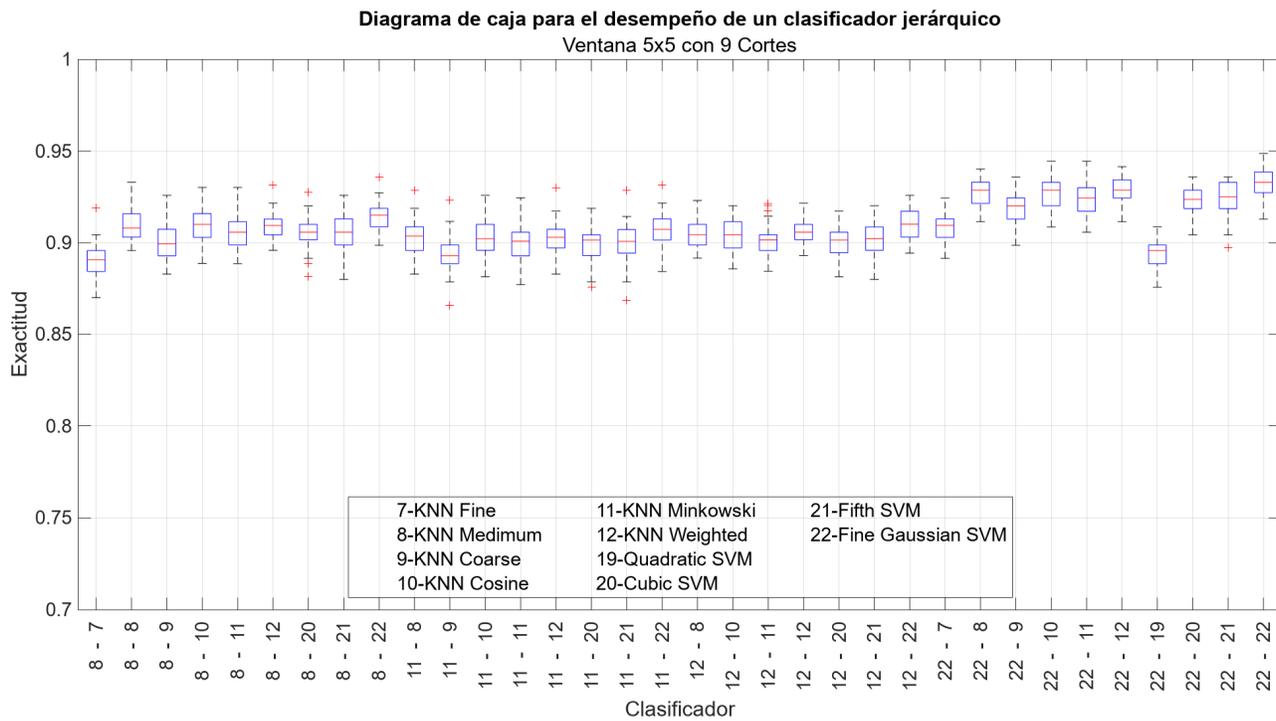


Figura 4.2. Resultados de 9 cortes de fMRI con ventana 5×5

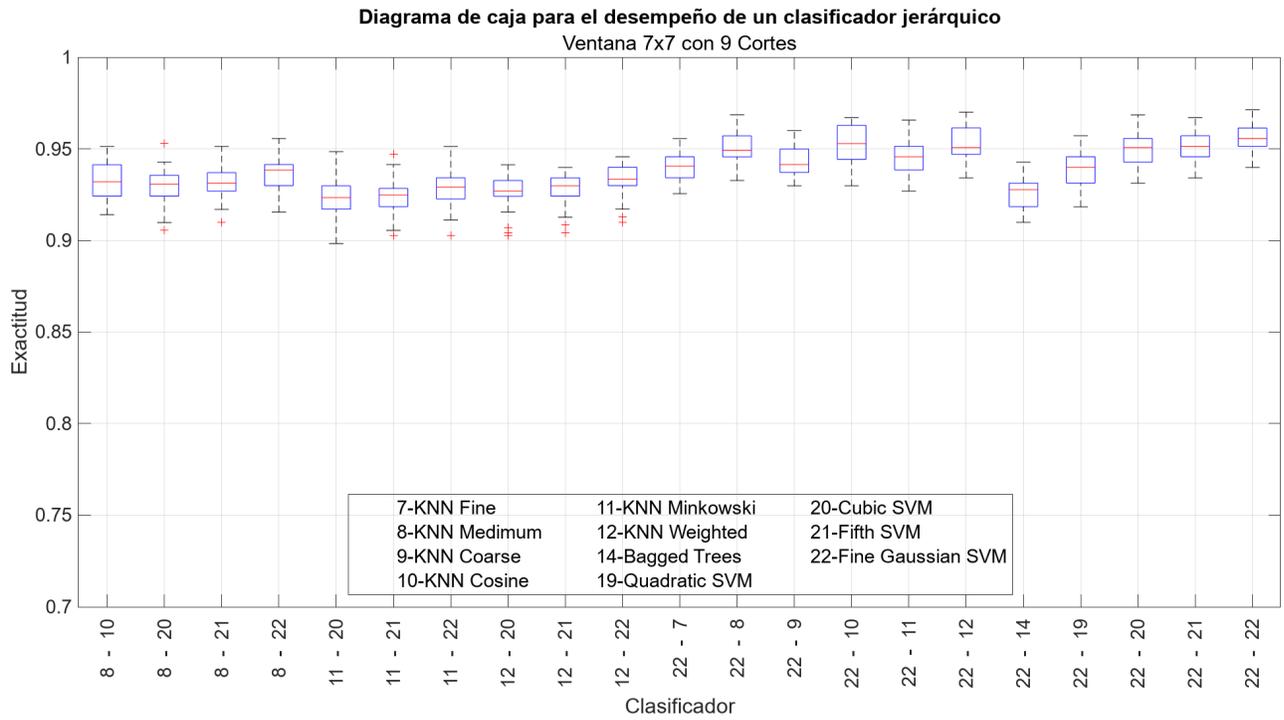


Figura 4.3. Resultados de 9 cortes de fMRI con ventana 7×7

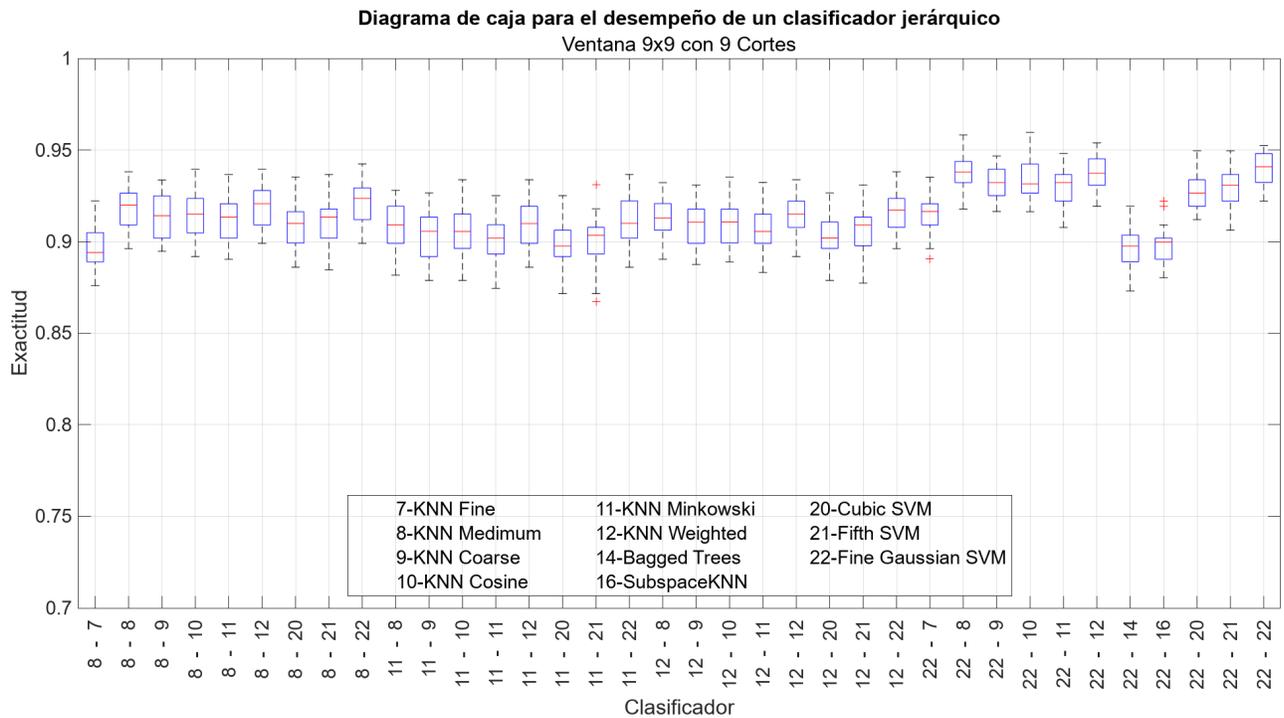


Figura 4.4. Resultados de 9 cortes de fMRI con ventana 9×9

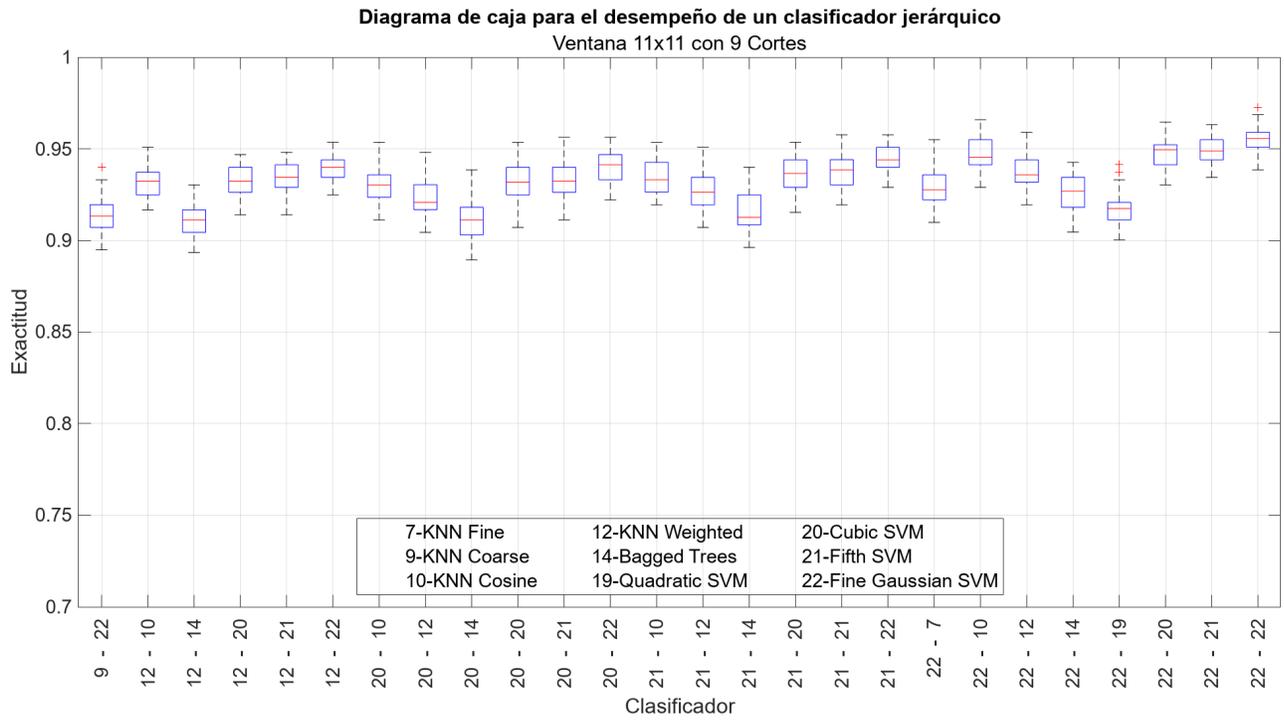


Figura 4.5. Resultados de 9 cortes de fMRI con ventana 11×11

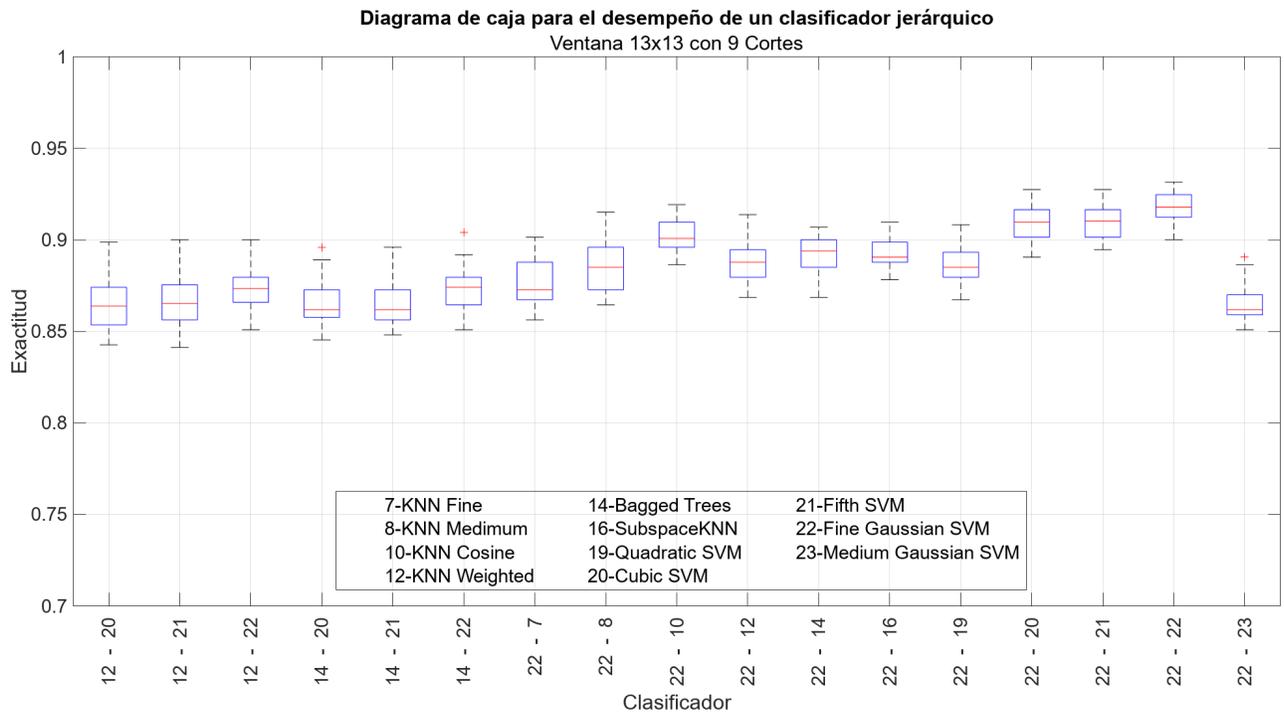


Figura 4.6. Resultados de 9 cortes de fMRI con ventana 13×13

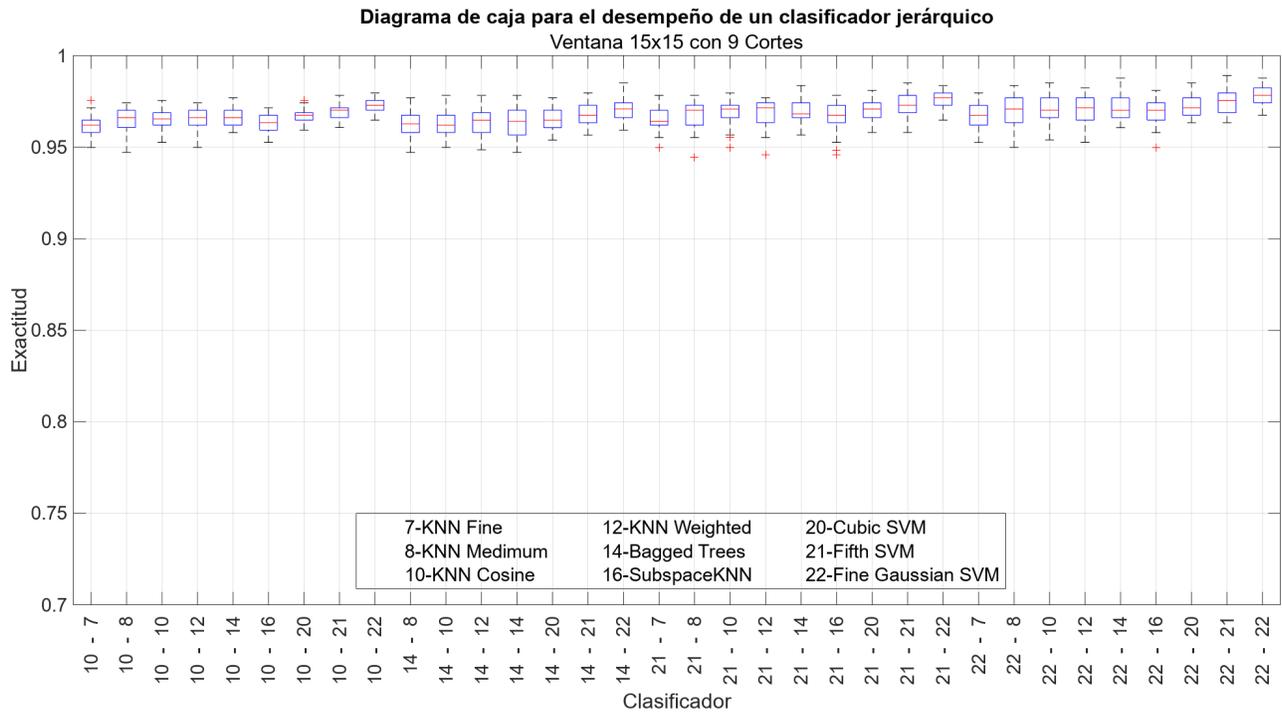


Figura 4.7. Resultados de 9 cortes de fMRI con ventana 15×15

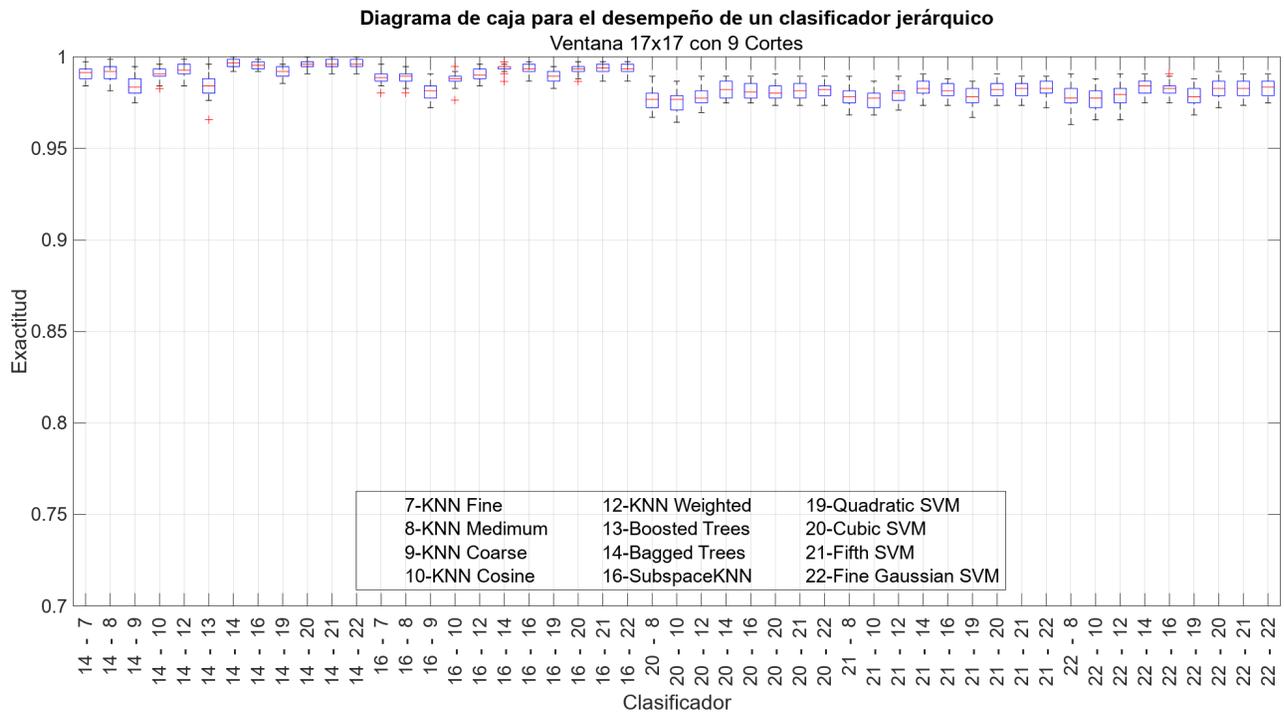


Figura 4.8. Resultados de 9 cortes de fMRI con ventana 17×17

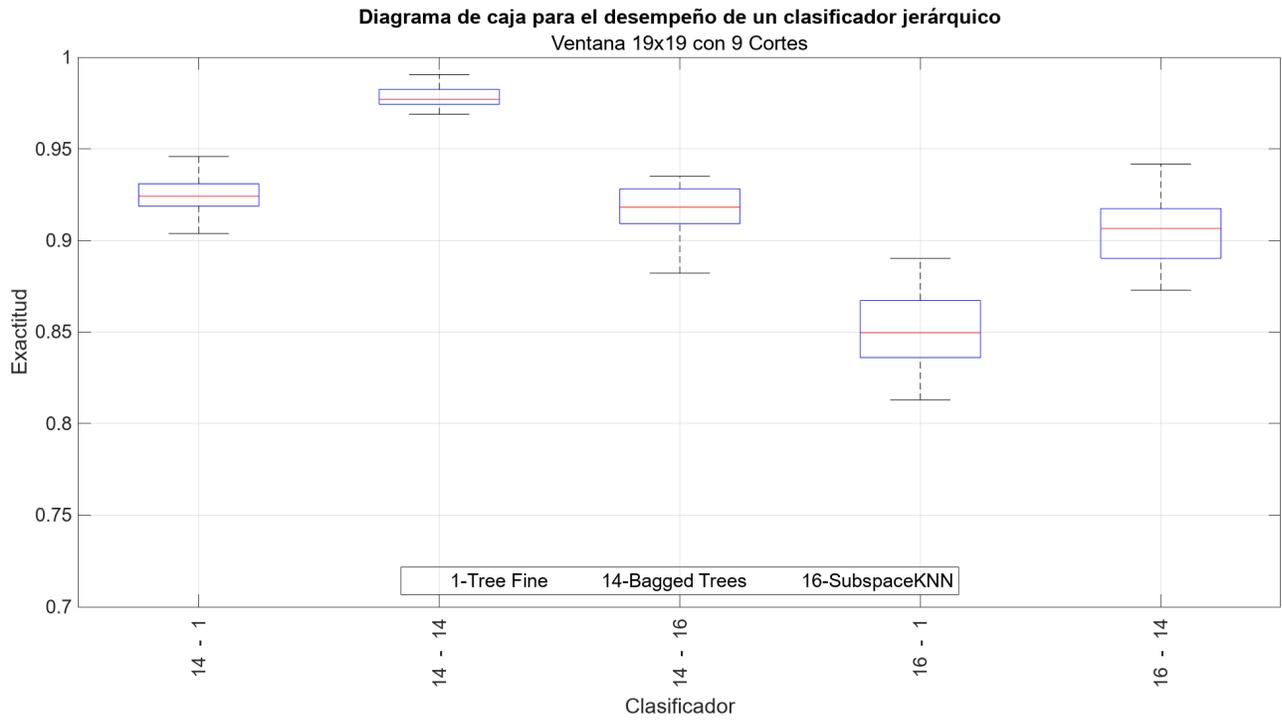


Figura 4.9. Resultados de 9 cortes de fMRI con ventana 19×19

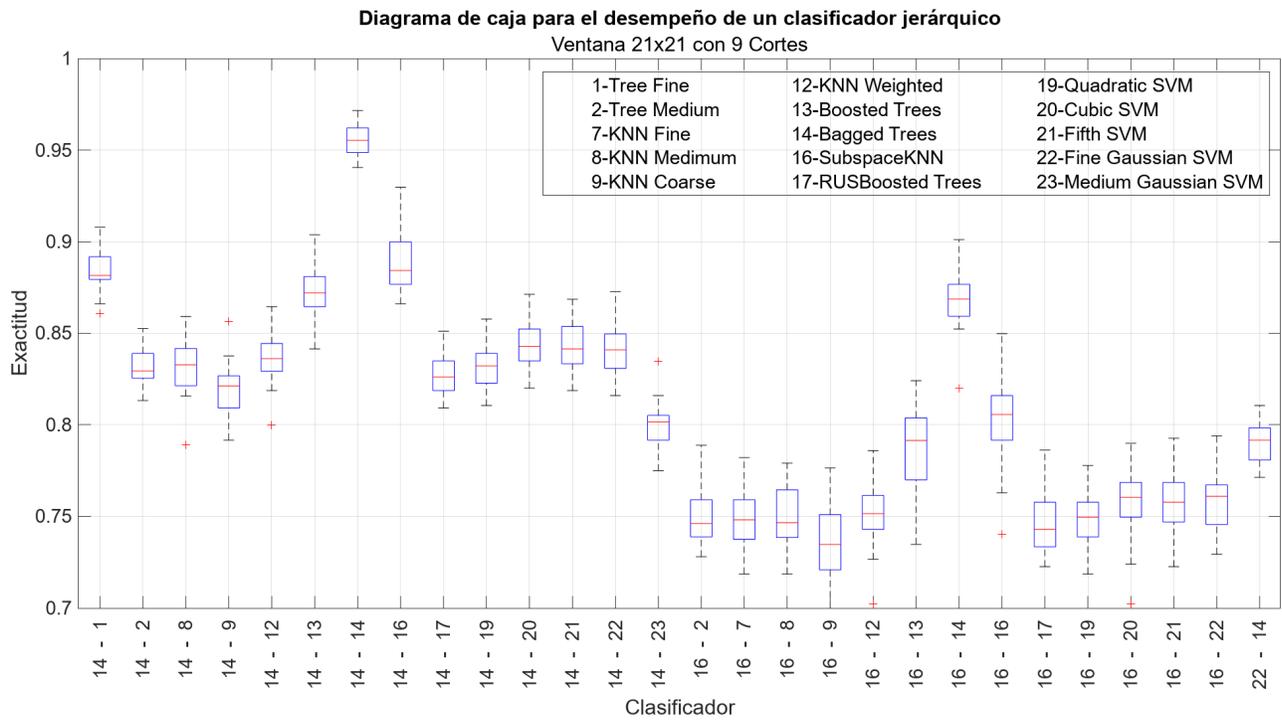


Figura 4.10. Resultados de 9 cortes de fMRI con ventana 21×21

Como se puede observar en la figura 4.10, a medida que el tamaño de la ventana aumenta

mejora la exactitud de clasificación, alcanzando un valor máximo en la ventana 17×17 de la figura 4.8. Sin embargo, este comportamiento no se cumple en todos los casos, como por ejemplo la figura 4.4 y 4.6, las cuales corresponden a las ventanas de 9×9 y 13×13 , en las cuales el porcentaje de exactitud disminuye notablemente. El peor caso se evidencia en la ventana de 13×13 la cual decae de un rango de 88 % - 96 % a 84 % - 93 % en comparación con la figura anterior 4.5 de la ventana 11×11 .

De manera similar, después de la ventana 17×17 , la respuesta de los clasificadores demuestran ser más inestables ya que sus porcentajes de clasificación van desde un valor menor al 70 % hasta 97 % en el caso de la ventana 21×21 correspondiente a la figura 4.10.

En la tabla 4.1, se comparan las medianas del desempeño de los clasificadores, podemos corroborar de forma numérica el comportamiento mencionado anteriormente. Se observa como a medida que aumenta el tamaño de la ventana su exactitud mejora notablemente.

Tabla 4.1. Tabla comparativa del desempeño de los clasificadores a medida que aumenta el número de ventana con 9 cortes.

Clasificador	3×3	5×5	7×7	9×9	11×11	13×13	15×15	17×17
22-Medium Gaussian SVM	93.85	92.86	94.92	93.80	—	88.51	97.02	97.75
8-KNN Medium								
22-Medium Gaussian SVM	93.85	92.86	95.06	93.73	93.58	88.78	97.16	97.95
12-KNN Weighted								
22-Medium Gaussian SVM	93.28	92.86	95.28	93.15	94.54	90.08	97.09	97.75
10-KNN Cosine								
22-Medium Gaussian SVM	94.29	93.29	95.56	94.08	95.56	91.79	97.83	98.35
22-Medium Gaussian SVM								
14-Bagged Trees	—	—	—	—	—	—	96.41	99.67
14-Bagged Trees								
14-Bagged Trees	—	—	—	—	—	86.18	96.75	99.60
21-Fifth SVM								

4.3. Resultados de aplicar múltiples ventanas con 15 cortes

Otra etapa de resultados realizados, consistió en aumentar el numero de cortes de prueba hasta 15 y probar el desempeño de la metodología. En esta sección se ilustran los diagramas de cajas resultantes de ir aumentando el tamaño de la ventana, pero esta vez hasta la ventana 17×17 , ya que en la prueba anterior pudimos notar que después de esta se genera inestabilidad. De igual forma se usarán los percentiles 90 %, 80 % y 80 % de exactitud, precisión y especificidad, respectivamente.

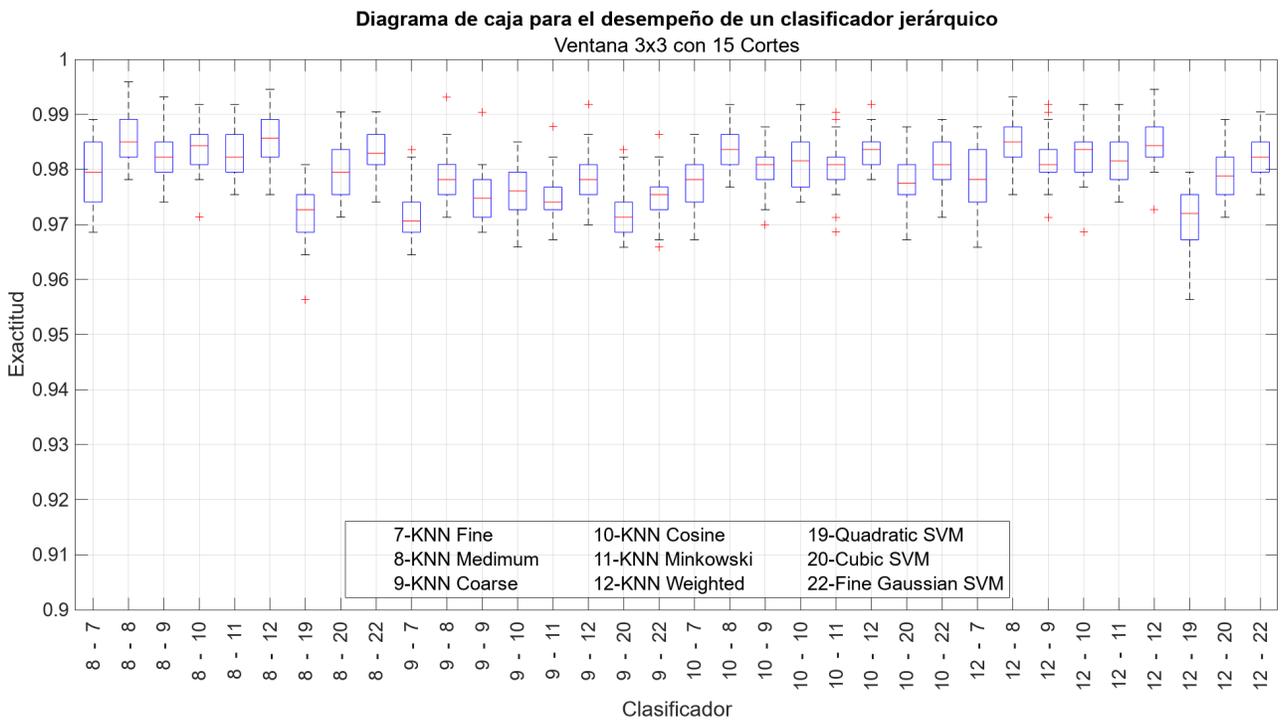


Figura 4.11. Resultados de 15 cortes de fMRI con ventana 3×3

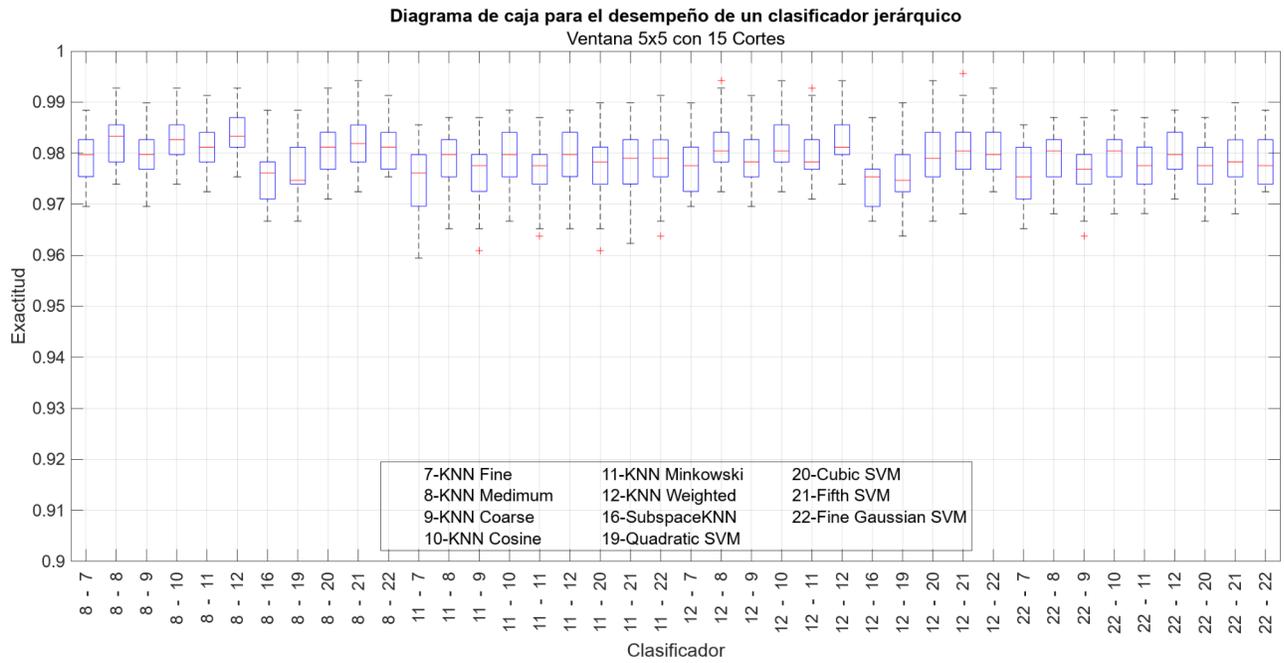


Figura 4.12. Resultados de 15 cortes de fMRI con ventana 5×5

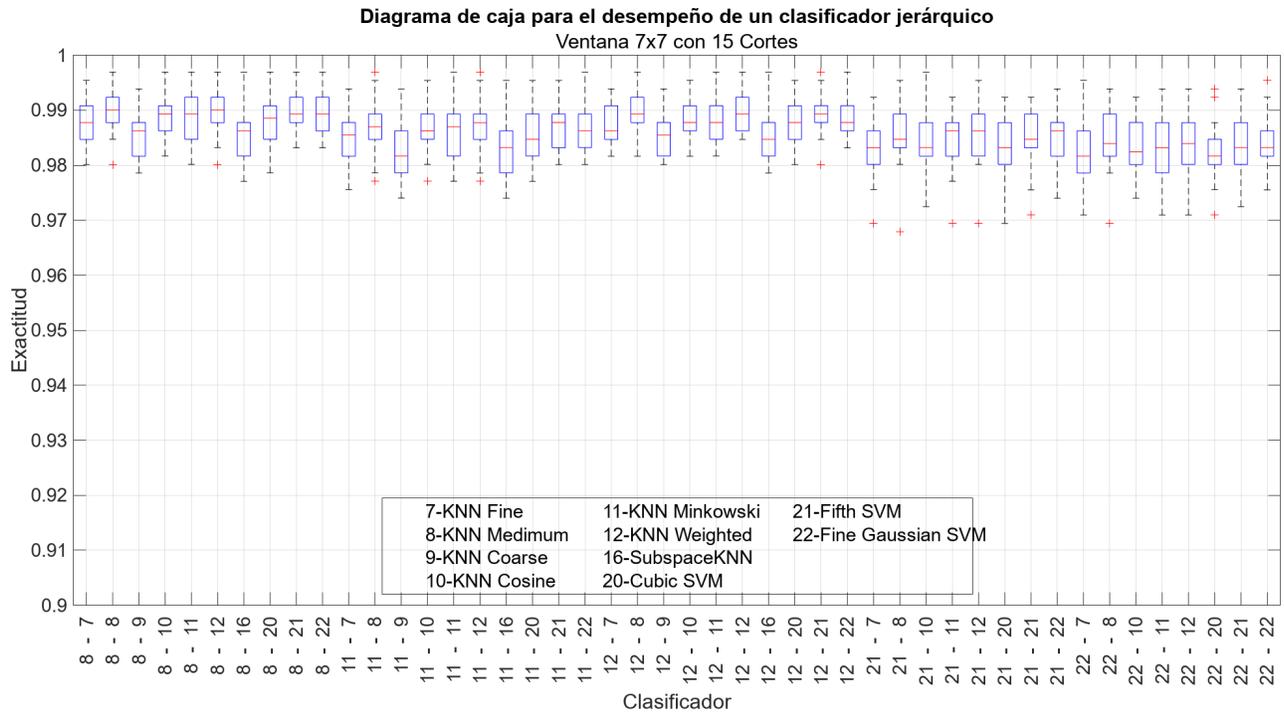


Figura 4.13. Resultados de 15 cortes de fMRI con ventana 7×7

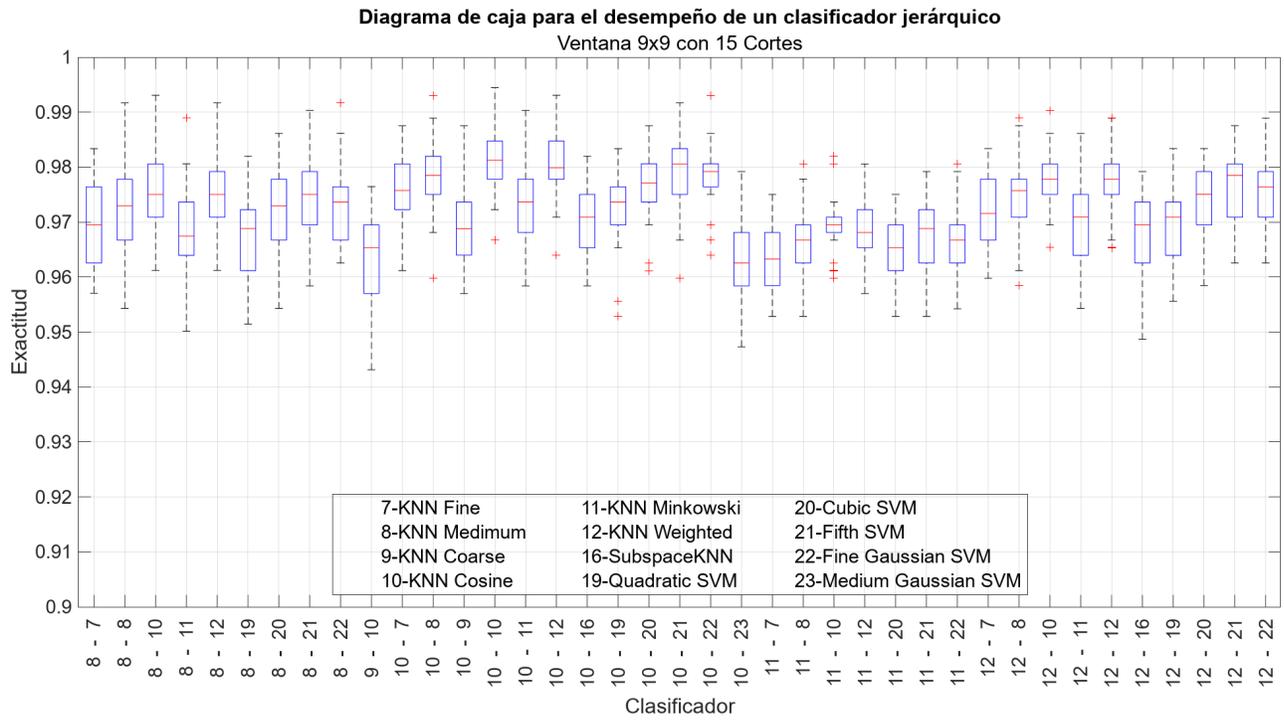


Figura 4.14. Resultados de 15 cortes de fMRI con ventana 9×9

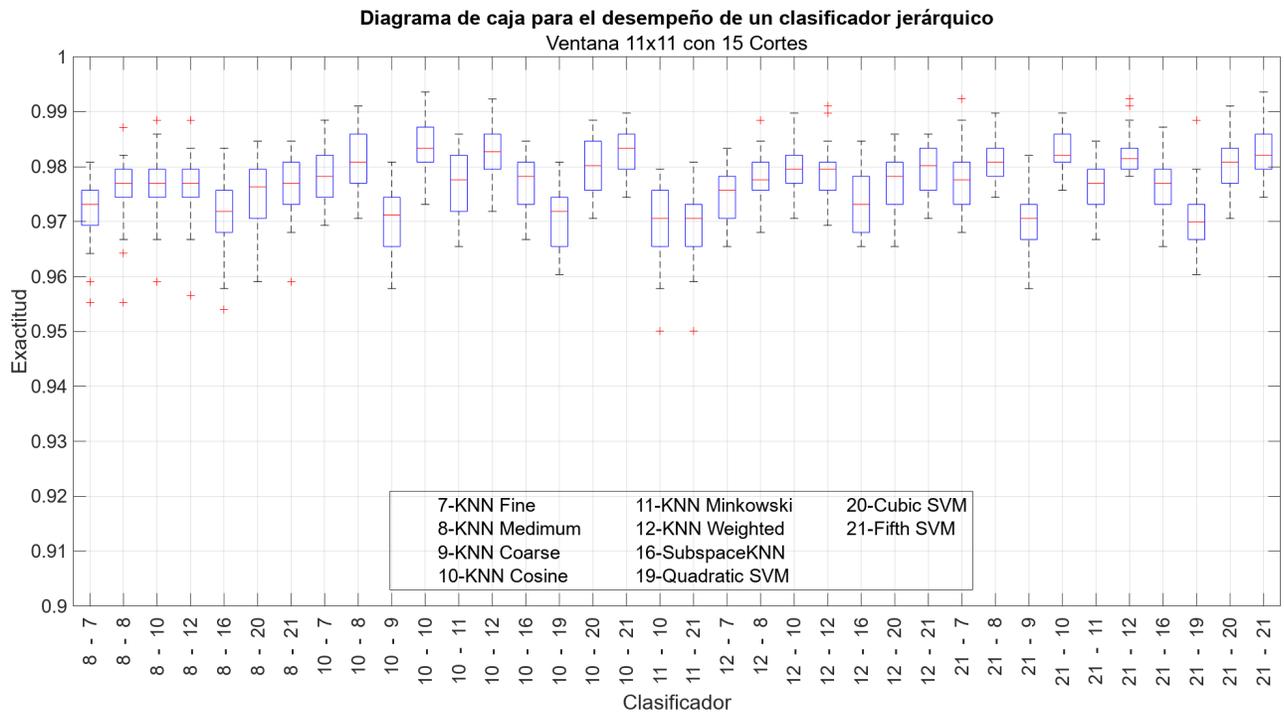


Figura 4.15. Resultados de 15 cortes de fMRI con ventana 11×11

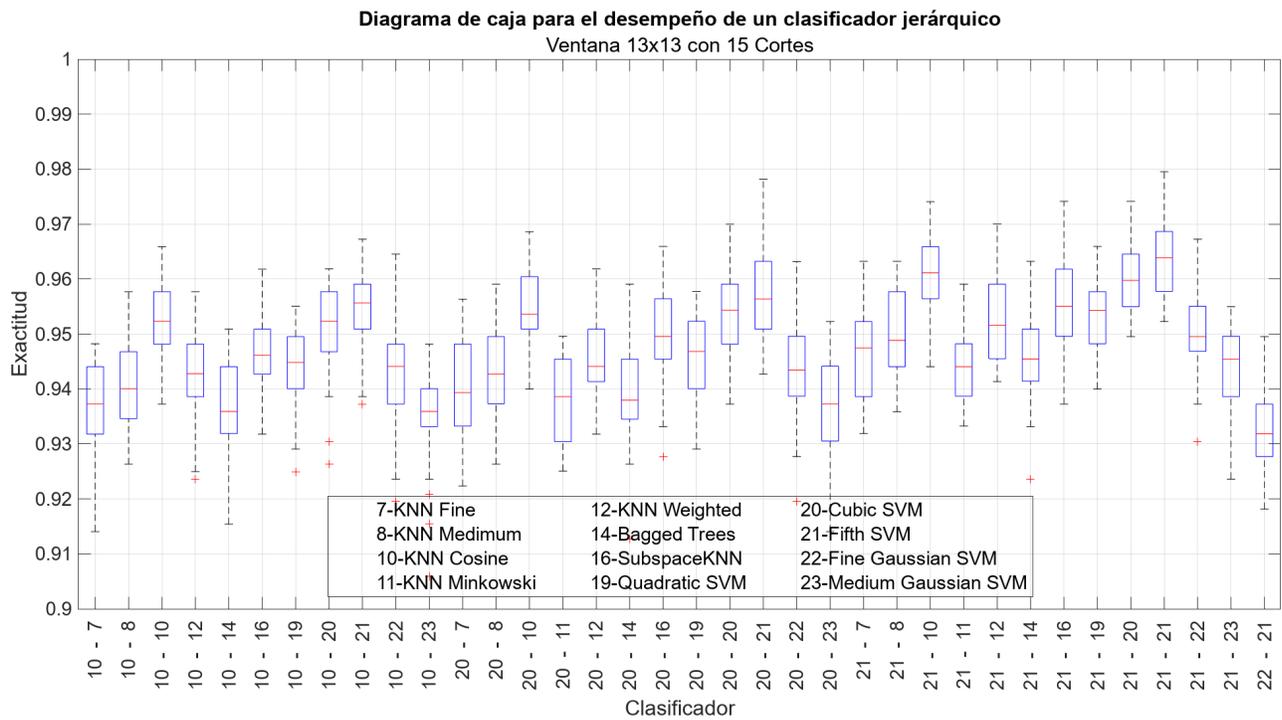


Figura 4.16. Resultados de 15 cortes de fMRI con ventana 13×13

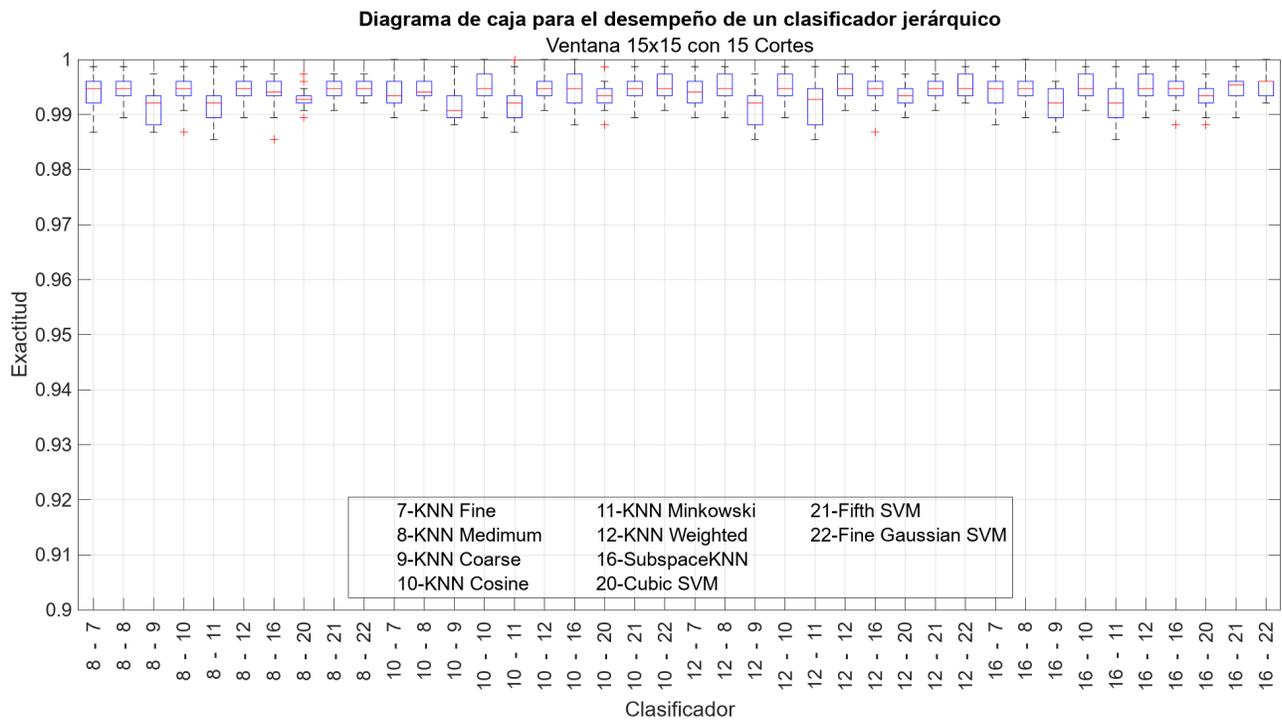


Figura 4.17. Resultados de 15 cortes de fMRI con ventana 15×15

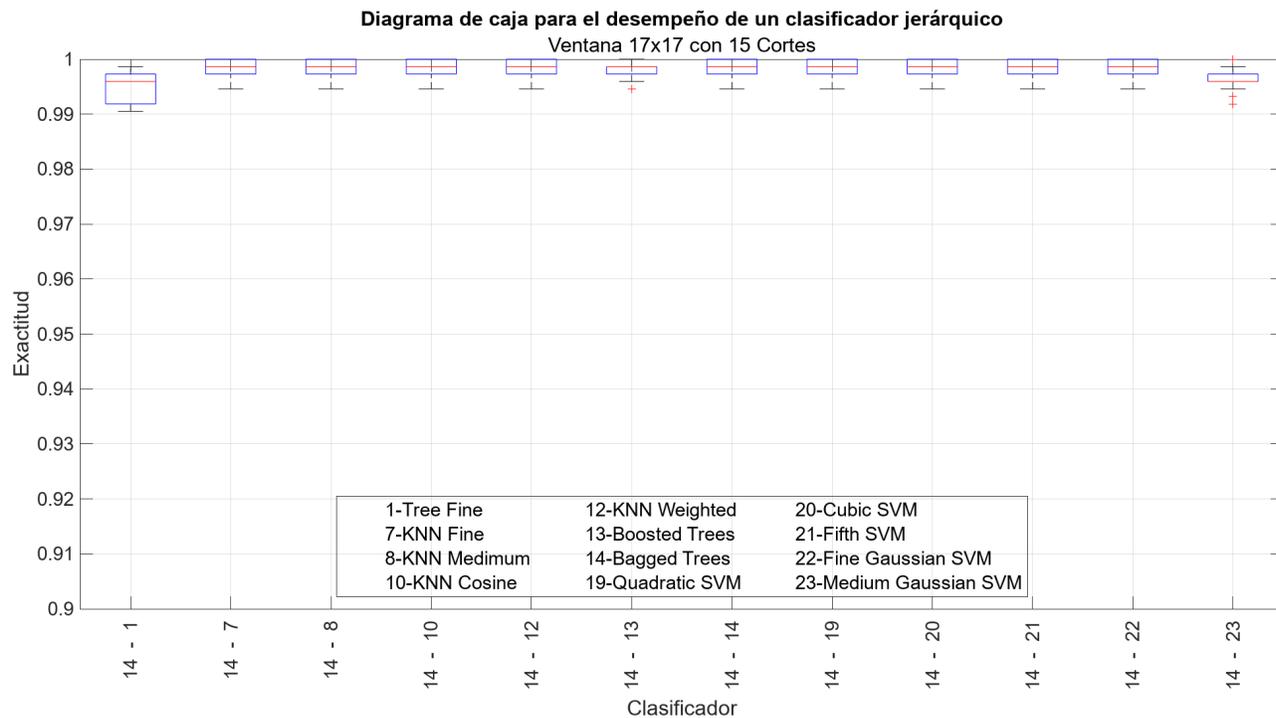


Figura 4.18. Resultados de 15 cortes de fMRI con ventana 17×17

La figura 4.18 observamos que al abarcar un mayor número de cortes de las fMRI, se obtiene como resultado un considerable incremento en el porcentaje de exactitud y en el número de clasificadores que cumplen con los requerimientos antes mencionados.

Al comparar las figuras 4.1 y 4.11, las cuales corresponden a la ventana más pequeña de la prueba de 9 y 15 cortes, podemos constatar que la exactitud mejoro de un rango de 89 % - 96 % a 96.5 % - 99.6 %, de la misma forma, esto también ocurre en las demás métricas, en el caso del percentil 80 % de la precisión paso de 97.74 %, 79.09 %, 83.12 % a 98.29 %, 89.01 %, 93.29 % y percentil 80 % de especificidad 88.31 %, 85.86 %, 79.72 % a 94.34 %, 94.06 %, 90.95 % para las clases de control, prodromal y PD respectivamente. También podemos observar en la figura 4.11, que porcentaje más bajo de la prueba de 15 cortes es mejor que el porcentaje más alto de la prueba de 9 cortes de la figura 4.8. Así mismo, la cantidad de clasificadores aumento de 9 a 34, lo que indica que las características encontradas en los cortes que se agregaron aportan información que ayuda a una mejor separación de clases por parte de los clasificadores.

Además en la tabla 4.2 podemos constatar, que sigue el mismo comportamiento que en la prueba anterior, en la que al ir incrementando la ventana mejora su porcentaje de clasificación exceptuando de igual manera a las ventanas de 9×9 y 13×13 . Nuevamente el porcentaje

de mejor clasificación se logra en la ventana de 17×17 siendo su exactitud prácticamente del 100% en la mayoría de clasificadores.

Tabla 4.2. Tabla comparativa del desempeño de los clasificadores a medida que aumenta el número de ventana con 15 cortes

Clasificador	3×3	5×5	7×7	9×9	11×11	13×13	15×15	17×17
8-KNN Medium 8-KNN Medium	98.50	98.34	99.01	97.30	97.70	—	99.47	—
10-KNN Cosine 12-KNN Weighted	98.36	—	—	97.99	98.27	94.28	99.47	—
8-KNN Medium 12-KNN Weighted	98.57	98.34	99.01	97.50	97.70	—	99.47	—
12-KNN Weighted 8-KNN Medium	98.50	98.06	98.93	97.57	97.76	—	99.47	—
12-KNN Weighted 12-KNN Weighted	98.12	98.12	98.93	97.78	97.95	—	99.47	—
14-Bagged Trees 14-Bagged Trees	—	—	—	—	—	—	—	99.86
14-Bagged Trees 8-KNN Medium	—	—	—	—	—	—	—	99.86
14-Bagged Trees 21-Fifth SVM	—	—	—	—	—	—	—	99.86

4.4. Resultados de combinación de ventanas

Con la finalidad de mejorar aún más el porcentaje de clasificación y corroborar la influencia que tiene el número de cortes en este porcentaje, se combinaron las dos mejores ventanas, las cuales como ya se ha podido observar en las pruebas anteriores, son las ventanas de 15×15 y 17×17 . Así mismo, se aumentó el número de cortes, desde 9 hasta 15 en saltos de dos en dos. Los resultados obtenidos se muestran a continuación.

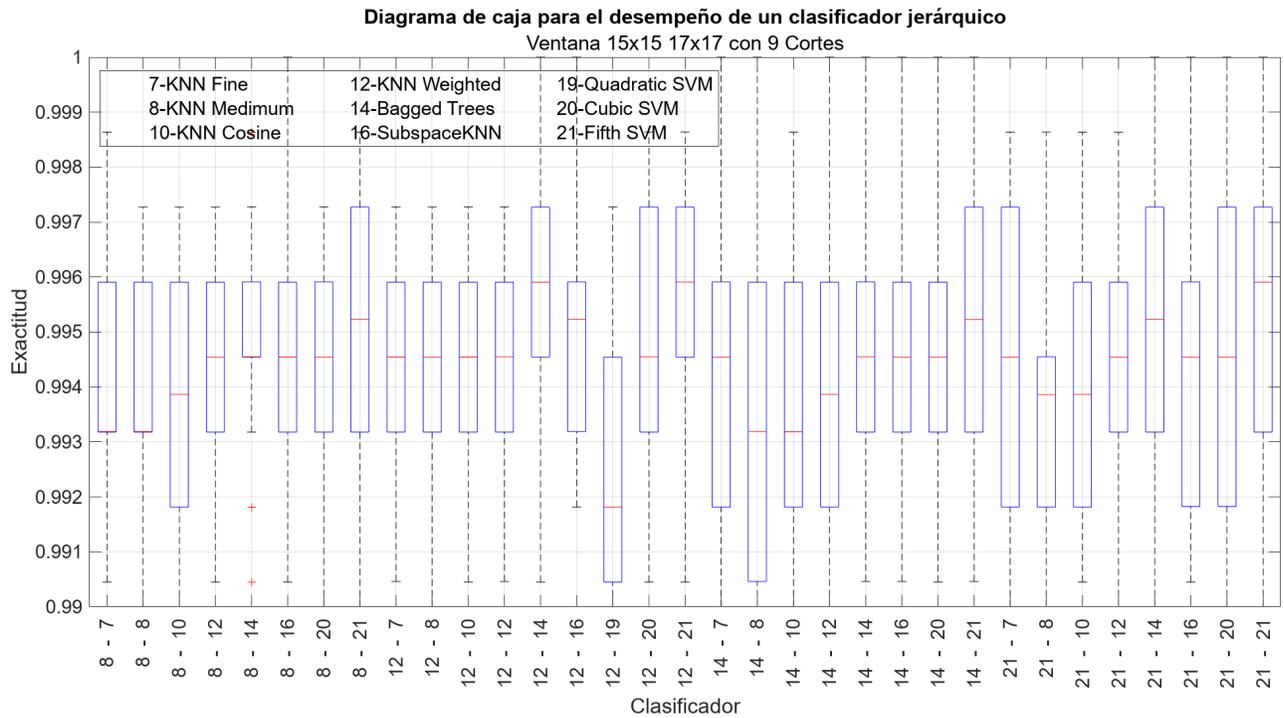


Figura 4.19. Resultados de combinar las ventanas 15×15 y 17×17 con diferentes cortes 9 cortes fMRI.

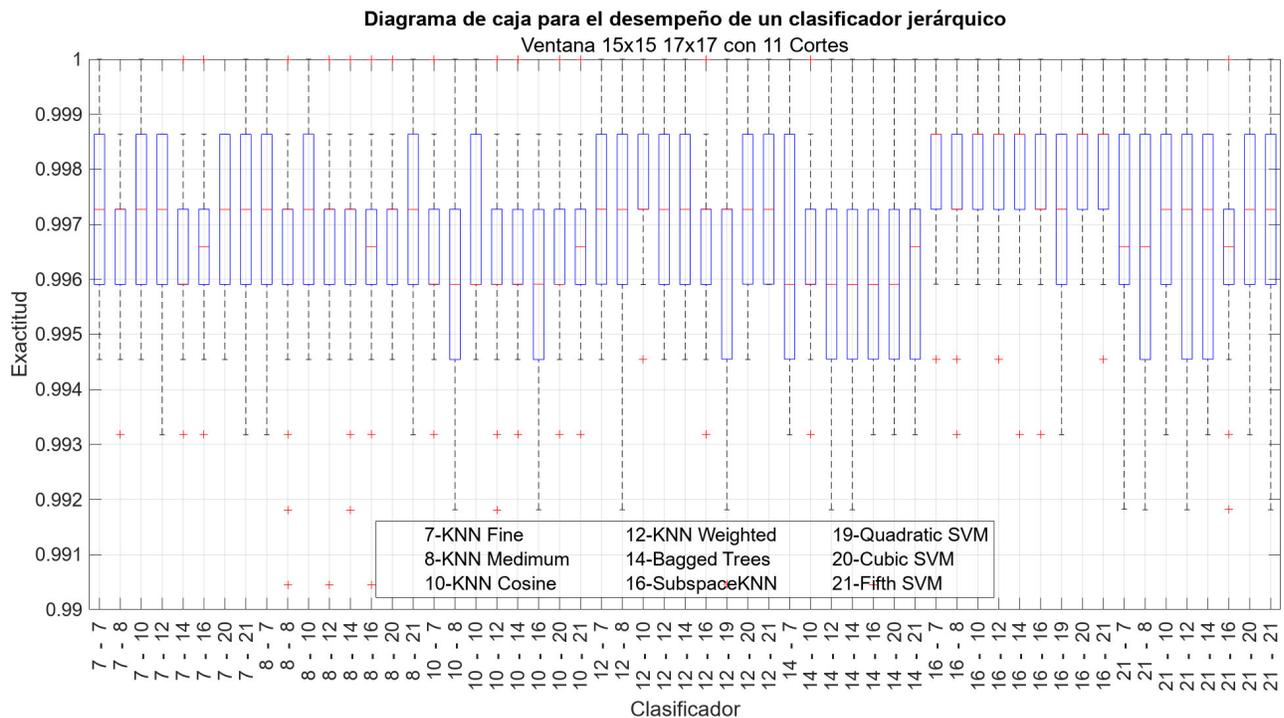


Figura 4.20. Resultados de combinar las ventanas 15×15 y 17×17 con diferentes cortes 11 cortes fMRI.

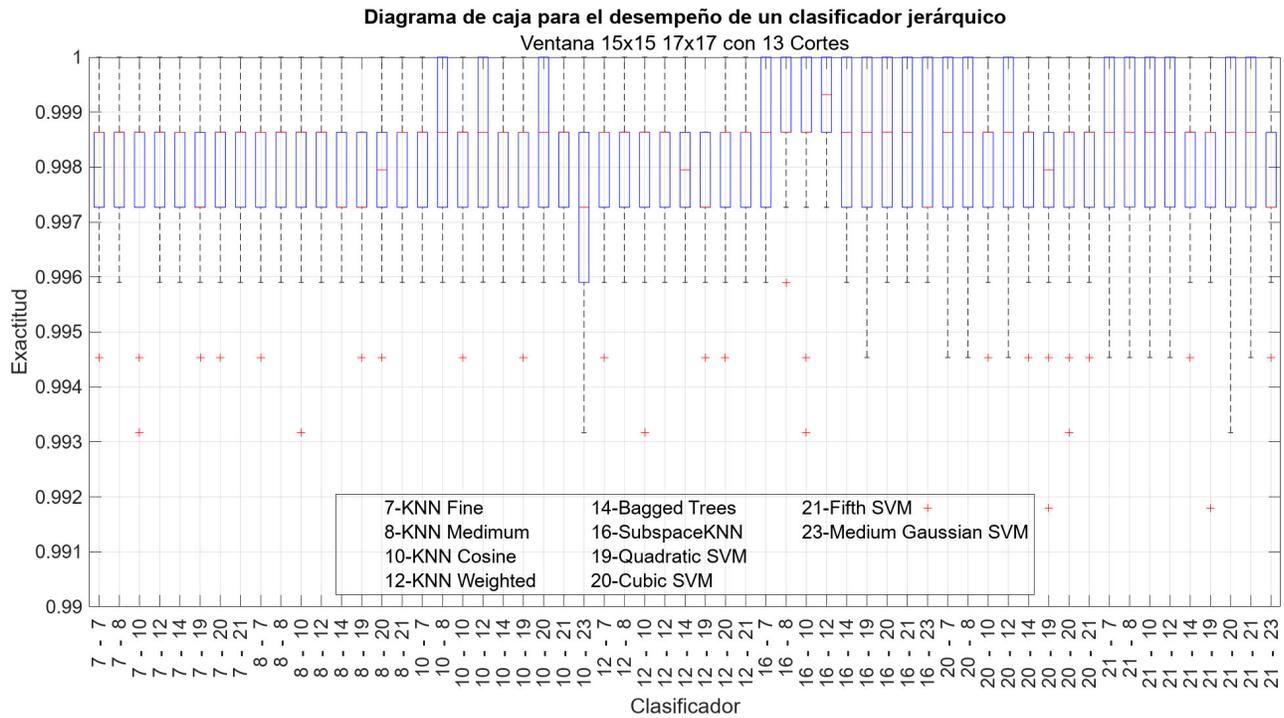


Figura 4.21. Resultados de combinar las ventanas 15×15 y 17×17 con diferentes cortes 13 cortes fMRI.

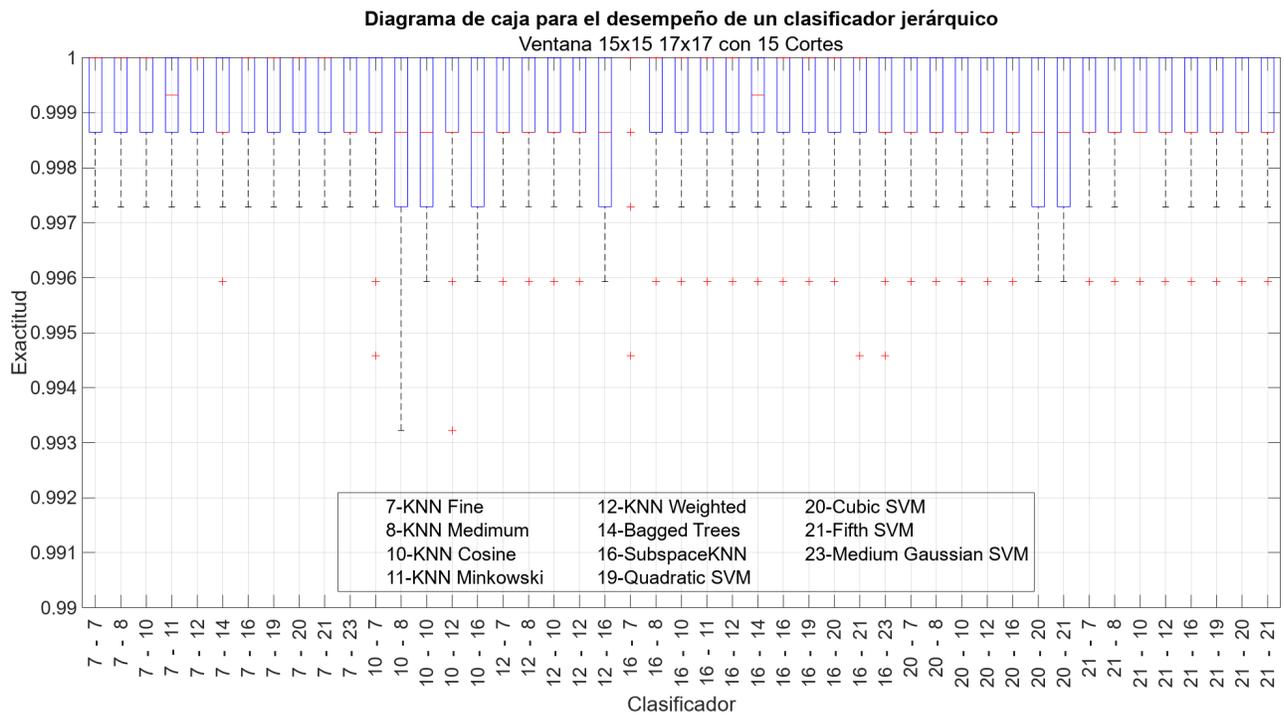


Figura 4.22. Resultados de combinar las ventanas 15×15 y 17×17 con diferentes cortes 15 cortes fMRI.

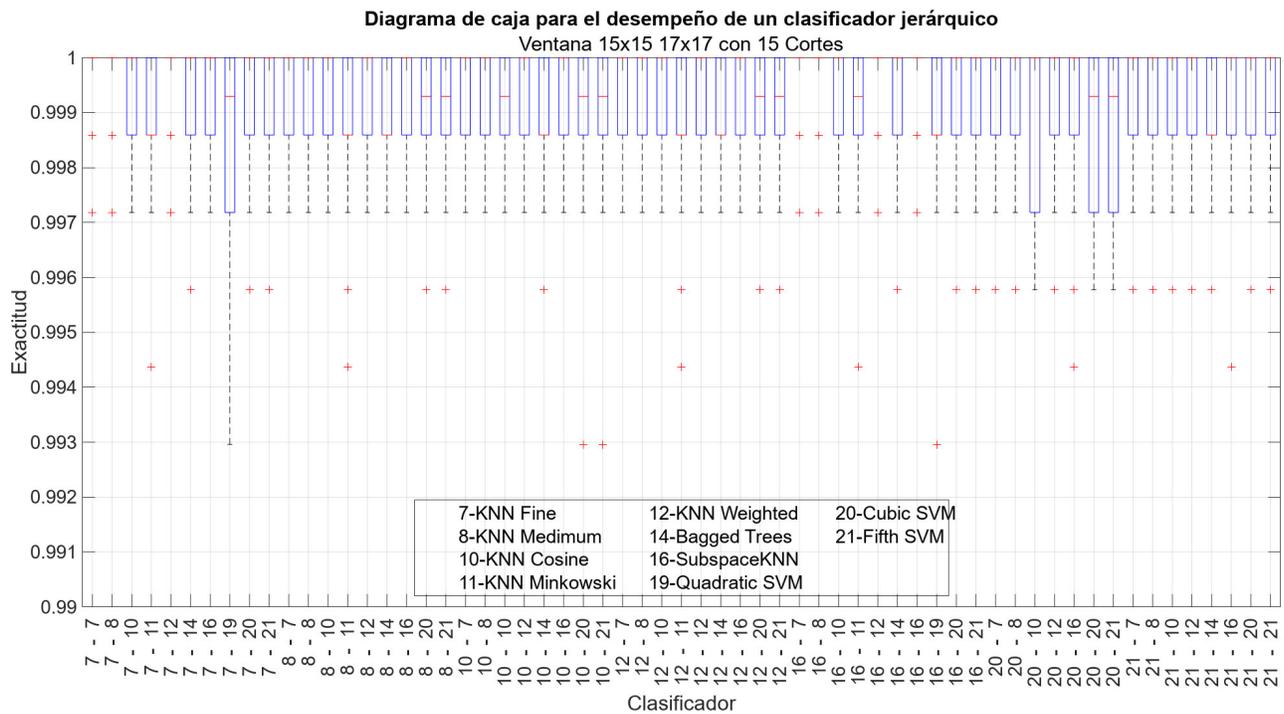


Figura 4.23. Resultados de combinar las ventanas 15×15 y 17×17 con diferentes cortes 15 cortes fMRI.

En la figura 4.19, corresponde a la combinación de ventanas 15×15 y 17×17 con 9 cortes, en esta se consiguió un porcentaje de exactitud que esta entre el 99 % y 100 % con percentil 80 % para la precisión y especificidad de 99.16 %, 94.47 %, 95.26 % y 98.59 %, 98.62 %, 98.06 % respectivamente. Al compararlo con la figura 4.8, la cual es el mejor resultado del conjunto de pruebas de 9 cortes, se logra apreciar una mejora tanto en su exactitud como en el IQR con lo que podemos afirmar que al combinar estas 2 ventanas si se consiguen mejores resultados.

Así mismo, al ir aumentando el número de cortes la mediana de los clasificadores aumenta hasta llegar al corte 15 donde su mediana en la mayoría de los casos es del 100 %, De igual forma, se logra apreciar que algunos clasificadores como el KNN Fine - KNN Medium, Subspace KNN - KNN Cosine y Subspace KNN - KNN Fine dan como valor mínimo y máximo 100 % de exactitud con outliers de 99.7 % como se ve en la figura 4.22 y 4.23.

Sin embargo, una de las desventajas de usar esta metodología es el tiempo de cómputo que casi se duplica (de 4.72 a 8.77 horas) debido al uso de las 2 ventanas, de igual manera, por la forma como se extraen las características, se genera un desbalance de clases con lo cual su precisión baja del percentil 80 % a 70 % para el caso de 11 cortes y a 60 % para los casos de 13 y 15 cortes.

En la tabla 4.3 se aprecia de forma numérica que el incremento número de cortes influye notablemente en el rendimiento de los clasificadores.

Tabla 4.3. Tabla comparativa del desempeño de los clasificadores a medida que aumenta el número de cortes con ventajas fijas de 15×15 y 17×17

Clasificador	9 Cortes	11 Cortes	13 Cortes	15 Cortes
12-KNN Weighted 14-Bagged Tree	99.59	99.73	99.80	99.86
12-KNN Weighted 21-Fifth SVM	99.59	99.73	99.86	99.93
14-Bagged Tree 21-Fifth SVM	99.52	99.66	—	—
21-Fifth SVM 21-Fifth SVM	99.59	99.73	99.86	100
12-KNN Weighted 16-SubspaceKNN	99.52	99.73	—	100
16-SubspaceKNN 7-KNN Fine	—	99.86	99.86	100
16-SubspaceKNN 8-KNN Medium	—	99.73	99.86	100
16-SubspaceKNN 12-KNN Weighted	—	99.86	99.93	100

4.5. Unión de la clase de control y prodromal

Como se describió en la metodología y para aprovechar la clasificación jerárquica de mejor manera, se muestran los resultados en la figura 4.27 en la que se unen las 2 clases más pequeñas las cuales son control y prodromal. Logrando así que los clasificadores tengan una mayor generalidad del problema al incluir más muestras de la clase PD.

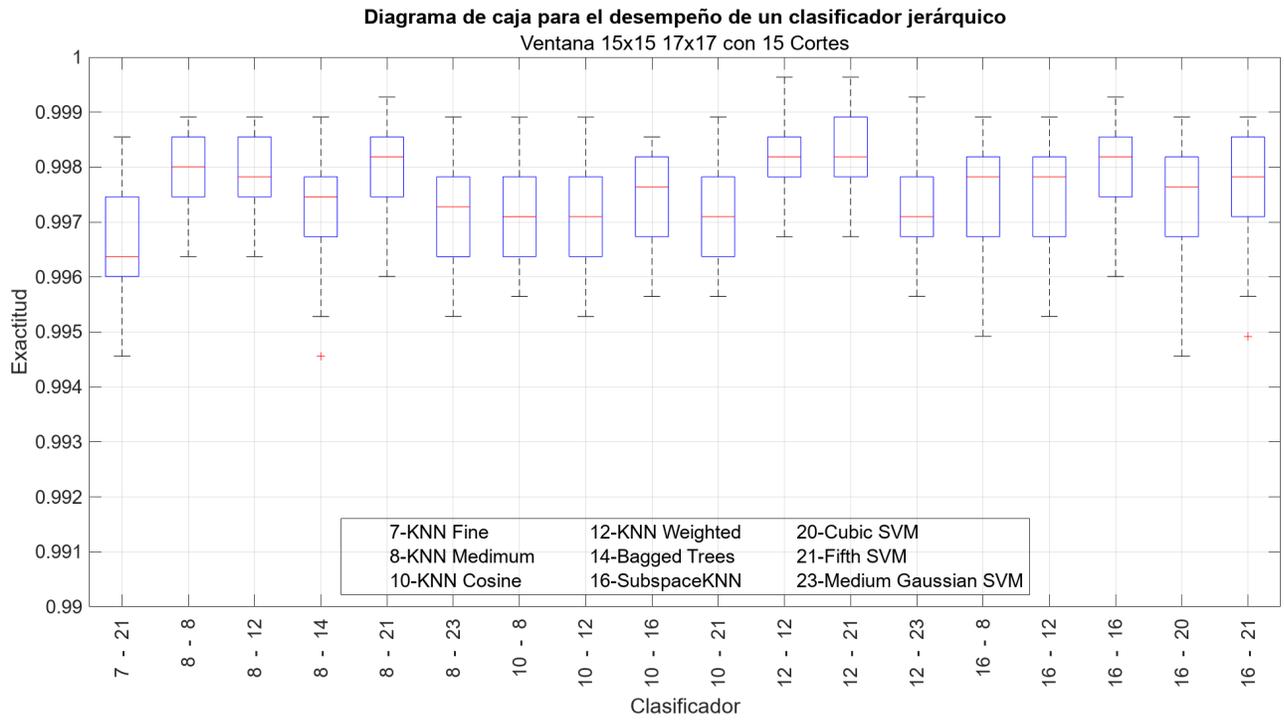


Figura 4.24. Resultados de combinar las ventanas 15×15 17×17 con 15 cortes de fMRI uniendo las clases de control y prodromal.

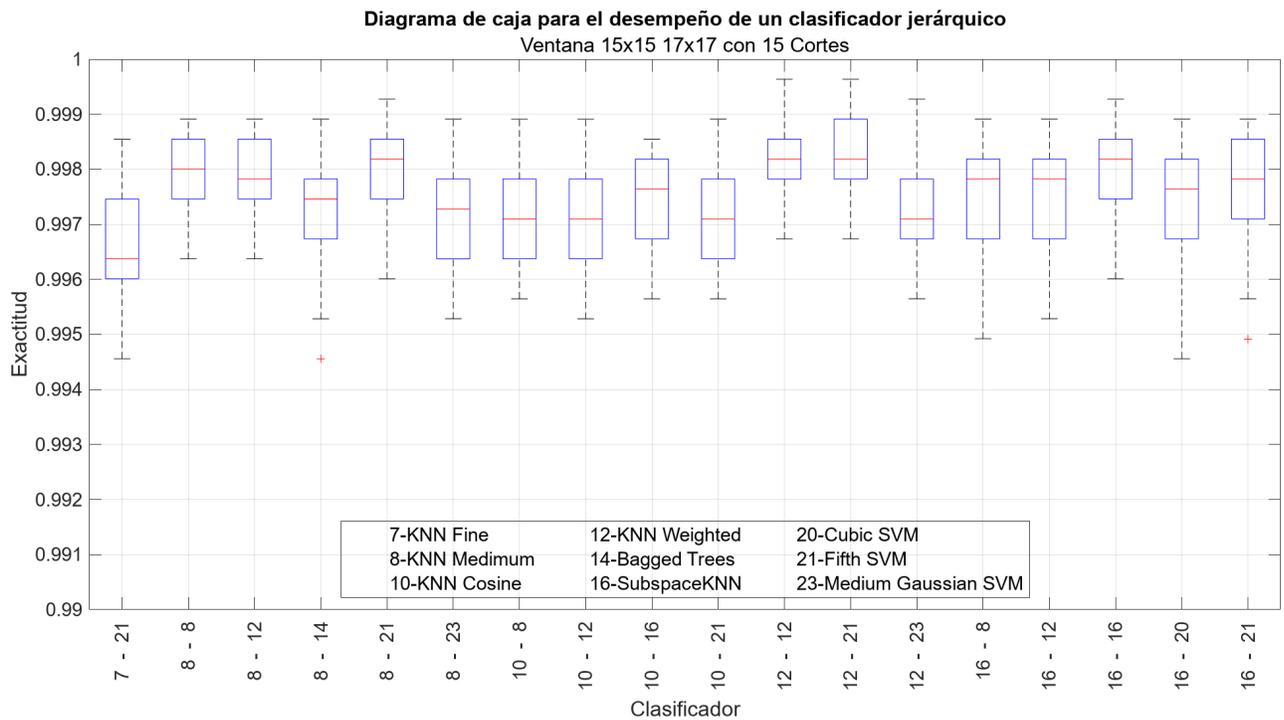


Figura 4.25. Resultados de combinar las ventanas 15×15 17×17 con 15 cortes de fMRI uniendo las clases de control y prodromal.

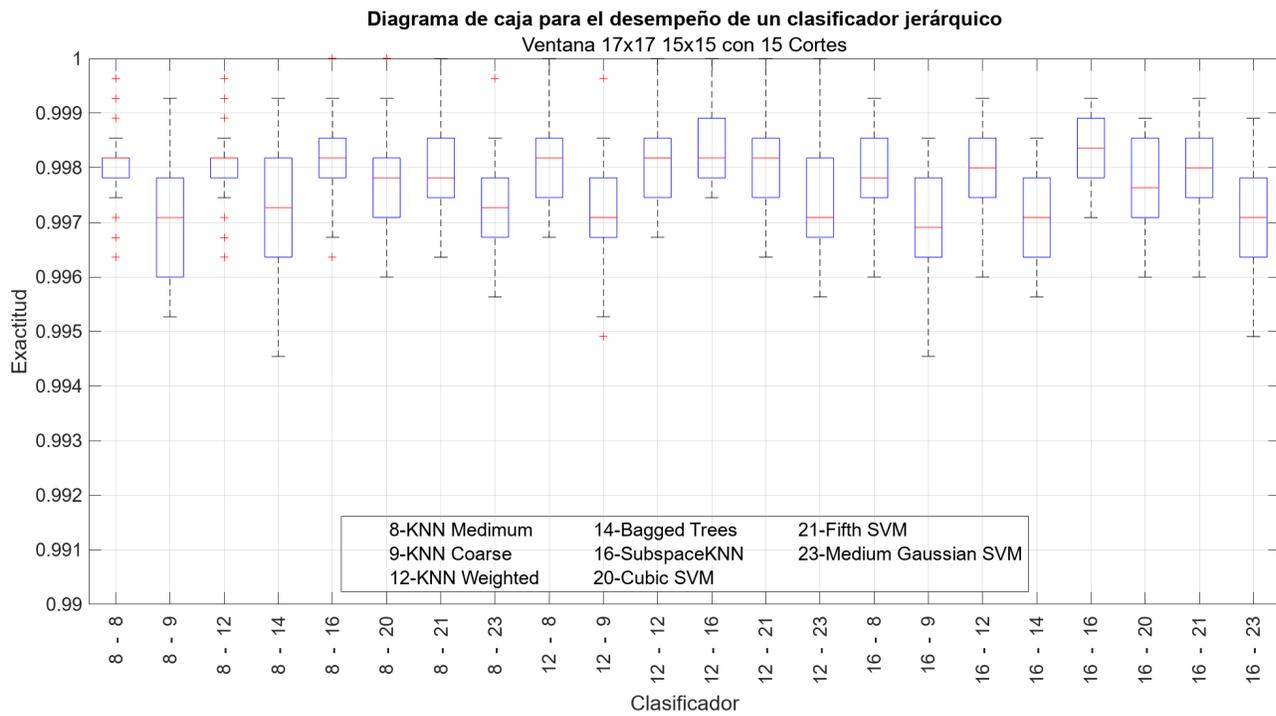


Figura 4.26. Resultados de combinar las ventanas 17×17 15×15 con 15 cortes de fMRI uniendo las clases de control y prodromal.

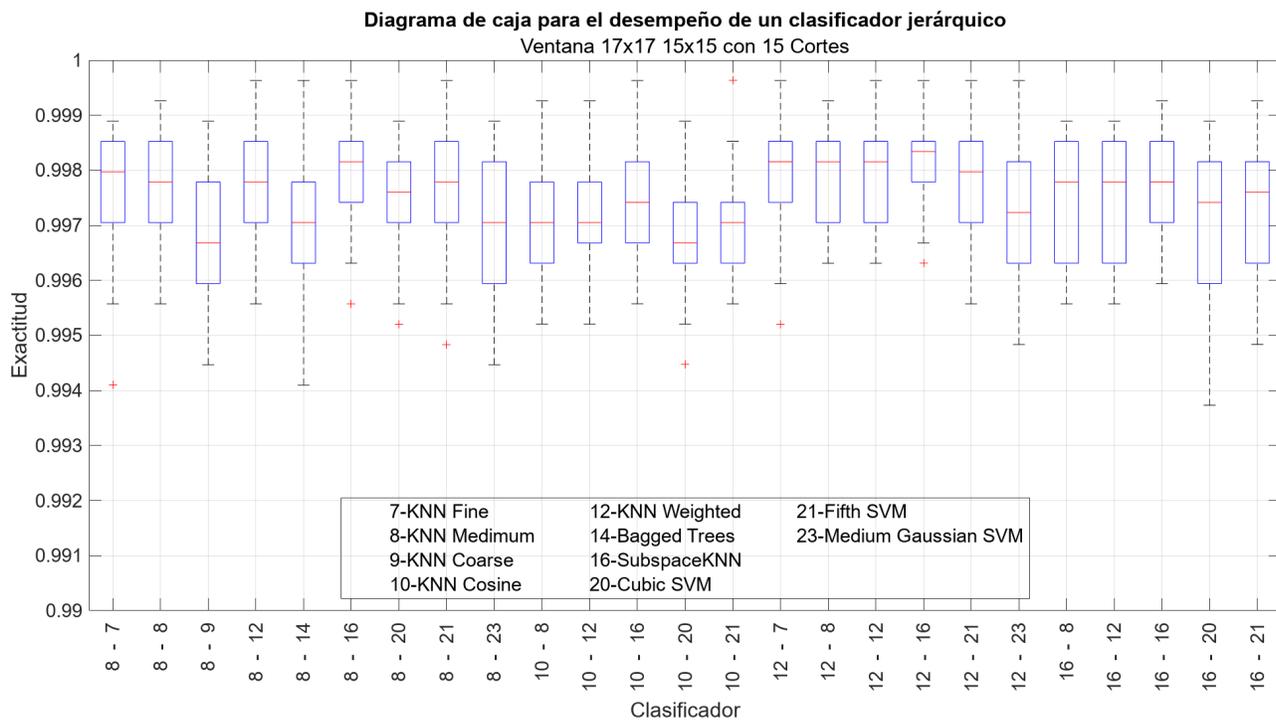


Figura 4.27. Resultados de combinar las ventanas 17×17 15×15 con 15 cortes de fMRI uniendo las clases de control y prodromal.

Cabe resaltar que para esta prueba, además de la generalidad que se logra al incluir más del triple de las muestras, de 141 a 524 como suma total de las 3 clases, se superan una de las debilidades de la prueba anterior en la que se disminuía el percentil de la precisión un 10 % y hasta 20 % a cambio de mejorar la exactitud de un rango de 99 % - 100 % a 99.7 % - 100 %. Con la configuración actual se logran mejorar los valores percentil de precisión y especificidad de un 60 % y 70 %, los cuales corresponden al mejor resultado de la prueba ventanas combinadas con 15 cortes, a valores de 82 % y 90 % respectivamente, el percentil 82 % de la precisión es 99.58 %, 99.17 %, 99.72 % y el percentil 90 % de la especificidad es 99.46 %, 99.72 %, 99.47 % los cuales corresponden a las clases control, prodromal y PD. Además, se mantiene una exactitud en un rango de 99.5 %-100 % como se observa en la figura 4.27.

También podemos observar que en la figura 4.27, en la que se observa que el clasificador de nivel alto siempre pertenece a la familia KNN, mientras que en el de nivel bajo está presente un 50 %, 50 %, 56 % y 50 % en las figuras 4.24, 4.25, 4.26 y 4.27 respectivamente, en promedio nos da un 51.50 %.

Para los clasificadores de nivel alto estas son sus distribuciones porcentuales:

- Para la primera y segunda prueba la cual corresponde a la figura 4.24 y 4.25 los clasificadores están proporcionados de la siguiente manera: un 5.56 % KNN Fine, 22.22 % para los clasificadores KNN Cosine, KNN Weighted, Subspace KNN y un 27.77 % KNN Medium.
- En la tercera prueba correspondiente a la figura 4.26 el 40 % son de los clasificadores KNN Cosine, Subspace KNN, el 24 % KNN Weighted y 36 % KNN Medium.
- Del mismo modo, en la figura 4.27, el clasificador KNN Weighted está un 27.8 %, los clasificadores KNN Subspace y KNN Medium un 36.36 % cada uno.

Los clasificadores del nivel bajo se distribuyen de la siguiente manera:

- En las 2 primeras pruebas del 50 %, el 11.11 % son KNN Subspace, el 16.17 % KNN Medium y 22.22 % KNN Weighted.
- Para la tercera prueba del 56 %, el 8 % pertenece a KNN Fine y KNN Coarse, el 48 % restante son de los clasificadores KNN Medium, Subspace KNN y KNN Weighted, cada uno con 16 %.

- En la ultima prueba del 47.8 %, el 9.08 % es del clasificador Subspace KNN y el 40.92 % restante corresponden a KNN Coarse, KNN Medium y KNN Weighted con 13.64 % cada uno.

Con estos datos podemos constatar que el mejor clasificador para esta prueba en el nivel alto es el KNN Medium, mientras que para los clasificadores de bajo nivel son los KNN Weighted.

Como complemento de la información presentada anteriormente se presenta la tabla 4.4, donde se muestra los clasificadores con mejores medianas, siendo la mayoría de la familia k-vecinos más cercanos

Tabla 4.4. Tabla comparativa del desempeño de los clasificadores con ventajas fijas de 15×15 y 17×17 , y 17×17 y 15×15

Clasificador	15 Cortes	15 Cortes	15 Cortes	15 Cortes
8-KNN Medimum 16-SubspaceKNN	–	–	99.82	99.82
8-KNN Medimum 21-Fifth SVM	99.82	99.82	99.78	99.78
12-KNN Weighted 8-KNN Medimum	–	–	99.82	99.82
12-KNN Weighted' 16-SubspaceKNN	–	–	99.82	99.83
16-SubspaceKNN 16-SubspaceKNN	99.82	99.82	99.84	99.78

En la tabla 4.5, podemos ver el resumen de artículos los cuales, al igual que nuestro trabajo realiza detección temprana de la PD, cabe destacar que, aunque muchos de estos utilizan la misma base de datos PPMI realizar una comparación directa es difícil ya que no todos usan las fMRI para hacer su detección temprana, Aunado a esto, existen en varios trabajos que no especifican sobre el cohorte con los cual trabajaron.

A lo largo de este capitulo, se realizaron múltiples pruebas con la finalidad de dar validez al método y encontrar los parámetros óptimos para metodología aplicada, encontrando que el método tiene un rendimiento optimo en la detección de la Enfermedad de Parkinson.

Tabla 4.5. Detección Temprana de la enfermedad de Parkinson usando la base de datos PPMI.

Artículo	Métricas	Método de detección	de Dataset
[Aversano et al., 2023]	F1=99 %, Exactitud=86 %	Random Forest, eXtreme Gradient Boosting, Extra Trees Classifier, CatBoost.	PPMI (Características motoras y no motoras) 582 PD, 145 Control, 462 Prodromal.
[Aggarwal et al., 2024]	Precisión=98.5 %, sensibilidad=99.14 %, especificidad=98.5 %	Modelos Basados en DL,	PPMI, 620 Pacientes
[Prashanth and Roy, 2018b]	Curva roc=95 %	logistic regression, random forests, Trees with power, SVM	PPMI, Cuestionario del paciente de la Escala de Calificación Unificada de la Enfermedad de Parkinson de la Sociedad de Trastornos del Movimiento (MDS-UPDRS).
[Solana-Lavalle and Rosas-Romero, 2021]	Resultados: precisión=99.01 % (hombres) y 96.97 % (mujeres), sensibilidad=99.35 % (hombres) y 100 % (mujeres), especificidad=100 % (hombres) y 96.15 % (mujeres)	Naive Bayes, Bayesian Net, MLP,SVM.	PPMI (MRI ponderadas T1), 226 pacientes hombres con PD, 86 controles varones, 104 pacientes mujeres con PD y 64 pacientes mujeres con PD
[Li et al., 2024]	promedio de 91.6 %, precisión de 94.7 %, recuperación de 86.2 %, F1 de 90.2 %, AUC de 92.8 %	PD-ARne (ML)	PPMI (rs-fMRI), 145 pacientes.
[Russo et al., 2021]	sensibilidad=86 % a 96 %, especificidad= 93 % a 100 %	Amplificación de semillas de alfa-sinucleína(α -SAA).	PPMI (DatScan), No indica la cantidad de pacientes.
[He et al., 2025]	AUC=0.891, sensibilidad=95 %.	Fusion de multiples sensores del celular e IoT	No indica
[Amoroso et al., 2018]	Precisión=93 %, sensibilidad=93 %, especificidad=92 %.	SVM y características clínicas	PPMI (MRI), No indica la cantidad de pacientes.
[Shinde et al., 2019]	Exactitud=85 %	CNN	PPMI (NM-MRI: Imágenes por resonancia magnética sensible a la neuromelanina)

Conclusiones y perspectivas

5.1. Conclusiones

En este trabajo, se ha demostrado la eficiencia que tienen los sistemas de clasificación asistidos por computadora, con el cual hemos sido capaces de realizar una detección precisa de la Enfermedad de Parkinson en etapa de control, prodromal y PD, con una exactitud superior al 99.5 %. Para las métricas de precisión y especificidad, en a primera clase conocida como control, que son los pacientes con alguna afección (diferente a la PD) que presentan síntomas similares, se obtuvo una precisión de 99.58 % y una especificidad de 99.72 %, en la segunda clase, la cual representa una etapa avanzada de la PD (clase PD) el valor de la precisión es de 99.72 % con una especificidad de 99.47 %, y la que consideramos más importante y relevante para esta investigación los pacientes en etapa inicial (clase Prodromal) donde el valor de precisión fue de 99.17 % y una especificidad de 99.46 %. En la clase Prodromal, como ya se había mencionado anteriormente, está la clave para conseguir una mejora en la calidad de vida de aquellos que tienen la PD, pues actualmente aún no se ha detectado la cura ha esta afección, y tener una herramienta como la detección precoz incide en un mejor resultado en base a los tratamientos con los que se cuenta actualmente.

Otros puntos relevantes a destacar en este trabajo son:

- La utilización de los clasificadores jerárquicos para disminuir el desequilibrio de clases y poder utilizar la mayor cantidad de datos de cada una de las clases.
- Incluir las transformaciones lineales no paramétricas a este ámbito de investigación, ya que muy pocos autores han utilizado este tipo de técnicas.
- Se deja un banco de pruebas extenso para futuros estudios.

Del mismo modo, cuando se coloque en práctica esta metodología ayudará significativamente en un ámbito económico, social y familiar. Bien es sabido que, en etapas avanzadas de la PD, la independencia como persona no es sostenible, por lo cual debe existir una preparación temprana para tomar en cuenta todos estos factores que permiten seguir mejorando la calidad de vida. Por ende, mejorar e innovar en estos métodos de detección es algo primordial hasta encontrar una cura de esta enfermedad.

5.2. Perspectivas

Como es bien sabido en el área de investigación, siempre existen oportunidades para mejorar e innovar los trabajos que realizamos. En nuestro caso, a pesar de que se obtuvieron excelentes resultados, aún quedan abiertas posibilidades como probar diferentes métodos, técnicas e inclusive aplicar esta metodología a problemas de la misma índole, por lo cual, a continuación, describiremos brevemente algunas de las cuales son las más relevantes para nosotros.

- Probar el clasificador KNN Medium-KNN Weighted como medio de asistencia para el personal médico especializado en la PD, así corroborar su eficacia con el personal más calificado para estas tareas.
- Aplicar métodos de data augmentation: los cuales permitan entrenar redes neuronales más complejas y comparar los resultados entre ML y DL.
- Bases de datos diferentes: Utilizar bases de datos que contengan imágenes fMIR para pruebas de robustez.

- Tiempos de entrenamiento extenso: aplicar técnicas que permitan disminuir la dimensionalidad de las características sin afectar el desempeño.
- Localización de la PD en las fMRI: Resaltar en los cortes de las fMRI las zonas donde se ha encontrado la afección para agilizar los diagnósticos por expertos en el área.

Referencias

- Nikita Aggarwal, Barjinder Singh Saini, and Savita Gupta. Feature engineering-based analysis of datscan-spect imaging-derived features in the detection of swedd and parkinson's disease. *Computers and Electrical Engineering*, 117:109241, 2024.
- Nikita Aggarwal, Barjinder Singh Saini, and Savita Gupta. Diagnosis of parkinson's disease based on biological and imaging-derived features using machine learning and deep learning. In *Artificial Intelligence in Biomedical and Modern Healthcare Informatics*, pages 235–244. Elsevier, 2025.
- Nicola Amoroso, Marianna La Rocca, Alfonso Monaco, Roberto Bellotti, and Sabina Tangaro. Complex networks reveal early mri markers of parkinson's disease. *Medical image analysis*, 48:12–24, 2018.
- FNU ASADUZZAMAN, AFM Nazmus Sakib, Sanjida Ali Shushmita, SM Ashraf Kabir, Md Tanzim Reza, and Mohammad Zavid Parvez. Parkinson's disease detection using fmri images leveraging transfer learning on convolutional neural network. In *2020 International Conference on Machine Learning and Cybernetics (ICMLC)*, pages 131–136. IEEE, 2020.
- Lerina Aversano, Mario Luca Bernardi, Marta Cimitile, Martina Iammarino, Antonella Madau, and Chiara Verdone. Early diagnosis of parkinson's disease exploiting motor and non-motor symptoms: Results from the ppmi cohort. *Procedia Computer Science*, 225:2096–2105, 2023.
- Erin Blakemore. ¿qué es la enfermedad de parkinson y por qué es tan difícil de

- diagnosticar?, 2025. URL <https://www.nationalgeographicla.com/ciencia/2025/04/que-es-la-enfermedad-de-parkinson-y-por-que-es-tan-dificil-de-diagnosticar>.
- Wikipedia contributors. DaT scan, 9 2024. URL https://en.wikipedia.org/wiki/DaT_scan.
- P Deepa and Rashmita Khilar. Parkinson’s disease detection and classification: Leveraging voice features and ensemble methods with feature selection and ert classifier. *Procedia Computer Science*, 235:1695–1706, 2024.
- Pedro Luis Rodríguez García. Diagnosis and medical treatment of the parkinsons disease. *Revista Cubana de Neurología y Neurocirugía*, 10(1):1–18, 2020.
- Ji Won Han, Yebin D Ahn, Won-Seok Kim, Cheol Min Shin, Seong Jin Jeong, Yoo Sung Song, Yun Jung Bae, and Jong-Min Kim. Psychiatric manifestation in patients with parkinson’s disease. *Journal of Korean medical science*, 33(47):e300, 2018.
- Robert M Haralick, Karthikeyan Shanmugam, and Its’ Hak Dinstein. Textural features for image classification. *IEEE Transactions on systems, man, and cybernetics*, 1(6):610–621, 2007.
- Jeffrey M. Hausdorff. Gait in parkinson’s disease v1.0.0. <https://physionet.org/content/gaitpdb/1.0.0/>, 2008. PhysioNet: The Research Resource for Complex Physiologic Signals.
- Tongyue He, Junxin Chen, M Shamim Hossain, and Zhihan Lyu. Enhanced detection of early parkinson’s disease through multi-sensor fusion on smartphone-based iomt platforms. *Information Fusion*, 117:102889, 2025.
- Instituto Mexicano del Seguro Social. Imss mejora calidad de vida de pacientes con parkinson mediante estimulación cerebral profunda, 2024. URL <https://www.gob.mx/imss/prensa/252716>.
- Nabeel Khalid and Muhammad Sarwar Ehsan. Critical analysis of parkinson’s disease detection using eeg sub-bands and gated recurrent unit. *Engineering Science and Technology, an International Journal*, 59:101855, 2024.
- Guangyao Li, Yalin Song, Mingyang Liang, Junyang Yu, and Rui Zhai. Pd-arnet: a deep learning approach for parkinson’s disease diagnosis from resting-state fmri. *Journal of Neural Engineering*, 21(5):056016, 2024.

- Kenneth Marek, Danna Jennings, Shirley Lasch, Andrew Siderowf, Caroline Tanner, Tanya Simuni, Chris Coffey, Karl Kieburtz, Emily Flagg, Sohini Chowdhury, et al. The parkinson progression marker initiative (ppmi). *Progress in neurobiology*, 95(4):629–635, 2011.
- Daniel S Marín M, Hans Carmona V, Melissa Ibarra Q, and Manuela Gámez C. Enfermedad de parkinson: fisiopatología, diagnóstico y tratamiento. *Revista de la Universidad Industrial de Santander. Salud*, 50(1):9–26, 2018. URL http://www.scielo.org.co/scielo.php?script=sci_arttext&pid=S0121-08072018000100079. Consultado el 21 de julio de 2025.
- Ahmed Hasin Neehal, Md Nura Azam, Md Sazzadul Islam, Md Ishrak Hossain, and Mohammad Zavid Parvez. Prediction of parkinson’s disease by analyzing fmri data and using supervised learning. In *2020 IEEE Region 10 Symposium (TENSYP)*, pages 362–365. IEEE, 2020.
- NeuronUP. Enfermedades neurodegenerativas, definición y clasificación, 2025. URL <https://neuronup.com/neurorrehabilitacion/enfermedades-neurodegenerativas/>. Consultado el 21 de julio de 2025.
- OMS. Enfermedad de parkinson”. world health organization (who). accedido el 20 de febrero de 2025. [en línea]. disponible:, 2023. URL <https://www.who.int/es/news-room/fact-sheets/detail/parkinson-disease>.
- Mehdi Panahi, Maliheh Habibi, and Mahboubé Sadat Hosseini. Enhancing mri radiomics feature reproducibility and classification performance in parkinson’s disease: a harmonization approach to gray-level discretization variability. *Magnetic Resonance Materials in Physics, Biology and Medicine*, pages 1–13, 2024.
- Luca Parisi, Narrendar RaviChandran, and Marianne Lyne Manaog. Feature-driven machine learning to improve early diagnosis of parkinson’s disease. *Expert Systems with Applications*, 110:182–190, 2018.
- Parkinson’s Foundation. Ser diagnosticado, 2025. URL <https://www.parkinson.org/espanol/entendiendo-parkinson/diagnosticado>. Consultado el 29 de julio de 2025.
- JR Playfer. Parkinson’s disease. *Postgraduate medical journal*, 73(859):257–264, 1997.
- S Pragadeeswaran and S Kannimuthu. Cosine deep convolutional neural network for parkinson’s disease detection and severity level classification using hand drawing spiral image in iot platform. *Biomedical Signal Processing and Control*, 94:106220, 2024.

- R Prashanth and Sumantra Dutta Roy. Early detection of parkinson's disease through patient questionnaire and predictive modelling. *International journal of medical informatics*, 119: 75–87, 2018a.
- R Prashanth and Sumantra Dutta Roy. Early detection of parkinson's disease through patient questionnaire and predictive modelling. *International journal of medical informatics*, 119: 75–87, 2018b.
- R Prashanth and Sumantra Dutta Roy. Early detection of parkinson's disease through patient questionnaire and predictive modelling. *International journal of medical informatics*, 119: 75–87, 2018c.
- S Jeba Priya, Arockia Jansi Rani, MSP Subathra, Mazin Abed Mohammed, Robertas Damaševičius, and Neha Ubendran. Local pattern transformation based feature extraction for recognition of parkinson's disease based on gait signals. *Diagnostics*, 11(8):1395, 2021.
- Elham Rastegari, Hesham Ali, and Vivien Marmelat. Detection of parkinson's disease using wrist accelerometer data and passive monitoring. *Sensors*, 22(23):9122, 2022.
- Stylios Ravanidis, Anastasia Bougea, Nikolaos Papagiannakis, Matina Maniati, Christos Koros, Athina-Maria Simitsi, Maria Bozi, Ioanna Pachi, Maria Stamelou, George P Paraskevas, et al. Circulating brain-enriched micrnas for detection and discrimination of idiopathic and genetic parkinson's disease. *Movement disorders*, 35(3):457–467, 2020.
- Marco J Russo, Christina D Orru, Luis Concha-Marambio, Simone Giaisi, Bradley R Groveman, Carly M Farris, Bret Holguin, Andrew G Hughson, David-Erick LaFontant, Chelsea Caspell-Garcia, et al. High diagnostic performance of independent alpha-synuclein seed amplification assays for detection of early parkinson's disease. *Acta neuropathologica communications*, 9:1–13, 2021.
- S Sangeetha and B Umarani. Mri image-based parkinson's disease classification using deep maxout fuzzy efficientnet. *Biomedical Signal Processing and Control*, 103:107416, 2025.
- Sumeet Shinde, Shweta Prasad, Yash Saboo, Rishabh Kaushick, Jitender Saini, Pramod Kumar Pal, and Madhura Ingalhalikar. Predictive markers for parkinson's disease using deep neural nets on neuromelanin sensitive mri. *NeuroImage: Clinical*, 22:101748, 2019.
- Gabriel Solana-Lavalle and Roberto Rosas-Romero. Classification of ppmi mri scans with voxel-based morphometry and machine learning to assist in the diagnosis of parkinson's disease. *Computer Methods and Programs in Biomedicine*, 198:105793, 2021.

- P Sriramakrishnan, T Kalaiselvi, M Thirumalaiselvi, ST Padmapriya, and S Ramkumar. A role of medical imaging techniques in human brain tumor treatment. *International Journal of Recent Technology and Engineering*, 8(4S2):2277–3878, 2019.
- Tewodros Megabiaw Tassew, Nie Xuan, and Bosong Chai. Pdds: A software for the early diagnosis of parkinson’s disease from mri and dat scan images using detection and segmentation algorithms. *Biomedical Signal Processing and Control*, 86:105140, 2023.
- Wu Wang, Junho Lee, Fouzi Harrou, and Ying Sun. Early detection of parkinson’s disease using deep learning and machine learning. *IEEE Access*, 8:147635–147646, 2020.
- Colaboradores Wikipedia. Años de vida ajustados por discapacidad - wikipedia, la enciclopedia libre.wikipedia, la enciclopedia libre. accedido el 20 de febrero de 2025. [en línea]. disponible:, 2023. URL https://es.wikipedia.org/wiki/AÑos_de_vida_ajustados_por_discapacidad.
- Ramin Zabih and John Woodfill. Non-parametric local transforms for computing visual correspondence. In *Computer Vision—ECCV’94: Third European Conference on Computer Vision Stockholm, Sweden, May 2–6 1994 Proceedings, Volume II 3*, pages 151–158. Springer, 1994.