



UNIVERSITAT
POLITÈCNICA
DE VALÈNCIA



ESCUELA TÉCNICA
SUPERIOR INGENIERÍA
INDUSTRIAL VALENCIA

TRABAJO FIN DE MÁSTER EN INGENIERÍA BIOMÉDICA

DESARROLLO DE PERFILES DE PACIENTES AFECTADOS POR SÍNDROME DE TÚNEL CARPIANO Y CEFALEA TENSIONAL MEDIANTE EL USO DE TÉCNICAS DE APRENDIZAJE AUTOMÁTICO

AUTOR: DANIEL MAYOR TOMILLO

TUTOR: JOSE DAVID MARTIN GUERRERO

Curso Académico: 2019-20

AGRADECIMIENTOS

Quiero aprovechar esta ocasión para agradecer:

A mi tutor, José David, por haberme acogido en pleno confinamiento para la realización de este trabajo, por confiar en mí y darme la oportunidad de seguir aprendiendo y descubriendo el mundo del aprendizaje automático aplicado al mundo sanitario.

Al equipo de profesionales de la *Facultat de Psicologia de la Universitat de Valencia* que han proporcionado los datos, sin los cuales, el estudio no podría haberse realizado.

De forma muy especial a Cristina, quien ha estado al pie del cañón desde el primer día, proporcionándome ayuda, aportando serenidad y entendiéndome como solamente ella sabe.

A mis padres y mis hermanos, por la paciencia estos últimos meses y por haberme dado la oportunidad de estar donde estoy ahora.

Finalmente, a mis compañeros de máster, en especial a aquellos con los que empecé mi andadura en la ingeniería biomédica con los complementos formativos hace ya dos años, gracias por haber compartido conmigo esta etapa y haberme enseñado tantas cosas.

RESUMEN

El Síndrome de Túnel Carpiano (STC) es una de las neuropatías por compresión presentes en el miembro superior más frecuentes en la práctica clínica. La Cefalea Tensional (CT) es el trastorno de cefalea más común en la población. Estas patologías están asociadas a fuertes períodos de dolor, que limitan en gran medida la calidad de vida de los pacientes que las padecen.

Se han propuesto diversas técnicas de aprendizaje automático no supervisado con el objetivo de encontrar diferentes perfiles de paciente presentes en los datos. Esto permite encontrar similitudes y diferencias entre los distintos grupos de pacientes, con el objetivo de encontrar patrones de comportamiento. Posteriormente, la comprensión de estos factores que diferencian cada grupo puede ayudar a los médicos a realizar tratamientos personalizados, optimizando los programas terapéuticos.

En este estudio, se han empleado dos técnicas de agrupamiento, mapas autoorganizativos (SOM) y agrupamiento espectral, con el objetivo de comprender la relación entre características clínicas, psicológicas, sensitivas y motoras de los dos grupos de pacientes de estudio. Además, se obtuvieron diferentes clústeres de pacientes agrupados según dichas características clínicas, mostrando elementos comunes y diferentes entre los grupos.

Las características recogidas de un total de 222 pacientes con STC incluyen duración de los síntomas, intensidad del dolor, función y gravedad de los síntomas, niveles depresivos, fuerza de agarre de pinzamiento de los diferentes dedos con el dedo pulgar, umbrales de dolor por presión (PPT) sobre diferentes zonas, umbrales de dolor por aplicación de calor y frío, además del lado de incidencia del STC y del grado obtenido mediante electromiografía. En cuanto a las características recogidas de un total de 208 pacientes de CT, incluyen tiempo de comienzo de los síntomas, dolor, duración y frecuencia mensual de las cefaleas, umbrales de dolor por presión en diferentes zonas, evaluaciones psicológicas mediante HDI, SF-36, HADS y STAI, umbrales de dolor obtenidos mediante un *roller*, además del sexo del paciente, y si recibe medicación preventiva y/o tratamiento sintomático.

Los SOM han permitido visualizar la correlación entre las distintas variables de ambos conjuntos de datos, mostrando en el caso de STC fuertes asociaciones entre variables clínicas, psicológicas, sensitivas y motoras. En el análisis de CT mediante SOM, también se encontraron algunas relaciones también entre características clínicas, sensitivas y psicológicas.

El empleo de agrupamiento espectral, junto con el SOM, ha permitido identificar subgrupos potenciales del conjunto de datos de pacientes completos. En concreto, se han detectado diferencias entre los grupos en cuanto a los valores de diferentes características, permitiendo agruparlos y distinguirlos, con el objetivo de servir como base para un posible tratamiento personalizado.

Palabras clave: Túnel carpiano; cefalea tensional; aprendizaje automático; mapas autoorganizativos; SOM; perfilado de pacientes; agrupamiento; espectral.

RESUM

La Síndrome de Túnel Carpià (STC) és una de les neuropaties per compressió presents en el membre superior més freqüents en la pràctica clínica. La Cefalea Tensional (CT) és el trastorn de cefalea més comuna en la població. Estes patologies estan associades a forts períodes de dolor, que limiten en gran manera la qualitat de vida dels pacients que les patixen.

S'han proposat diverses tècniques d'aprenentatge automàtic no supervisat amb l'objectiu de trobar diferents perfils de pacient presents en les dades. Açò permet trobar similituds i diferències entre els distints grups de pacients amb l'objectiu de trobar patrons de comportament. Posteriorment, la comprensió d'estos factors que diferencien cada grup pot ajudar els metges a realitzar tractaments personalitzats, optimitzant els programes terapèutics.

En este estudi s'han empleat dos tècniques d'agrupament, mapes autoorganitzatius (SOM) i agrupament espectral amb l'objectiu de comprendre la relació entre característiques clíniques, psicològiques, sensibles i motores dels dos grups de pacient d'estudi. A més es van obtindre diferents clusters de pacients agrupats segons dites característiques clíniques, mostrant elements comuns i diferents entre els grups.

Les característiques arreplegades d'un total de 222 pacients amb STC inclouen duració dels símptomes, intensitat del dolor, funció i gravetat dels símptomes, nivells depressius, força d'agafada de pinçament dels diferents dits amb el dit polze, llimdars de dolor per pressió (PPT) sobre diferents zones, llimdars de dolor per aplicació de calor i fred, a més del costat d'incidència del STC i grau obtingut per mitjà d'electromiografia. Quant a les característiques arreplegues d'un total de 208 pacients de CT inclouen temps de començament dels símptomes, dolor, duració i freqüència mensual de les cefalees, llimdars de dolor per pressió en diferents zones, avaluacions psicològiques per mitjà de HDI, SF-36, HADS i STAI, llimdars de dolor obtinguts per mitjà d'un roller, a més del sexe del pacient, i si rep medicació preventiva i/o tractament simptomàtic.

Els SOM han permés visualitzar la correlació entre les distintes variables d'ambdós conjunts de dades, mostrant en el cas de STC fortes associacions entre variables clíniques, psicològiques, sensibles i motores. En l'anàlisi de CT per mitjà de SOM es van trobar algunes relacions també entre característiques clíniques, sensibles i psicològiques.

L'ocupació d'agrupament espectral, junt amb el SOM ha permés identificar subgrups potencials del conjunt de dades de pacients complets. En concret s'han detectat diferències entre els grups quant als valors de diferents característiques permetent agrupar-los i distingir-los amb l'objectiu de servir com a base per a un possible tractament personalitzat.

Paraules clau: Túnel carpià; cefalea tensional; aprenentatge automàtic; mapes autoorganitzatius; SOM; perfilat de pacients; agrupament; espectral.

ABSTRACT

Carpal Tunnel Syndrome (CTS) is one of the compression neuropathies in the upper limb most common in clinical practice. Tension Headache (TC) is the most common headache disorder in the population. These pathologies are associated with strong periods of pain, limiting the quality of life of patients who suffer from them.

Some unsupervised machine learning techniques have been proposed with the aim of finding different patient profiles present in the data. This allows finding similarities and differences between the different groups of patients in order to find patterns of behavior. Subsequently, understanding the factors that differentiate each group can help doctors to carry out personalized treatments, optimizing therapeutic programs.

In this study, two grouping techniques have been used, self-organizing maps (SOM) and spectral clustering. The aim is to understand the relationship between clinical, psychological, sensory, and motor characteristics of the two groups of study. In addition, different clusters of patients grouped according to said clinical characteristics were obtained, showing common and different elements between the groups.

The characteristics collected from 222 patients with CTS include duration of symptoms, intensity of pain, function and severity of symptoms, depressive levels, grip strength of the different fingers with the thumb, pressure pain thresholds (PPT) on different areas, pain thresholds due to the application of heat and cold, the incidence side of CTS and grade obtained by electromyography. Regarding the characteristics collected from a total of 208 CT patients, they include time of onset of symptoms, pain, duration and monthly frequency of headaches, pressure pain thresholds (PPT) in different areas, psychological evaluations using HDI, SF-36, HADS and STAI, pain thresholds obtained using a roller, the sex of the patient, and if they receive preventive medication and/or symptomatic treatment.

The SOMs have made it possible to visualize the correlation between the different variables of both data sets, showing in the case of CTS strong associations between clinical, psychological, sensory and motor variables. In the analysis of CT by SOM, some relationships were also found between clinical, sensory and psychological features.

The use of spectral clustering in conjunction with SOM has allowed the identification of potential subgroups of the entire patient data set. Specifically, differences have been detected between the groups in terms of the values of different characteristics, allowing them to be clustered and distinguished in order to serve as a basis for a possible personalized treatment.

Keywords: Carpal tunnel; tension headache; machine learning; self-organizing maps; SOM; patient profiling; clustering; spectral.

ÍNDICE

DOCUMENTOS CONTENIDOS EN EL TRABAJO FINAL DE MÁSTER

- **Memoria del Trabajo Fin de Máster.** Descripción detallada del proyecto.
- **Presupuesto.** Estudio económico detallado del proyecto.



UNIVERSITAT
POLITÈCNICA
DE VALÈNCIA



ESCUELA TÉCNICA
SUPERIOR INGENIERÍA
INDUSTRIAL VALENCIA

DOCUMENTO I

MEMORIA

DESARROLLO DE PERFILES DE PACIENTES AFECTADOS
POR SÍNDROME DE TÚNEL CARPIANO Y CEFALEA
TENSIONAL MEDIANTE EL USO DE TÉCNICAS DE
APRENDIZAJE AUTOMÁTICO

AUTOR: DANIEL MAYOR TOMILLO

TUTOR: JOSÉ DAVID MARTÍN GUERRERO

2019 - 2020

ÍNDICE DE CONTENIDOS DE LA MEMORIA

1. MOTIVACIÓN Y OBJETIVOS.....	5
1.1. MOTIVACIÓN Y DESCRIPCIÓN DEL PROBLEMA	5
1.2. OBJETIVOS	6
1.3. GUÍA DE LA MEMORIA	6
2. INTRODUCCIÓN.....	8
2.1. SÍNDROME DE TÚNEL CARPIANO	8
2.1.1. Anatomía.....	9
2.1.2. Fisiopatología.....	10
2.1.3. Factores de riesgo y causas.....	10
2.1.4. Características clínicas	11
2.1.5. Diagnóstico.....	12
2.1.6. Clasificación.....	12
2.1.7. Epidemiología.....	13
2.1.8. Tratamiento.....	13
2.2. CEFALEA TENSIONAL.....	14
2.2.1. Fisiopatología.....	14
2.2.2. Características clínicas	15
2.2.3. Diagnóstico.....	16
2.2.4. Clasificación.....	17
2.2.5. Epidemiología.....	18
2.2.6. Tratamiento.....	19
2.3. APRENDIZAJE AUTOMÁTICO	20
2.3.1. Aprendizaje no supervisado.....	21
2.3.2. Otros tipos de aprendizaje.....	21
3. MATERIALES.....	23
3.1. DATOS DE PACIENTES	23
3.1.1. Conjunto de datos de pacientes con Síndrome de Túnel Carpiano.....	23
3.1.2. Conjunto de datos de pacientes con Cefalea Tensional.....	24
3.2. HERRAMIENTAS INFORMÁTICAS	26
3.2.1. Software	26
3.2.2. Hardware.....	27
4. MÉTODOS	28
4.1. EXPLORACIÓN DE LOS DATOS.....	28
4.1.1. Kernel Density Estimate.....	28
4.1.2. Coeficiente de correlación	30
4.1.3. Test Chi-cuadrado.....	31
4.2. PREPROCESADO DE LOS DATOS	31
4.2.1. Imputación de valores con el algoritmo k-Nearest Neighbors	33
4.2.2. Selección de características	34
4.2.3. Normalización.....	36
4.3. TÉCNICAS DE APRENDIZAJE NO SUPERVISADO.....	37
4.3.1. Conceptos previos.....	38
4.3.2. Agrupamiento mediante k-means.....	39

DESARROLLO DE PERFILES DE PACIENTES AFECTADOS POR SÍNDROME DE TÚNEL CARPIANO Y
CEFALEA TENSIONAL MEDIANTE EL USO DE TÉCNICAS DE APRENDIZAJE AUTOMÁTICO

4.3.3. Agrupamiento mediante Hierarchical Clustering	40
4.3.4. Agrupamiento mediante Spectral Clustering	41
4.3.5. Agrupamiento mediante affinity propagation	42
4.3.6. Agrupamiento mediante mean-shift	43
4.3.7. Mapas autoorganizativos.....	44
4.3.8. Métricas de evaluación del desempeño	45
5. RESULTADOS Y DISCUSIÓN	49
5.1. EXPLORACIÓN DE LOS DATOS.....	49
5.1.1. Síndrome de Túnel Carpiano	49
5.1.2. Cefalea Tensional	56
5.2. PREPROCESADO DE LOS DATOS	64
5.2.1. Valores ausentes y anómalos	64
5.2.2. Codificación de características cualitativas.....	64
5.2.3. Selección de características y estandarización.....	65
5.3. CLÚSTERES EN CONJUNTO DE DATOS DE SÍNDROME DE TÚNEL CARPIANO	65
5.3.1. Obtención del número de clústeres	65
5.3.2. Mapas autoorganizativos.....	68
5.3.3. Clústeres obtenidos mediante agrupamiento espectral.....	70
5.4. CLÚSTERES EN CONJUNTO DE DATOS DE CEFALEA TENSIONAL	80
5.4.1. Obtención del número de clústeres	80
5.4.2. Mapas autoorganizativos.....	82
5.4.3. Clústeres obtenidos mediante agrupamiento espectral.....	85
6. CONCLUSIONES Y LÍNEAS FUTURAS	94
6.1. CONCLUSIONES	94
6.2. LÍNEAS FUTURAS.....	95
7. BIBLIOGRAFÍA	97

1. MOTIVACIÓN Y OBJETIVOS

1.1. MOTIVACIÓN Y DESCRIPCIÓN DEL PROBLEMA

El Síndrome de Túnel Carpiano (STC) es una de las neuropatías por compresión presentes en el miembro superior más frecuentes en la práctica clínica. Este problema se produce por un atrapamiento del nervio mediano que puede provocar una disminución de la fuerza de agarre con atrofia y, en casos graves, incluso puede provocar un deterioro permanente del tejido muscular y la pérdida de la función de la mano [1].

En concreto, la compresión del nervio medial, representa aproximadamente el 90% de todas las neuropatías por compresión [2] y un 3,8% de las compresiones por nervios en general [3]. La prevalencia e incidencia informadas del STC varían ampliamente según los criterios de diagnóstico utilizados en diferentes estudios. Clínicamente, se estima que entre un 4-9% de las personas desarrollan el STC en algún momento de su vida [4], limitando su calidad de vida.

El diagnóstico de STC se basa principalmente en el cuadro clínico que presenta el paciente. Debido a esto, para su diagnóstico se requiere la presencia de síntomas relacionados junto con una velocidad anormal de la conducción nerviosa. En este caso, la patología es fácilmente detectable con test electrofisiológicos, aunque existe cierta controversia en cuanto a su clasificación. *Stevens* en [5] emplea tres grados de clasificación, pero sin niveles de latencia específicos; mientras que *Bland* en [6] utiliza seis niveles y varios umbrales de latencia específicos, además de los límites de velocidad y amplitud. Una buena aproximación es la clasificación en tres niveles propuesta por *Sucher* en [7].

Por otro lado, la Cefalea Tensional (CT) se caracteriza por un dolor de cabeza intenso sin más rasgos distintivos que el propio dolor. Es el tipo de cefalea más común en la población y la más infradiagnosticada, debido a que muchos pacientes con CT poco frecuente no consulta a un médico, sino que se automedica con analgésicos de venta libre. Esta patología se diagnostica principalmente por la ausencia de características de otros tipos de cefaleas más estudiadas, como la migraña [8].

Actualmente, se estima que la prevalencia global de la CT en adultos se encuentra alrededor del 40%. Aunque la CT es generalmente menos grave que la migraña para el paciente individual, el impacto socioeconómico total de este tipo de dolor de cabeza es incluso mayor que el que provoca la migraña, debido a su mayor prevalencia [9]. En la clasificación de causas de discapacidad de la Organización Mundial de la Salud (OMS), los trastornos por dolor de cabeza son de las 10 condiciones más discapacitantes para los dos géneros, siendo de las cinco más discapacitantes para las mujeres.

En el caso de la CT, aún se desconocen las causas exactas que la producen. Los mecanismos miofasciales periféricos y la falta de regulación en las estructuras de procesamiento del dolor están implicados, pero su importancia varía con la frecuencia de la cefalea y entre los diferentes pacientes. Aunque se ha tratado de definir una clasificación para esta patología con el sistema *International Classification of Headache Disorders* [10], el conocimiento sobre la CT continúa siendo muy limitado.

Entre las técnicas de ciencia de datos, el aprendizaje automático se conoce como un conjunto de métodos que pueden detectar automáticamente patrones y estructuras en los datos. Posteriormente, se pueden emplear los patrones descubiertos para predecir o clasificar datos futuros, para observar estructuras o subgrupos en los datos, o extraer información de los datos adecuada para obtener nuevos conocimientos. Los algoritmos de agrupamiento pueden encontrar patrones entre pacientes que, sin embargo, son difíciles de detectar por los médicos.

El dolor y la cronificación del dolor son fenómenos con una alta prevalencia y que la medicina actual no ha llegado a comprender del todo; el dolor es un fenómeno complejo [11]. Los métodos de aprendizaje automático pueden utilizar datos clínicos y experimentales complejos para comprender mejor la complejidad del dolor. Por lo tanto, puede ser de gran ayuda el uso de estas técnicas de aprendizaje automático con el fin de detectar perfiles típicos y obtener los rasgos característicos de los pacientes aquejados de Cefalea Tensional y Síndrome de Túnel Carpiano.

1.2. OBJETIVOS

El objetivo fundamental del presente trabajo final de máster es, por tanto, la detección de perfiles típicos de paciente y su correspondiente análisis para, en función de cada perfil, conocer qué rasgos resultan más importantes. Para realizar este estudio, se emplearán técnicas de agrupamiento no supervisado y se aplicarán en los datos recogidos de pacientes diagnosticados con Cefalea Tensional o Síndrome de Túnel Carpiano.

De esta forma, se desea que el tratamiento sea personalizado y se centre en corregir los aspectos más importantes para cada paciente en particular. Este objetivo fundamental conlleva los siguientes objetivos secundarios:

- 1) Análisis exploratorio del conjunto de datos: descripción de variables y pacientes, visualización, detección de valores perdidos (e imputación si procede), detección de datos atípicos (e imputación si procede), normalización, codificación, etc.
- 2) Detección de perfiles de paciente con herramientas de aprendizaje no supervisado (agrupamiento).
- 3) Análisis clínico de los perfiles y propuestas de atención personalizada. En esta parte, se contará con la ayuda de miembros de la *Facultat de Psicologia* de la *Universitat de València*, que son expertos en estos problemas y pueden ayudar en la visión clínica del mismo.
- 4) Propuestas de continuación del trabajo.

1.3. GUÍA DE LA MEMORIA

En el capítulo 2 se realiza una introducción al proyecto, donde se describen detalladamente las patologías de los pacientes a perfilar, la Cefalea Tensional y el Síndrome del Túnel Carpiano. Además, realiza una breve introducción de las técnicas de aprendizaje automático que permiten la realización del estudio.

El capítulo 3 hace referencia a los materiales empleados para la realización del proyecto, incluyendo las características de los pacientes que se suelen extraer en cada una de las enfermedades y que están presentes en la base de datos utilizada.

En el capítulo 4, se indican las técnicas empleadas y su justificación para la consecución de los objetivos del presente proyecto. Además, se incluye información sobre la aplicación de técnicas de aprendizaje automático en investigación de patologías relacionadas con el dolor y la obtención de perfiles de pacientes.

En cuanto al capítulo 5, se exponen y discuten los resultados obtenidos al aplicar las diferentes metodologías de preprocesado de los datos. Se incluye la descripción, análisis y discusión de las variables extraídas de los pacientes, así como los perfiles obtenidos mediante las técnicas de aprendizaje automático.

Finalmente, en el capítulo 6, se detallan las conclusiones más importantes que se han extraído del estudio de los datos y se recopilan algunas propuestas como posibles futuras líneas de investigación dentro del ámbito del presente proyecto.

2. INTRODUCCIÓN

2.1. SÍNDROME DE TÚNEL CARPIANO

El Síndrome del Túnel Carpiano (STC) es una de las neuropatías por compresión del miembro superior más frecuentes en la práctica clínica, ya que representa aproximadamente el 90% de todas las neuropatías [2].

Esta condición está causada por la compresión del nervio medial, un nervio que atraviesa un túnel óseo y fibroso situado en la muñeca, lo que provoca dolor, entumecimiento y hormigueo en la mano hasta el antebrazo. En etapas avanzadas, algunas personas con STC presentan debilidad y pérdida muscular en la mano. En la Figura 1, se puede observar la zona en la que se localiza el dolor y la afectación por esta patología, así como un esquema del nervio mediano.




Figura 1. Representación sensorial del síndrome de túnel carpiano [12].

Existen dos tipos de Síndrome de Túnel Carpiano, el STC agudo y el STC crónico. La forma aguda de esta patología es relativamente infrecuente y se debe a un aumento rápido y sostenido de la presión en el túnel carpiano. Esto se asocia comúnmente con una fractura del radio o con quemaduras, coagulopatía, infección local o inyecciones. La forma crónica del STC es mucho más común y los síntomas pueden persistir durante meses o años.

El STC es una afección que se produce en personas de mediana edad, con mayor incidencia en mujeres y personas con ciertos factores de riesgo, como la diabetes, la obesidad, la artritis, la edad avanzada, o el trabajo en ciertas ocupaciones. Cabe destacar que esta patología es común en mujeres embarazadas. En este caso, el diagnóstico del STC se realiza durante el tercer trimestre del embarazo y, a menudo, es bilateral. En la mayoría de las pacientes, los síntomas se resuelven con el tiempo, aunque, si no desaparecen es necesario un tratamiento posterior al parto.

Esta patología es uno de los factores de riesgo laborales ampliamente reconocidos; particularmente en industrias donde el trabajo implica la utilización continua de fuerza/presión y el uso repetitivo de

herramientas vibratorias. Sin embargo, es necesario excluir todas las demás causas como son la obesidad, diabetes, etc. antes de atribuirlo a un factor laboral.

Los movimientos complejos y la sensación táctil de la mano son esenciales para completar las tareas cotidianas, siendo el STC una patología con un impacto significativo en las actividades de la vida diaria. En 2002, la Oficina de Estadísticas Laborales de EE. UU. Informó que el número medio de días fuera del trabajo fue más alto para el STC (30 días) en comparación con cualquier otra enfermedad y lesión discapacitante importante [13].

2.1.1. Anatomía

El túnel carpiano se encuentra en la zona de la palma de la mano más cercana a la muñeca. Está definido por el pisiforme y el gancho del hamato en la parte medial y las tuberosidades del escafoides y el trapecio lateralmente. El tejido conectivo grueso (el retináculo flexor) recubre estas cuatro prominencias óseas, lo que establece un túnel para los tendones flexores extrínsecos de los dedos (flexor profundo de los dedos, flexor superficial de los dedos y flexor largo del pulgar) [2], manteniéndolos en su lugar durante la flexión de la muñeca (Figura 2).

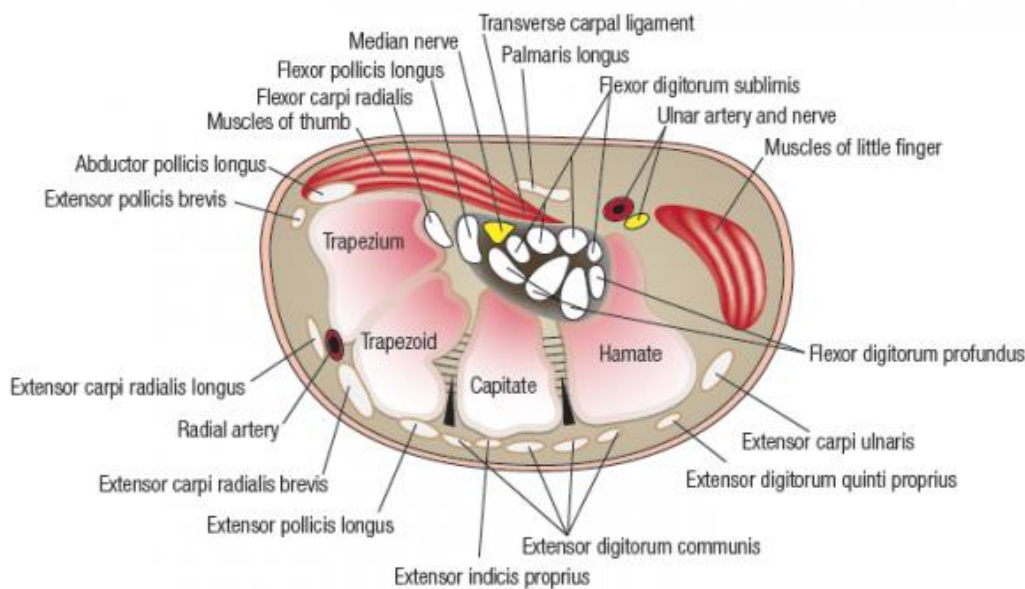


Figura 2. Esquema de la sección de la muñeca [12].

El túnel carpiano es atravesado por 10 estructuras, nueve tendones y el nervio mediano (Figura 2). El nervio mediano es un nervio periférico principal del miembro superior. Sigue su curso a través de los cordones lateral y medial del plexo braquial hacia el compartimento anterior del antebrazo a través del túnel carpiano hasta la muñeca. En la muñeca, este nervio se ramifica para proporcionar nervios motores al grupo muscular tenar e inervación sensorial a la superficie palmar de la muñeca, pulgar, dedo índice, dedo medio y mitad lateral del dedo anular.

El Síndrome del Túnel Carpiano (STC) se produce cuando el túnel se estrecha o los tendones flexores extrínsecos o las vainas del tendón se hinchan. La compresión en el túnel carpiano incide en el nervio mediano y produce síntomas de alteración de la sensibilidad en los dedos que inerva. Los síntomas

pueden progresar llegando al desgaste y debilidad de los músculos tenares, lo que conlleva una debilitación en el agarre.

2.1.2. Fisiopatología

La literatura ha mostrado una combinación de varios mecanismos fisiopatológicos en STC. Estos mecanismos están interactuando e incluyen el aumento de la presión en el túnel, lesión de la microcirculación del nervio mediano, lesiones de la vaina de mielina y el axón, compresión del tejido conectivo del nervio mediano e hipertrofia del tejido sinovial [14].

La patogenia exacta del STC no está clara. Se han propuesto varias teorías para explicar los síntomas y los estudios de conducción nerviosa alterada [2]:

- 1) **Teoría de compresión mecánica.** Es la teoría más ampliamente aceptada. Indica que los síntomas del STC se deben a la compresión del nervio mediano en el túnel carpiano. El principal inconveniente de esta teoría es que explica las consecuencias de la compresión del nervio, pero no explica la etiología subyacente de la compresión mecánica.
- 2) **Teoría de insuficiencia microvascular.** Propone que la falta de suministro de sangre conduce al agotamiento de nutrientes y oxígeno en el nervio, lo que hace que pierda lentamente su capacidad para transmitir impulsos nerviosos. Con el tiempo, se desarrollan cicatrices y tejido fibroso dentro del nervio. Según la gravedad de la lesión, los cambios en los nervios y los músculos pueden ser permanentes.
- 3) **Teoría vibratoria.** Según la teoría de la vibración, los síntomas del STC podrían deberse a los efectos del uso prolongado de herramientas vibratorias en el nervio mediano en el túnel. Esta vibración produciría cambios en las fibras nerviosas. Estos cambios se observaron por primera vez en las fibras amielínicas que sirven a la actividad simpática, cuya pérdida podría reducir el flujo microvascular hacia el nervio mediano, lo que provocaría la rotura de su vaina de mielina y una disminución de la velocidad de conducción motora.

2.1.3. Factores de riesgo y causas

Los factores de riesgo que pueden desembocar en STC incluyen diabetes mellitus, menopausia, hipotiroidismo, obesidad, artritis y embarazo [4]. Dado que el hipotiroidismo, la menopausia y el embarazo son factores de riesgo, existe una fuerte sospecha de que los cambios hormonales pueden ser causantes. Sin embargo, en la actualidad no existe actualmente evidencia que apoye esta hipótesis.

Los datos epidemiológicos muestran que la incidencia del STC relacionado con el embarazo es alta, entre un 7-43% cuando se diagnostica electrofisiológicamente y 31-62% cuando se diagnostica con examen clínico.

Existen pruebas contundentes que respaldan la diabetes mellitus tipo 1 y tipo 2 como factores de riesgo para el STC. De manera similar, el sobrepeso aumenta el riesgo de padecer síndrome del túnel carpiano en 1,5 veces y la obesidad aumenta el riesgo en dos veces [15]. Por el contrario, no existe evidencia de un mecanismo específico por el cual la diabetes o la obesidad aumentan el riesgo de STC. Esto también ocurre con el tabaquismo.

Por otro lado, los factores de riesgo ocupacional, debidos al empleo ejercido, por sí solos no explican la aparición de STC y se propone que interviene una combinación de varios factores [2]. Esto fue respaldado por un análisis que mostró que el 81,5% de la variación explicable en el STC definido electrofisiológicamente se atribuyó al índice de masa corporal, la edad y la relación entre la profundidad y el ancho de la muñeca, mientras que solo el 8,29% se debió a factores relacionados con el trabajo.

En concreto, se ha tratado de buscar la asociación entre el uso del ordenador (teclado o ratón) y el STC. En este caso, estudios recientes no mostraron una asociación, aunque algunas circunstancias laborales podrían estar asociadas con dicho síndrome. La mayoría de STC se atribuyen a factores relacionados con el paciente (factores de riesgo intrínsecos). Varios estudios han señalado que la aparición de STC está relacionada con hábitos y estilo de vida poco saludables [16].

2.1.4. Características clínicas

En el STC, es importante la presentación clínica, ya que, una historia clínica completa y precisa, junto con la exclusión de otras posibles causas, es el principal mecanismo de diagnóstico. Posteriormente, se detallarán otras formas diagnósticas basadas en electrofisiología.

El STC se caracteriza por parestesias y disestesias nocturnas intermitentes que aumentan en frecuencia y ocurren durante las horas de vigilia. La parestesia se utiliza para describir una sensación anormal, que no es considerada como desagradable. La disestesia es una sensación anormal desagradable, independientemente de que sea espontánea o provocada.

Posteriormente, se desarrolla pérdida de sensibilidad, junto con debilidad y atrofia del músculo tenar, que provienen de una degeneración axonal extensa [17]. Esta secuencia de síntomas es bastante típica y rara vez ocurre en trastornos distintos al STC.

El STC generalmente se caracteriza por el desarrollo de síntomas en la mano que, en casos graves, pueden extenderse proximalmente al antebrazo, la parte superior del brazo y, a veces, el hombro. Durante años, los criterios de diagnóstico sensorial en la literatura se limitaron a los síntomas que ocurrían en el territorio del nervio mediano de la mano. Sin embargo, en la práctica clínica, se utilizaron criterios sensoriales más amplios, que no limitaron los síntomas a los primeros tres dígitos, sino que incluyeron toda la superficie palmar. Los síntomas que se limitan a los primeros tres dígitos podrían indicar una afectación más severa del nervio mediano.

Aunque el dolor es un síntoma común en pacientes que presentan el STC en la práctica clínica, no siempre está presente. La prueba de *Tinel*, que consiste en el golpeteo del retináculo flexor; y la maniobra de *Phalen*, en la que se realiza una flexión pasiva completa de la muñeca sostenida durante 1 minuto; son pruebas de diagnóstico muy empleadas para el STC. Aunque estas pruebas se utilizan ampliamente debido a su facilidad de realización, su sensibilidad y especificidad, son objeto de un amplio debate, por lo que se suele concretar el diagnóstico mediante estudios de conducción nerviosa, considerados *gold standard*.

2.1.5. Diagnóstico

La combinación de síntomas y características clínicas con las mediciones electrofisiológicas es el medio más robusto para el diagnóstico del STC. Los estudios de conducción nerviosa y la electromiografía (EMG) se utilizan para evaluar la conducción de impulsos eléctricos a lo largo de los nervios periféricos.

Los estudios de conducción nerviosa miden la velocidad de conducción nerviosa sensorial y motora en el nervio mediano al nivel de la muñeca mediante el uso de electrodos. El componente sensorial del nervio mediano se ve afectado mucho antes que el componente motor, por lo que, en las primeras etapas del STC, suele haber un retraso en la velocidad de conducción del nervio sensorial. Como medidas diagnósticas se emplean las latencias sensoriales y motoras.

En casos severos de STC, los resultados de los estudios de conducción nerviosa pueden no tener relación con los hallazgos clínicos debido a la naturaleza variable del deterioro en diferentes fibras nerviosas [18]. Por lo tanto, estos estudios sugieren que el diagnóstico debe basarse en la presencia de síntomas clínicos, hallazgos físicos y estudios de conducción nerviosa en conjunto.

Actualmente, se encuentra disponible una técnica emergente para la obtención de imágenes de las conexiones neuronales mediante tractografía por resonancia magnética [4]. Esta técnica puede proporcionar detalles sobre el daño morfológico y la inflamación, y los primeros estudios muestran que el coeficiente de difusión aparente concuerda con los resultados de los estudios de conducción nerviosa. Aunque proporciona excelentes capacidades de imagen, el uso de esta técnica está limitado por su coste y, al igual que ocurre con la ecografía, la investigación debe demostrar que su valor clínico añadido justifica el coste.

2.1.6. Clasificación

Una de las escalas más empleadas para diagnosticar la gravedad electrofisiológica del STC es la basada en tres grados (Tabla 1), propuesta por *Sucher* en [7]. Esta escala proporciona una combinación de los criterios de clasificación utilizados en anteriores publicaciones de *Bland* [6], *Stevens* [5] y otros. De esta forma, se obtiene una representación más precisa de las posibles anomalías, permitiendo mayor diferenciación en casos limítrofes, lo que contribuye a tomar las mejores decisiones terapéuticas.

Tabla 1. Escala de gravedad electrofisiológica [7].

Clasificación	Descripción
Leve	<ul style="list-style-type: none"> • Latencia sensorial prolongada. • Latencia motora normal o mínimamente prolongada. • Sin bloqueo de conducción o bloqueo leve. • No existen anomalías en el EMG tenar. • Amplitudes de las repuestas sensitivas y motoras son normales.
Moderado	<ul style="list-style-type: none"> • Latencia motora y latencia sensorial prolongadas. • Puede existir bloqueo de conducción. • Se pueden observar escasas anomalías en el EMG tenar. • Puede haber disminución de la amplitud de las respuestas sensitivas y motoras.
Severo	<ul style="list-style-type: none"> • Latencia sensorial y motora. Si están presentes, son muy prolongadas. • El bloqueo de conducción puede estar presente y ser pronunciado (mayor al 70%) • Amplitud de las respuestas motora y sensitiva reducidas o ausentes. • Existe evidencia de anomalías en el EMG.

2.1.7. Epidemiología

La prevalencia e incidencia informadas del STC varían ampliamente según los criterios de diagnóstico utilizados en diferentes estudios. El uso de criterios clínicos en el diagnóstico da como resultado una estimación más alta que el uso de criterios electrofisiológicos. Clínicamente, se cree que una de cada 10 personas desarrolla el STC en algún momento de su vida [4].

Atroshi et al. en [19], en su estudio muestran una prevalencia del STC similar entre hombres y mujeres, con una proporción hombre: mujer de 1: 1,4. Sin embargo, la prevalencia es más alta en mujeres mayores. A la edad de 65 a 74 años, la prevalencia en mujeres es casi cuatro veces mayor que en hombres, 5,1% frente a 1,3%, respectivamente.

En la Tabla 2, se puede observar la prevalencia de esta patología en los distintos países de la Unión Europea [3]. Estos datos son bastante dispares entre países, lo que puede deberse a los distintos criterios diagnósticos empleados.

Tabla 2. Prevalencia del STC en diferentes países de Europa

País	Población Total	Población de edad 15-65(%)	Prevalencia (%)
Reino Unido	62989551	66,2	0,39
Alemania	81843743	65,9	43,1
Italia	60820696	65,6	01,1
España	46196276	68,2	10,7
Francia	6532772	64,8	3,15
Dinamarca	5580516	65,4	3,1
Hungría	9957731	68,5	10,88
Portugal	10541840	66,8	0,29
Suecia	9482855	65,2	3,8
Turquía	74724269	67,2	2,8
Países Bajos	16730348	67,1	4,9
Finlandia	5401267	66,3	3,8

2.1.8. Tratamiento

Generalmente, el tratamiento para el STC se puede clasificar en quirúrgico y no quirúrgico.

Los métodos no quirúrgicos son eficaces en pacientes con STC de leve a moderado. Están indicados en pacientes sin debilidad ni atrofia muscular, sin denervación en el examen con aguja de electromiografía y con una anomalía leve en los estudios de conducción nerviosa. Las mujeres embarazadas con STC rara vez requieren tratamiento quirúrgico. Estos métodos incluyen el uso de ortesis de mano, entablillado de la muñeca, terapia ultrasónica, terapia con láser, esteroides orales, medicamentos antiinflamatorios no esteroideos (AINE), vitamina B6 oral, inyección local de corticosteroides, modificaciones en el lugar de trabajo, yoga, etc.

Los tratamientos basados en cirugía consisten en la división del ligamento carpiano transversal. Esto reduce la presión sobre el nervio mediano, aumentando el espacio en el túnel carpiano. La cirugía está indicada en casi todos los pacientes con STC de moderado a grave.

2.2. CEFALEA TENSIONAL

La Cefalea Tensional (CT) son episodios recurrentes de dolor de cabeza que pueden durar minutos o, incluso, semanas. El dolor suele ser de carácter opresivo, de intensidad leve a moderada y de ubicación bilateral, con escasos síntomas a mayores. Dentro de las cefaleas primarias, la CT es la de mayor prevalencia [20], aunque varía entre estudios entre el 30% y el 78% [10].

Anteriormente, la Cefalea Tensional era conocida con otros muchos términos, como dolor de cabeza psicógeno, dolor de cabeza por estrés, dolor de cabeza psicomiogénico, dolor de cabeza por contracción muscular, etc. Sin embargo, el término "cefalea tensional" ha sido elegido por el Comité de Clasificación de Cefaleas de la Sociedad Internacional de Cefaleas en 1988 y consolidado en las versiones posteriores ICHD-II e ICHD-III [10].

La CT es la forma más común de dolor de cabeza, pero recibe muy poca atención por parte de las autoridades sanitarias, los investigadores clínicos o los farmacólogos industriales en comparación con otras patologías como la migraña. Además, la mayoría de las personas con CT poco frecuente o frecuente no consulta a un médico, sino que deciden automedicarse con analgésicos de venta libre [8]. Sin embargo, la CT crónica, definida como un dolor de cabeza que se presenta durante, al menos, 15 días al mes, es un problema de salud importante con enormes efectos socioeconómicos.

Para algunos autores, la sensibilización periférica es la causa principal de la Cefalea Tensional Episódica (CTE). Sin embargo, este tipo de cefalea puede llegar a convertirse en crónica si también se produce sensibilización central, causada por estímulos nociceptivos prolongados en el tiempo en tejidos miofasciales. En el caso de la Cefalea Tensional Crónica (CTC), la causa principal es la sensibilización central.

La palabra tensional muestra una patogénesis incierta e indica que algún tipo de tensión mental o muscular puede desempeñar un papel causal [21]. Sin embargo, una gran número de estudios clínicos y neurofisiológicos confirman una base neurobiológica y se alejan del ámbito de las enfermedades psicológicas.

Los mecanismos miofasciales periféricos y la desregulación central de las estructuras de procesamiento del dolor están implicados en el origen de la CT, pero su importancia relativa varía con la frecuencia de la cefalea y entre los diferentes pacientes.

El diagnóstico de la CT se basa exclusivamente en los síntomas clínicos, que son similares a los síntomas de la migraña. Debido a la falta de características específicas de la enfermedad, varios dolores de cabeza secundarios, dolores de cabeza que se sabe que son causados por otro trastorno, pueden presentarse como CT [8].

2.2.1. Fisiopatología

A pesar de los numerosos estudios clínicos y neurofisiológicos realizados a lo largo de los años, la causa exacta de la CT sigue sin estar clara. Cuando, en la CT, el dolor se origina en los tejidos miofasciales o en los mecanismos centrales del cerebro, genera cierto debate entre los diferentes autores.

Se ha demostrado que los mecanismos miofasciales pericraneales probablemente sean de importancia en la CTE. Sin embargo, la sensibilización de las vías del dolor en el sistema nervioso central como

resultado de estímulos nociceptivos prolongados de los tejidos miofasciales pericraneales parece ser responsable de la conversión de la enfermedad a CTC [22].

El origen de esta nocicepción periférica aún no se ha identificado y las formas de prevenir la sensibilización central pueden proporcionar las herramientas para tratar a los pacientes con CT más difíciles de tratar.

En la Figura 3, propuesta por *Fumal et al.* en [8], se muestra un modelo fisiopatológico de la CTC. El aumento continuado de entradas nociceptivas desde los tejidos miofasciales pericraneales (líneas rojas) da lugar a cambios plásticos, es decir, a la sensibilización de las neuronas nociceptivas de segundo orden en el asta dorsal espinal (segundo y tercer segmentos cervicales) y el núcleo del trigémino. Por lo tanto, la entrada nociceptiva a las estructuras supraespinales aumentará considerablemente, lo que podría resultar en un aumento de la excitabilidad de las neuronas supraespinales y una variación en la transmisión nociceptiva en el asta dorsal espinal y el núcleo del trigémino (líneas verdes). Los cambios neuroplásticos centrales también pueden aumentar el impulso a las neuronas motoras, lo que da como resultado un leve aumento de la actividad muscular y un aumento de la dureza muscular. Esta sensibilización central es malinterpretada como dolor.




Figura 3. Modelo fisiopatológico de la CT crónica [8].

2.2.2. Características clínicas

El dolor producido por la CT se define como sordo, similar a la presión, que constriñe o da una sensación de plenitud en la cabeza. Con bastante frecuencia, los pacientes describen su dolor como “llevar una carga pesada en la cabeza”. La ubicación del dolor varía considerablemente entre pacientes y puede ser interior o posterior. Además del dolor, hay una serie de características clínicas que ayudan en el diagnóstico de esta patología:

- La actividad física no influye en la intensidad del dolor de cabeza en la mayoría de los pacientes. Esto contrasta marcadamente con la migraña, donde el dolor empeora con la actividad física

de rutina y, por lo tanto, se considera uno de los mejores criterios para distinguir entre migraña y CT [23].

- La CT puede provocar fotofobia o fonofobia, que es hipersensibilidad a la luz o al sonido respectivamente, pero no ambos síntomas a la vez. Sin embargo, la presencia de náuseas y vómitos descarta el diagnóstico de CT.
- El estrés, la falta de sueño y los desajustes horarios en las comidas se encuentran entre los factores desencadenantes del dolor de cabeza más comunes, síntomas informados tanto por pacientes con migraña como por aquellos con dolor de cabeza de tipo tensional.
- A menudo, la CT comienza en algún momento durante el día y aumenta lentamente a lo largo del mismo. Además, el dolor no suele alterarse durante las diferentes actividades, aunque puede agravarse al final de la noche.
- La obtención de una historia clínica buena y detallada y exámenes físicos y neurológicos cuidadosos son claves a la hora de obtener un diagnóstico.
- El examen físico debe incluir la palpación manual de los músculos pericraneales para identificar los puntos sensibles y los puntos gatillo. Los puntos sensibles son áreas donde la presión manual induce dolor en la zona de aplicación. Los puntos gatillo se palpan en áreas de sensibilidad profunda localizada donde la presión sostenida también induce dolor referido en otra área de la región.

2.2.3. Diagnóstico

La CT se diagnostica principalmente por la ausencia de características propias de otros tipos de cefaleas, como la migraña. Por esto, tener una historia clínica buena y detallada es clave para el diagnóstico de este tipo de patologías.

La característica fisiopatológica más significativa en pacientes con cualquier tipo de CT es el aumento de la sensibilidad pericraneal. Se presenta típicamente de manera interictal, entre dos episodios de cefaleas; se exacerba durante la cefalea real y aumenta con la intensidad y frecuencia de las cefaleas.

La sensibilidad pericraneal se detecta y registra fácilmente mediante palpación manual. Pequeños movimientos de rotación con los dedos índice y medio y presión firme, preferiblemente con la ayuda de un palpómetro), proporcionan puntuaciones de sensibilidad local de 0 a 3 para los músculos frontal, temporal, masetero, pterigoideo, esternocleidomastoideo, esplenio y trapecio. Estos se pueden sumar para obtener una puntuación de sensibilidad total para cada paciente. Estas medidas son una guía útil para el tratamiento y agregan valor y credibilidad a las explicaciones que se le dan al paciente.

La dificultad diagnóstica más común entre los trastornos de cefalea primaria es discriminar entre CT y las formas leves de migraña sin aura [10]. El principal problema es que los pacientes con dolores de cabeza frecuentes suelen sufrir ambos trastornos. El Comité de Clasificación de Cefaleas de la Sociedad Internacional de Cefaleas ha sugerido criterios diagnósticos más estrictos para la CT con la esperanza de excluir la migraña que fenotípicamente se asemeja a la CT.

2.2.4. Clasificación

Se han determinado en el ICHD-III [10] una serie de criterios de clasificación para la CT según las características clínicas del paciente (Tabla 3). Existen una serie de criterios comunes en todas las CT que se detallan a continuación:

- 1) Duran de 30 minutos a siete días.
- 2) Al menos dos de los siguientes cuatro características:
 - a) Ubicación bilateral.
 - b) Dolor por presión (no pulsante).
 - c) Intensidad leve o moderada.
 - d) No agravada por la actividad física rutinaria como caminar o subir escaleras.
- 3) No deben presentar náuseas ni vómitos y puede desarrollar fotofobia o fonofobia, pero no ambas.

Tabla 3. Clasificación de la cefalea tensional

Tipo	Descripción	Criterios de diagnóstico	Subtipos	Características de los subtipos
Cefalea tensional episódica poco frecuente	Episodios infrecuentes de cefalea, típicamente bilateral, de calidad opresiva o tensora y de intensidad leve a moderada, que duran de minutos a días.	Al menos 10 episodios de cefaleas que ocurren en menos de 1 día/mes en promedio (menos de 12 días/año) y cumplen los criterios comunes.	Cefalea tensional episódica infrecuente asociada con sensibilidad pericraneal	Aumento de la sensibilidad pericraneal en la palpación manual.
	El dolor no empeora con la actividad física de rutina y no se asocia con náuseas, aunque puede haber fotofobia o fonofobia.		Cefalea tensional episódica infrecuente no asociada con dolor a la palpación pericraneal	Sin aumento de la sensibilidad pericraneal.
Cefalea tensional episódica frecuente	Episodios frecuentes de cefalea, típicamente bilateral, de calidad opresiva o tensora y de intensidad leve a moderada, que duran de minutos a días.	Al menos 10 episodios de cefalea que ocurren de 1 a 14 días/mes en promedio durante más de 3 meses (más de 12 y menos de 180 días/año) y cumplen los criterios comunes.	Cefalea tensional episódica frecuente asociada con dolor a la palpación pericraneal	Aumento de la sensibilidad pericraneal en la palpación manual.
	El dolor no empeora con la actividad física de rutina y no se asocia con náuseas, aunque puede haber fotofobia o fonofobia.		Cefalea tensional episódica frecuente no asociada con dolor a la palpación pericraneal	Sin aumento de la sensibilidad pericraneal.

**DESARROLLO DE PERFILES DE PACIENTES AFECTADOS POR SÍNDROME DE TÚNEL CARPIANO Y
CEFALEA TENSIONAL MEDIANTE EL USO DE TÉCNICAS DE APRENDIZAJE AUTOMÁTICO**

Cefalea tensional crónica	<p>Trastorno que evoluciona de una cefalea tensional episódica frecuente, con episodios diarios o muy frecuentes de cefalea, típicamente bilaterales, de calidad opresiva o tensora y de intensidad leve a moderada, que duran de horas a días.</p> <p>El dolor no empeora con la actividad física de rutina, pero puede estar asociado con náuseas leves, fotofobia o fonofobia.</p>	<p>Dolor de cabeza que se presenta en un promedio de 15 días/mes durante más de 3 meses (180 días/año), que cumple con los criterios comunes.</p>	Cefalea tensional crónica asociada con sensibilidad pericraneal	Aumento de la sensibilidad pericraneal en la palpación manual.
			Cefalea tensional crónica no asociada con hipersensibilidad pericraneal	Sin aumento de la sensibilidad pericraneal.
Cefalea tensional probable	<p>Cefalea tensional sin una de las características definidas para cumplir con todos los criterios para un tipo o subtipo de cefalea tensional definida anteriormente, y no cumple los criterios de otro trastorno de cefalea.</p>		Cefalea tensional episódica infrecuente probable	Cumplen todos los criterios definidos para cefalea tensional episódica infrecuente menos uno
			Cefalea tensional episódica frecuente probable	Cumplen todos los criterios definidos para cefalea tensional episódica frecuente menos uno
			Cefalea tensional crónica probable	Cumplen todos los criterios definidos para cefalea tensional crónica menos uno

2.2.5. Epidemiología

En diversos estudios se ha estimado que la prevalencia de por vida de la CT es del 79%; mientras que solamente el 3% de los pacientes experimentaron CTC, es decir, cefaleas que se presentan, al menos, 15 días al mes [24].

La prevalencia de la CT disminuye con la edad en ambos sexos, aunque suele ser mayor en mujeres [20]. En la Tabla 4 se pueden observar las prevalencias de la CT en distintos países de Europa por sexos y edades.

Tabla 4. Prevalencia de la CT en diferentes países de Europa [20].

País	Población muestral	Rango de edad (años)	Prevalencia (%)		
			H	M	Total
Croacia	3794	15-65	32,3	37,1	34,8
Dinamarca	28195	12-41	78,9	92,5	86
Alemania	7341	>18	53	66	60,2
Noruega	8255	13-19	12,5	23,2	18
Suecia	1850	7-15	7,9	11,8	9,8
Turquía	2226	17-21	14,3	22,7	20,35

2.2.6. Tratamiento

La compleja interrelación entre los diversos aspectos fisiopatológicos de la CT podría explicar por qué este trastorno es tan complicado de tratar. Además, se deben utilizar varios enfoques terapéuticos en secuencia o en combinación para su tratamiento.

El tratamiento de la CT debe prevenir la condición de convertirse en crónica, por tanto, la elección terapéutica para cada paciente debe ser estudiada con el fin de reducir los estímulos nociceptivos prolongados de los tejidos miofasciales pericraneales.

Las terapias para la CT se pueden subdividir en tratamiento a corto plazo, abortivos (principalmente farmacológicos) de cada ataque de cefalea y tratamientos profilácticos (farmacológicos o no farmacológicos) a largo plazo para evitar su progresión.

En cuanto a las técnicas no farmacológicas, las terapias se basan en técnicas psicológicas y conductuales y técnicas de fisioterapia.

Dentro de las técnicas psicológicas para el tratamiento de la CT, se pueden emplear técnicas de relajación basadas en retroalimentación por *biofeedback*, empleando electromiografía (EMG). El entrenamiento de relajación y de *biofeedback* EMG solos, y en combinación, conducen a una reducción de casi el 50% en el desarrollo del dolor de cabeza [25].

En cuanto a las técnicas de fisioterapia para el tratamiento de la CT incluyen posicionamiento, instrucción ergonómica, masaje, estimulación nerviosa eléctrica transcutánea, aplicación de calor o frío y acupuntura. Ninguna de estas técnicas ha demostrado ser eficaz a largo plazo, aunque el tratamiento físico, como el masaje, puede ser útil en episodios agudos de CT [26].

2.3. APRENDIZAJE AUTOMÁTICO

El aprendizaje automático es un subcampo de la ciencia de datos y un ejemplo de aplicación de la inteligencia artificial. El aprendizaje automático se conoce como un conjunto de métodos que pueden detectar automáticamente patrones en los datos.

Los patrones descubiertos en los datos se emplean posteriormente para predecir o clasificar datos futuros, para observar estructuras como subgrupos en los datos, o extraer información adecuada de los datos para generar nuevos conocimientos. La inteligencia artificial (IA) y el aprendizaje automático tienen como objetivo aprender de los datos.

Los datos están caracterizados por variables o características que pueden dividirse en dos grupos:

- **Variables cuantitativas o numéricas.** Reflejan una magnitud, es decir, los valores que pueden tomar son números. Pueden ser discretas, si existe un número finito de valores que puede tomar o continua, si el número de valores que puede tomar la variable es infinito.
- **Variables cualitativas o categóricas.** Son variables no son numéricas, cuyos valores encajan en categorías. Se trata de una variable que toma como valores modalidades, categorías o incluso niveles, en contraste con las variables cuantitativas que miden una cantidad.

Las variables cualitativas se dividen en dos grupos, nominales, si las categorías de la variable no se pueden ordenar; y ordinales, cuando las categorías se pueden ordenar.

La definición inicial de IA se origina en Alan Turing, quien propuso en [27] un experimento en el que 2 jugadores, que pueden ser humanos o artificiales, intentan convencer a un tercer jugador humano de que también son humanos. El jugador creado con IA pasa la prueba si el tercer jugador no puede decir quién es la máquina.

El aprendizaje automático surge en la intersección entre la estadística, que busca aprender las relaciones a partir de los datos, y la informática, con énfasis en los algoritmos informáticos eficientes. La estadística emplea ecuaciones matemáticas para modelar relaciones de probabilidad entre variables de datos, mientras que el aprendizaje automático aprende de los datos sin necesidad de conocimientos previos.

Las técnicas de aprendizaje automático se pueden agrupar en cuatro categorías:

- **Aprendizaje supervisado.** Si se conoce a priori el resultado o salida que se desea predecir, es decir, todos los datos se encuentran etiquetados.
- **Aprendizaje no supervisado.** Si no se conoce a priori el resultado o salida que se desea predecir, por tanto, los datos no se encuentran etiquetados.
- **Aprendizaje semi-supervisado.** Se encuentra a medio camino entre el aprendizaje supervisado y el no supervisado. Solamente se conocen las etiquetas de un subconjunto de los datos.
- **Aprendizaje reforzado.** El modelo es alimentado con una recompensa. El objetivo es encontrar la política (secuencia de acciones) que maximice la recompensa a largo plazo.

En los últimos años se ha incrementado el interés de la comunidad médica en el uso de técnicas de aprendizaje automático con fines médicos [28]. Se debe, en gran medida, a los avances en hardware,

ordenadores rápidos y baratos, y al aumento de la disponibilidad de conjuntos de datos médicos y sanitarios tanto públicos como privados.

2.3.1. Aprendizaje no supervisado

Los métodos de aprendizaje no supervisados no requieren que el conjunto de datos de entrenamiento contenga información a priori de las variables objetivo, ya que, en este caso, no existen unos resultados que predecir.

Los métodos no supervisados pueden detectar estructuras de agrupamiento nuevas y potencialmente interesantes en un conjunto de datos. El objetivo es modelizar la estructura o distribución de los datos para extraer información, como patrones o agrupaciones naturales.

Se denomina no supervisado porque, al contrario del aprendizaje supervisado, tiende a ser subjetivo, ya que, no existe una sola respuesta correcta. En la Figura 4 se puede observar el esquema general de los algoritmos no supervisados.

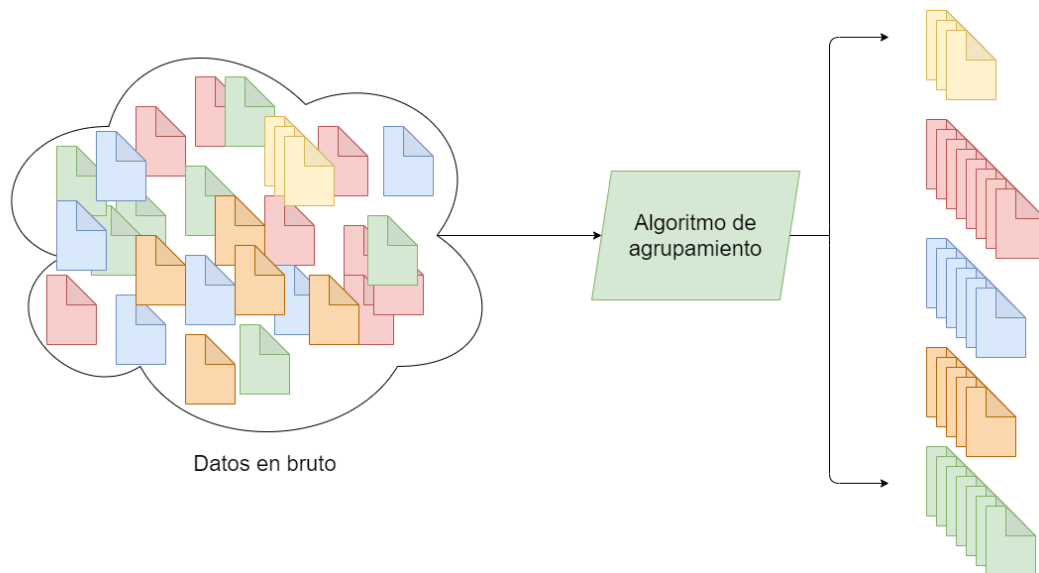


Figura 4. Esquema general de un algoritmo de aprendizaje no supervisado.

La mayoría de los algoritmos no supervisados requieren que se introduzcan ciertos parámetros de entrada (por ejemplo, el número de grupos en el conjunto de datos), lo que puede limitar su aplicabilidad. Se detallarán en profundidad en la siguiente sección.

2.3.2. Otros tipos de aprendizaje

Las técnicas de aprendizaje automático se pueden agrupar en cuatro categorías:

- El **aprendizaje supervisado** es un proceso que consiste en aproximar una función, que trata de predecir una variable objetivo, a partir de un conjunto de variables de entrada. Si la variable objetivo a predecir es cuantitativa, se trata de un problema de regresión; mientras que, si la variable objetivo es cualitativa, se considera un problema de clasificación.

El término "supervisado" hace referencia al proceso de entrenamiento del algoritmo, el cual se supervisa teniendo los datos previamente etiquetados y clasificados, es decir, se conocen el grupo, valor o categoría a la que pertenecen los datos. De esta forma, el algoritmo va aprendiendo a clasificar las muestras de entrada comparando el resultado del modelo y la etiqueta real de la muestra, que es conocida. Durante el entrenamiento, el modelo realiza las compensaciones necesarias teniendo en cuenta el error obtenido en la estimación del resultado con respecto al valor real.

En la Figura 5, se puede observar un esquema general del aprendizaje supervisado. La variable objetivo se ha representado con la letra Y; mientras que las variables utilizadas para predecir las salidas se han representado con la letra X.

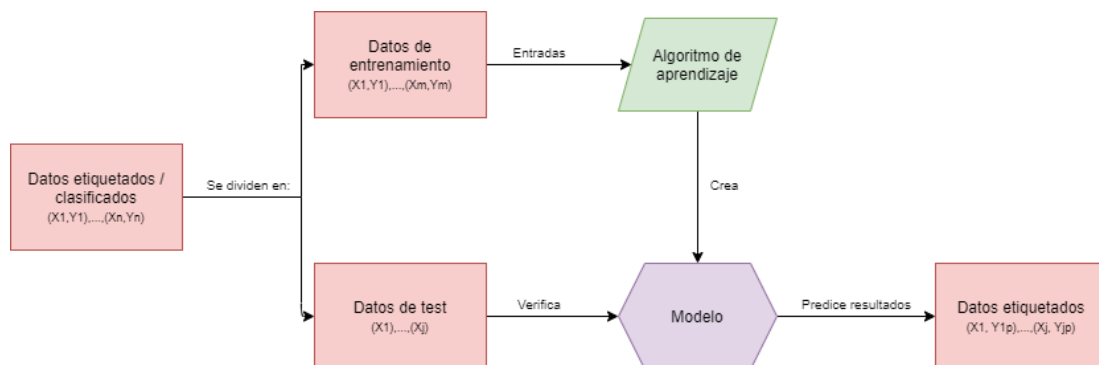


Figura 5. Esquema general de un modelo de aprendizaje supervisado.

- El **aprendizaje semi-supervisado** se encuentra a medio camino entre el aprendizaje supervisado y el no supervisado. En este caso se dispone tanto de datos con información a priori de la variable objetivo como de datos sin información de dicha variable.

El objetivo de este tipo de técnicas es combinar los datos etiquetados y los no etiquetados para construir un modelo supervisado que aumente la cantidad de datos etiquetados, lo que genera unos mejores resultados en el modelo final.

- El **aprendizaje por refuerzo** trata de desarrollar un sistema que, mediante secuencias de intentos y fallos, se mejora a sí mismo en función de una recompensa obtenida al realizar el intento. Para ello, se emplea la técnica denominada exploración/explotación, que consiste en dejar que la acción tenga lugar, se observan las consecuencias y la siguiente acción considera los resultados de la primera acción. El objetivo final es encontrar la política (secuencia de acciones) que maximice la recompensa a largo plazo.

3. MATERIALES

3.1. DATOS DE PACIENTES

Los datos utilizados para la realización del presente trabajo final de máster han sido recopilados y aportados por la profesora Esperanza Navarro, perteneciente a la *Facultad de Psicología de la Universitat de València*. El conjunto de datos está formado por una serie de características clínicas y resultados de pruebas realizadas a pacientes aquejados de Síndrome de Túnel Carpiano y Cefalea Tensional.

3.1.1. Conjunto de datos de pacientes con Síndrome de Túnel Carpiano

El conjunto de datos de pacientes con STC presenta 35 variables cuantitativas y 3 variables cualitativas definidas en la Tabla 5.

Tabla 5. Variables del conjunto de datos de pacientes con STC

VARIABLES CUANTITATIVAS	
Característica	Descripción
edad	Edad en años del paciente.
yearswithpain	Tiempo, especificado en años, desde la aparición del dolor.
doloractual	<p>Escala de dolor con valores entre 0 y 10 en el momento de la prueba. La valoración del dolor puede ser:</p> <ul style="list-style-type: none"> • Dolor leve. Si el paciente puntúa el dolor como menor de 3. • Dolor moderado. Si la valoración se sitúa entre 4 y 7. • Dolor severo. Si la valoración es igual o superior a 8.
dolorpeorsemana	Escala con valores entre 0 y 10 en referencia al peor dolor sufrido durante la semana. La valoración del dolor es la misma que para el dolor actual.
CTSfunction	Escala con valores entre 1 y 5 que evalúa la funcionalidad de la mano afectada. Cuanto mayor es el valor, peor es la funcionalidad.
CTSseveridad	Escala con valores entre 1 y 5 que evalúa la severidad de los síntomas en la mano afectada. Cuando mayor es el valor, mayor es la severidad.
PPTmedianoafected PPTmedianounaffected PPTcubitalaffected PPTcubitalunaffected PPTradialaffected PPTradialunaffected PPTcuelloafected PPTcuellounaffected PPTcarpoafected PPTcaporunaffected PPTpiernaafected PPTpiernaunaffected	<p>Valor de presión mínima ejercida para despertar la sensación de dolor (umbral de dolor). Las zonas probadas son:</p> <ul style="list-style-type: none"> • Nervio mediano de la mano afectada y la sana. • Nervio cubital de la mano afectada y la sana. • Nervio radial de la mano afectada y la sana. • Zona del cuello del lado afectado y del lado sano. • Zona del carpo de la mano afectada y la sana. • Pierna del lado afectado y del lado sano.

DESARROLLO DE PERFILES DE PACIENTES AFECTADOS POR SÍNDROME DE TÚNEL CARPIANO Y CEFALEA TENSIONAL MEDIANTE EL USO DE TÉCNICAS DE APRENDIZAJE AUTOMÁTICO

UDCtunelafecto UDCtunelunaffected UDCpalmaafecta UDCpalmaunaffected	Valor de temperatura en escala ascendente que provoca la primera sensación de dolor (umbral de dolor al calor) medido en: <ul style="list-style-type: none"> • Zona del túnel carpiano de la mano afectada y de la sana. • Palma de la mano afectada y sana.
UDFtunelafecto UDFtunelunaffected UDFpalmaafecta UDFpalmaunaffected	Valor de temperatura en escala descendente que provoca la primera sensación de dolor (umbral de dolor al frío) medido en: <ul style="list-style-type: none"> • Zona del túnel carpiano de la mano afectada y de la sana. • Palma de la mano afectada y sana.
Pinzaindicedrcha Pinzacorazondrcha Pinzaanulardrcha Pinzameñiquedrcha Pinzaindiceizqda Pinzacorazonizqda Pinzaanularizqda Pinzameñiqueizqueda	Valor de fuerza de agarre en la punta de los dedos entre el pulgar y el resto de los dedos de las manos. La fuerza de pinzamiento se mide en Kg entre: <ul style="list-style-type: none"> • Dedo índice y pulgar de las manos derecha e izquierda. • Dedo corazón y pulgar de las manos derecha e izquierda. • Dedo anular y pulgar de las manos derecha e izquierda. • Dedo meñique y pulgar de las manos derecha e izquierda.
Depresion	Valor obtenido tras la evaluación de la depresión del paciente mediante la prueba BDI-II. Los puntos de corte estandarizados son [29]: <ul style="list-style-type: none"> • 0-13: depresión mínima. • 14-19: depresión leve. • 20-28: depresión moderada. • 29-63: depresión severa.

VARIABLES CUALITATIVAS

Característica	Descripción
grados	Grado del STC, medido por electromiografía. Los posibles valores son Leve, Moderado o Importante.
lado	Indica el lado del dolor del STC. Los posibles valores son Bilateral, Derecho e Izquierdo.

3.1.2. Conjunto de datos de pacientes con Cefalea Tensional

El conjunto de datos de pacientes con CT consta de 35 variables cuantitativas y 3 variables cualitativas definidas en la Tabla 6.

Tabla 6. Variables del conjunto de datos de pacientes con CT

VARIABLES CUANTITATIVAS

Característica	Descripción
Edad	Edad en años del paciente.
Tiempo_comienzo	Tiempo, especificado en años, desde el comienzo de los síntomas.
EVA	Escala de dolor con valores entre 0 y 10, donde la valoración del dolor puede ser: <ul style="list-style-type: none"> • Dolor leve. Si el paciente puntúa el dolor como menor de 3. • Dolor moderado. Si la valoración se sitúa entre 4 y 7. • Dolor severo. Si la valoración es igual o superior a 8.

DESARROLLO DE PERFILES DE PACIENTES AFECTADOS POR SÍNDROME DE TÚNEL CARPIANO Y CEFALEA TENSIONAL MEDIANTE EL USO DE TÉCNICAS DE APRENDIZAJE AUTOMÁTICO

Duracion	Duración en horas de cada episodio de cefalea.
FreqMONT	Número de días con cefalea al mes.
TrPsactivos TrPslatentes TOTALTrPs	<p>Número de puntos gatillo o <i>Trigger Points</i> (miofasciales) activos, latentes y totales.</p> <p>Los puntos gatillo miofasciales son puntos hiperirritables ubicados dentro de una banda de músculo esquelético o fascia, que causan dolor referido, sensibilidad local y contracción local cuando se comprimen [30].</p> <ul style="list-style-type: none"> • Los puntos gatillo activos producen dolor espontáneo, sensibilidad en una banda tensa, y una respuesta de contracción local cuando se estimula manualmente o con una aguja. • Los puntos gatillo latentes son lesiones neuromusculares subclínicas menores que no causan dolor, excepto cuando se comprimen.
UDP_C5C6_Dcha UDP_C5C6_Izda UDP_Temporal_Dcho UDP_Temporal_Izdo UDP_IIMeta_Dcho UDP_IIMeta_Izdo UDP_Tibial_Dcho UDP_Tibial_Izdo	<p>Valor de presión mínima ejercida para despertar la sensación de dolor (umbral de dolor). Las zonas probadas son:</p> <ul style="list-style-type: none"> • Entre cervicales 5 y 6 derecha e izquierda. • Zona craneal temporal derecha e izquierda. • II metacarpiano de mano derecha e izquierda. • Zona tibial en pierna derecha e izquierda.
HDI_Emocional HDI_Fisico	<p>La escala <i>Headache Disability Inventory</i> (HDI) evalúa el impacto de la cefalea y su tratamiento en la vida diaria [31]. Cuanto mayor es la puntuación, mayor es la incapacidad autopercibida por la cefalea.</p> <p>La escala HDI emocional comprende valores entre 0 y 52 y la HDI físico entre 0 y 48.</p>
Funcion_fisica Rol_fisico Dolor_corporal Salud_general Vitalidad Funcion_social Rol_emocional Salud_mental	<p>Valoración psicométrica de los componentes físicos y mentales de la prueba SF-36 [32]. Este procedimiento mide la calidad de vida de las personas, evaluando diferentes dimensiones de la salud de los pacientes. Se obtienen valores entre 0 y 100, siendo 0 una limitación importante y 100 sin limitaciones por las cefaleas. Las dimensiones evaluadas son:</p> <ul style="list-style-type: none"> • Función física. Es el grado en que la salud limita las actividades físicas tales como el autocuidado, caminar, inclinarse, realizar esfuerzos, etc. • Rol físico. Es el grado en que la salud física interfiere en el trabajo y en otras actividades diarias, generando un rendimiento menor que el deseado. • Dolor corporal. Es la intensidad del dolor y su efecto en la salud. • Salud general. Es una valoración personal de la salud que incluye la salud actual, las perspectivas de salud en el futuro y la resistencia a enfermar. • Vitalidad. Sentimiento de energía y vitalidad frente al sentimiento de cansancio y agotamiento. • Función Social. Grado en que los problemas de salud interfieren en la vida social. • Rol Emocional. Grado en que los problemas emocionales interfieren en el trabajo u otras actividades, incluyendo reducción en el tiempo dedicado a éstas y la disminución de la intensidad en el trabajo. • Salud Mental. Incluye depresión, ansiedad, control de la conducta y el bienestar.

globalsueño	Es la calidad del sueño global, evaluada en un rango de valores entre 0 y 21. A partir de un valor de 8, se considera que la calidad del sueño es mala.
HADS_depresión HADS_ansiedad	La escala de ansiedad y depresión hospitalaria (HADS) es un instrumento de autoevaluación altamente empleado para detectar malestar emocional (ansiedad y depresión) en poblaciones con enfermedad física. Se presenta en dos subescalas, de ansiedad y de depresión, con un rango de valores entre 0 y 21, cada una de ellas [29]. Mayor puntuación indica una mayor ansiedad y/o depresión.
STAI_estado STAI_rasgo	El STAI es un instrumento de autoevaluación de la ansiedad en dos subescalas, la ansiedad como estado (condición emocional transitoria) y la ansiedad como rasgo (propensión ansiosa relativamente estable) [33]. Cada subescala consta de valores entre 0 y 60.
RollerDRCHOUMBRAL* RollerIZDOUMBRAL* DolorRollerDRCHOUMBRAL* DolorRollerIZDOUMBRAL*	Escala de dolor con valores entre 0 y 10 en referencia al dolor que se produce tras la presión que se ejerce con un dispositivo <i>roller</i> en los lados derecho e izquierdo. <i>*Estos valores se encuentran en fase experimental y queda pendiente su inclusión en el estudio.</i>

VARIABLES CUALITATIVAS

Característica	Descripción
Sexo	Indica el sexo del paciente. Puede ser Mujer o Varón.
Medicacion_preventiva	Indica si el paciente toma medicación farmacológica preventiva de las cefaleas. Los posibles valores son Si o No.
Tratamiento_sintomático	Indica si el paciente se somete a algún tipo de tratamiento cuando presenta síntomas. Los posibles valores son Si o No.

3.2. HERRAMIENTAS INFORMÁTICAS

3.2.1. Software

En primer lugar, para la visualización y extracción de los datos proporcionados por la profesora Esperanza Navarro ha sido necesaria la utilización del software *SPSS Statistics* de *IBM*. Con la ayuda de este programa se han exportado los datos a un formato interpretable por otras herramientas, en concreto, a formato CSV.

El primer acercamiento y visualización de los datos se ha realizado a través de la plataforma *MATLAB R2019b*, de *The MathWorks, Inc*. Esta plataforma permite un entorno de programación y gráficos integrados con múltiples funciones para el análisis de datos.

Para el desarrollo y la implementación de las técnicas de visualización y preprocesado, junto con la creación de los modelos y la visualización de los resultados se ha empleado el lenguaje de programación *Python3.8*. En concreto, ha sido necesario instalar las librerías *Matplotlib*, *Seaborn*, *NumPy*, *SciPy*, *Pandas* y *scikit-learn* que permiten aplicar las técnicas desarrolladas en la siguiente sección.

Además, se ha utilizado el entorno de desarrollo (IDE) *PyCharm Community Edition* que permite editar los programas realizados en *Python* de forma inteligente, lo que hace el flujo de trabajo mucho más dinámico y eficiente.

3.2.2. Hardware

Es importante conocer las características internas del hardware en el que se ha llevado a cabo el proyecto, ya que, de esto depende tanto el funcionamiento como la velocidad y el rendimiento que se puede alcanzar al interpretar y ejecutar los distintos algoritmos.

La totalidad del proyecto ha sido realizado con el ordenador *MSI Modern 14 A10RB-663XES* cuyas características fundamentales son:

- Procesador *Intel Core i7-10510U* de 4 núcleos con una frecuencia básica del procesador de 1,8GHz.
- 16GB de memoria RAM DDR4 a 2666MHz.
- 512GB de disco duro SSD.
- Tarjeta gráfica *Nvidia GeForce MX250* con 2GB de memoria y frecuencia base de 1227 MHz.

4. MÉTODOS

4.1. EXPLORACIÓN DE LOS DATOS

En esta sección se detallan las técnicas que se han empleado para la visualización y exploración de los datos. Es importante explorar y comprender los datos antes de aplicar mecanismos de aprendizaje automático para evitar obtener resultados irrelevantes y, posteriormente, para interpretar y entender los resultados obtenidos.

La exploración de los datos permite comprender cuál es el contenido de los datos y las relaciones que existen entre características, determinar qué datos son solamente ruido o cuáles van a causar problemas al aplicar las técnicas de aprendizaje automático. Según el tipo de variable, se pueden obtener una serie de parámetros de interés.

De las variables numéricas o cuantitativas se pueden:

- Obtener parámetros estadísticos, como la media, la mediana, los cuartiles o la desviación típica. Esto permite comprender la escala y el rango de las variables.
- Buscar errores y valores atípicos, mediante métodos estadísticos o de visualización como los diagramas de cajas (*box-plot*).
- Comprender la distribución estadística de la característica. Para ello, se pueden emplear histogramas o el *Kernel Density Estimate plot* (KDE).
- Buscar relaciones entre características para evitar usar datos redundantes. En este caso, se pueden emplear diagramas de dispersión o el coeficiente de correlación.

Sin embargo, de las variables categóricas o cualitativas, es posible:

- Obtener las frecuencias de las diferentes categorías de las variables. Su representación se puede realizar en forma de diagrama de barras.
- Buscar la relación entre diferentes características cualitativas empleando tablas de contingencia o test Chi-cuadrado (χ^2).

A continuación, se detallan algunas de las técnicas empleadas en la exploración del conjunto de datos.

4.1.1. Kernel Density Estimate

El *Kernel Density Estimate* (KDE) es un método no paramétrico que permite estimar la función de densidad de probabilidad (FDP) de una variable aleatoria continua [34]. No se trata de un método paramétrico porque no asume ninguna distribución subyacente para la variable.

Para comprender en que consiste el KDE, es necesario definir el *kernel*. Un *kernel* es un tipo especial de función de densidad de probabilidad (FDP) en el que los valores deben ser positivos, reales y la integral definida sobre la función debe ser igual a 1.

Los *kernels* más empleados son FDPs de distribuciones con simetría par, como la distribución uniforme (-1,1) y la distribución normal.

Para cada muestra de la variable, se crea una función del *kernel* con la muestra en su centro; esto asegura que el *kernel* sea simétrico con respecto al dato. Luego, la FDP se estima agregando todas estas funciones del *kernel* y dividiendo por la cantidad de muestras para garantizar que satisfaga las 2 propiedades de un función de densidad de probabilidad:

- Cada valor posible de la FDP es positivo.
- La integral definida de la FDP debe ser igual a 1.

En la Figura 6, se puede observar la construcción de un KDE (línea continua) con un *kernel* simétrico (línea de puntos) para 4 muestras en $x = 0.5$, $x = 0.7$, $x = 1$ y $x = 2.5$.




Figura 6. Construcción de un KDE con *kernel* simétrico [34].

La estimación de la FDP se puede ver como una suma de "relieves". Se asigna un relieve a cada muestra, en el que el tamaño del relieve representa la probabilidad asignada a los valores vecinos de ese dato. Por ejemplo, si el conjunto de datos contiene dos datos en $x = 1,5$ un dato en $x = 0,5$; entonces, la protuberancia en $x = 1,5$ es dos veces más grande que la protuberancia en $x = 0,5$.

Cada *kernel* tiene un ancho de banda, lo que determina el ancho del relieve o, lo que es lo mismo, el ancho de los valores vecinos a los que se asigna la probabilidad. Un ancho de banda más grande da como resultado una protuberancia más corta y amplia que se extiende más lejos del centro y asigna más probabilidad a los valores vecinos.

Los pasos para obtener el KDE son:

- 1) Elegir un *kernel*. Los más comunes en la estimación del KDE son normales (Gaussianos), uniformes (rectangulares) y triangulares.
- 2) Para cada muestra x_i se construye la función de *kernel* escalada (1).

$$\frac{1}{h} \cdot K \left[\frac{x - x_i}{h} \right] \quad (1)$$

donde $K()$ es la función *kernel* elegida y el parámetro h es el ancho de banda, ancho de ventana o el parámetro de suavizado, previamente definido.

- 3) Se suman todas las funciones de *kernel* escaladas individuales y se divide por el número de muestras n , obteniendo la KDE (2). Esto otorga una probabilidad de $1/n$ a cada muestra x_i , lo que asegura que la integral del KDE final sea 1.

$$\hat{f}(x) = \frac{1}{h \cdot n} \cdot \sum_{i=1}^n K \left[\frac{x - x_i}{h} \right] \quad (2)$$

4.1.2. Coeficiente de correlación

La correlación es una medida que implica una asociación monótona entre dos variables. Una relación monótona entre dos variables es aquella en la que a medida que aumenta el valor de una variable, también lo hace el valor de la otra variable; o a medida que aumenta el valor de una variable, el valor de la otra variable disminuye [35], [36]. Por lo tanto, valores más altos de una variable tienden a asociarse con valores más altos (correlación positiva) o más bajos (correlación negativa) de la otra variable, y viceversa.

La relación lineal entre dos variables es un caso especial de relación monótona. El término correlación se utiliza, normalmente, en el contexto de una relación lineal entre dos variables aleatorias continuas, conocida como correlación de Pearson.

Existen varios tipos de coeficientes de correlación, los más empleados son el coeficiente de correlación de momento del producto de *Pearson* y el coeficiente de correlación de rango de *Spearman*. El uso correcto del tipo de coeficiente de correlación depende de los tipos de variables que se estudian:

- **Coeficiente de correlación de Pearson [36].** Normalmente, se denota como ρ para un parámetro de población y como r para estadística. Se utiliza cuando ambas variables en estudio tienen una distribución normal. Este coeficiente se ve afectado por valores extremos, que pueden exagerar o atenuar la fuerza de la relación y, por lo tanto, es inapropiado cuando una o ambas variables no se distribuyen normalmente. Para averiguar si existe correlación entre las variables x e y , la fórmula para calcular el coeficiente de correlación de *Pearson* muestral viene dada por la fórmula (3).

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{[\sum_{i=1}^n (x_i - \bar{x})^2] \cdot [\sum_{i=1}^n (y_i - \bar{y})^2]}} \quad (3)$$

donde x_i e y_i son los valores de x e y para el individuo i -ésimo y n son el total de pares de muestras o individuos.

- **Coeficiente de correlación de Spearman [36].** Se denota como ρ_s para un parámetro de población y como r_s para estadística. Su cálculo es apropiado cuando una o ambas variables son asimétricas y cuando existen valores extremos. Para el cálculo del coeficiente de *Spearman*, las muestras son ordenadas y reemplazadas por su respectivo orden. Para averiguar si existe correlación entre las variables x e y , la fórmula para calcular el coeficiente de correlación de *Spearman* viene dada por (4).

$$r_s = 1 - \frac{6 \cdot \sum_{i=1}^n d_i^2}{n \cdot (n^2 - 1)} \quad (4)$$

donde d_i es la diferencia de orden entre las muestras x e y del individuo i -ésimo y n es el total de individuos.

Un coeficiente de valor inferior a 0,1 o superior a $-0,1$ indica una relación insignificante. Sin embargo, una correlación superior a 0,9 o inferior a $-0,9$ es considerada una relación muy fuerte entre las variables. Los valores intermedios son discutibles, un coeficiente de correlación de 0,65 podría interpretarse como una correlación moderada, mientras que 0,40 describe una asociación baja.

4.1.3. Test Chi-cuadrado

La prueba Chi-cuadrado de independencia (χ^2), también conocida como prueba Chi-cuadrado de Pearson, o simplemente Chi-cuadrado, es una de las estadísticas más útiles para probar la existencia o no de independencia entre dos variables categóricas [37]. Para evaluar la independencia entre las variables, se calculan los valores que indicarían la independencia absoluta, lo que se denomina frecuencias esperadas, comparándolos con las frecuencias de la muestra según la fórmula (5).

$$\chi^2 = \sum_{i=1}^k \left[\frac{(O_i - E_i)^2}{E_i} \right] \quad (5)$$

donde O_i es el valor observado y E_i el valor esperado.

Como es habitual, la hipótesis nula (H_0) indica que ambas variables son independientes, mientras que la hipótesis alternativa (H_1) indica que las variables tienen algún grado de asociación o relación. Como ocurre con cualquier estadística, existen una serie de requisitos:

- 1) Los datos de las celdas deben ser frecuencias o recuentos de casos en lugar de porcentajes o alguna otra transformación de los datos.
- 2) Los niveles o categorías de las variables son mutuamente excluyentes, no puede haber pertenencia a varios niveles simultáneamente.
- 3) Cada sujeto solamente puede ser usado una vez, por lo que si se evalúan los mismos sujetos a lo largo del tiempo, no se puede utilizar la prueba χ^2 .
- 4) Los grupos de estudio deben ser independientes.
- 5) Se emplean solamente dos variables y ambas se miden como categorías. También se pueden usar intervalos de una variable cuantitativa que se han contraído en categorías ordinales.
- 6) Todos los valores esperados de la tabla de contingencia deben ser mayores de 5.

El estadístico chi-cuadrado tomará un valor igual a 0 si existe coincidencia perfecta entre las frecuencias observadas y las esperadas; sin embargo, el estadístico tomará un valor elevado si existe una gran discrepancia entre estas frecuencias, y consecuentemente se deberá rechazar la hipótesis nula.

4.2. PREPROCESADO DE LOS DATOS

Con el objetivo de preparar los datos para su posterior procesamiento utilizando las técnicas de aprendizaje automático se deberá realizar un preprocesamiento y limpieza. Esto es debido a que los datos pueden contener registros ruidosos, es decir, incompletos, dañados o haber sido introducidos de forma incorrecta en la base de datos. Los defectos más comunes son:

- **Valores duplicados.** Es necesario detectar estos registros duplicados y eliminar todos aquellos que se repitan más de una vez para evitar cualquier tipo de sesgo en el aprendizaje automático.
- **Datos anómalos (*Outliers*).** Debido a errores de almacenamiento, de medición o de inserción de los datos, pueden aparecer *outliers* o datos anómalos en el conjunto de datos. Estos valores pueden distorsionar la distribución de los datos haciendo que el proceso de aprendizaje automático se vea afectado. Se puede considerar que un valor es atípico cuando su distancia desde el valor medio es tres veces mayor que desviación estándar.
- **Ausencia de valores.** Algunos valores del conjunto de datos pueden estar vacíos, ya sea por ausencia de medición o por un error al almacenar la información. Para solventar este problema se pueden aplicar varias soluciones [38]:
 - **K-vecinos más próximos:** Consiste en imputar el valor ausente teniendo en cuenta los registros próximos empleando el algoritmo *k-Nearest Neighbors* (KNN).
 - **Rellenar con un valor fijo** usando un parámetro estadístico de la característica como la media, la mediana, la moda o un valor predefinido.
 - **Rellenar un modelo predictivo.** Existen técnicas que permiten predecir el valor perdido utilizando un modelo que emplea el resto de las variables del conjunto de datos. El método más típico es la regresión
 - **Eliminar el registro completo.** En el caso de que las técnicas anteriores no sean adecuadas para rellenar los valores vacíos, se puede optar por descartar ese registro.
 - **Considerar el vacío como una categoría.** Si la variable donde faltan datos es categórica, se puede añadir una categoría extra para todos los valores vacíos de dicha variable.
- **Inconsistencia de datos.** En ocasiones se detectan errores en el formato o en el tipo de los datos, es decir, el tipo de dato no coincide con la medida que se está recogiendo. Puede ser debido a un error de lectura de los datos o a un mal almacenamiento de estos.

Además de la eliminación de defectos en el conjunto de datos, también es necesario realizar una preparación de los datos antes de introducirlos en los algoritmos de aprendizaje automático:

- **Extracción/selección de características.** Conocer las características principales es crucial para conseguir una buena solución al problema planteado.
 - La **selección de características** se basa en elegir las mejores características del conjunto de datos, las más significativas o relevantes y eliminar el resto.
 - La **extracción de características** consiste en crear nuevas características utilizando una combinación de las características originales. Por tanto, se transforma el espacio de datos original combinando las características originales para crear un nuevo espacio de datos. La técnica más ampliamente empleada para la extracción de características es el análisis de componentes principales (PCA). Estas técnicas no se explorarán en el presente trabajo, debido a que se busca conservar las características originales para una correcta interpretación clínica de los resultados [39].

- **Codificación de variables categóricas.** La mayor parte de los modelos de aprendizaje automático y técnicas de agrupamiento requieren que todas las variables de entrada y salida sean numéricas. Por tanto, es necesario codificar las variables cualitativas en números antes de poder ajustar y evaluar un modelo. Las dos aproximaciones más empleadas son:
 - **Codificación ordinal.** También se denomina codificación de números enteros y es fácilmente reversible. A cada valor de categoría único se le asigna un número entero, normalmente comenzando en cero.

Es útil para variables categóricas ordinales, ya que los algoritmos aprovechan la relación ordenada existente entre los números.
 - **Codificación *One-Hot*.** Se emplean las denominadas variables ficticias que codifican características categóricas como un conjunto de variables binarias. Hay una variable ficticia para cada categoría posible. Los valores de las variables ficticias se establecen en cero; solamente la variable ficticia correspondiente al valor de la categoría toma el valor uno.
- **Normalización/estandarización.** La normalización es una técnica que a menudo se aplica como parte de la preparación de los datos para el aprendizaje automático. El objetivo de la normalización es cambiar los valores de las columnas cuantitativas en el conjunto de datos para usar una escala común, sin distorsionar las diferencias en los rangos de valores ni perder información. Esta técnica es necesaria para que algunos algoritmos de aprendizaje automático modelen los datos correctamente.

A continuación, se profundiza en las técnicas de preprocesado de datos empleadas en el presente estudio.

4.2.1. Imputación de valores con el algoritmo *k-Nearest Neighbors*

Dado un patrón incompleto, el algoritmo *k-Nearest Neighbors* (KNN) selecciona los K casos más cercanos del conjunto de datos con valores conocidos en las características a ser imputadas, de tal forma que se minimice una métrica de distancia. Por tanto, el algoritmo KNN, en lugar de utilizar todas las instancias disponibles en los datos, utiliza sólo los casos más cercanos al registro con la característica vacía, mejorando las técnicas más sencillas que emplean la media, mediana o moda [40].

El valor óptimo de K generalmente se elige mediante validación cruzada. Una vez que se han encontrado los K vecinos más cercanos, se debe estimar un valor de reemplazo para el atributo vacío. La forma en que se calcula el valor de reemplazo depende del tipo de datos. La moda se suele emplear para las variables categóricas o cualitativas, mientras que la media se utiliza para variables cuantitativas continuas [41].

Dado un registro incompleto, con una característica vacía, este método selecciona los K casos más cercanos que no tienen valores perdidos en las características a imputar, de modo que minimizan alguna medida de distancia [38].

Una de las métricas más empleadas es la distancia heterogénea (*Heterogeneous Euclidean-Overlap Metric*, HEOM) [42], que permite manejar datos incompletos tanto en características cuantitativas

como categóricas. En los conjuntos de datos de estudio existen datos incompletos y variables cualitativas y cuantitativas por lo que la distancia HEOM es adecuada. La distancia HEOM entre dos registros x e y viene dada por (6).

$$d_H(x, y) = \sqrt{\sum_{j=1}^n d_j(x_j, y_j)^2} \quad (6)$$

siendo $d_j(x_j, y_j)$, la distancia entre x e y evaluada en la j -ésima característica de entrada (7).

$$d_j(x_j, y_j) = \begin{cases} 1, & \text{si } x_j \text{ o } y_j \text{ son desconocidos} \\ d_o(x_j, y_j), & \text{si } x_j \text{ e } y_j \text{ son categóricas} \\ d_N(x_j, y_j), & \text{si } x_j \text{ e } y_j \text{ son cuantitativas} \end{cases} \quad (7)$$

La distancia *overlap* (d_o) asigna un valor de distancia igual a 0 si las características categóricas x_j e y_j son iguales. En caso contrario si asigna una distancia igual a 1. La distancia normalizada d_N viene dada por (8).

$$d_N(x_j, y_j) = \frac{|x_j - y_j|}{\max(j) - \min(j)} \quad (8)$$

donde $\max(j)$ y $\min(j)$ son respectivamente los valores máximo y mínimo observados en el conjunto de entrenamiento para la característica numérica j .

4.2.2. Selección de características

La reducción de dimensionalidad es un preprocesamiento necesario en el análisis, visualización y modelado de datos con gran número de características. Una de las formas más sencillas de reducir la dimensionalidad es mediante la selección de características, donde se seleccionan solo aquellas dimensiones de entrada que contienen la información relevante para resolver el problema particular.

A diferencia del aprendizaje supervisado, que tiene etiquetas de clase para guiar la búsqueda de características relevantes, en el aprendizaje no supervisado es necesario definir qué significa relevante. Por lo general, se representan en forma de funciones de criterio.

Ladha et al. en [43] proponen las siguientes ventajas de la selección de características:

- Reduce la dimensionalidad del espacio de características para limitar los requisitos de almacenamiento y aumentar la velocidad del algoritmo.
- Elimina los datos redundantes, irrelevantes o ruidosos mejorando la calidad de los datos.
- Acelera el tiempo de ejecución de los algoritmos de aprendizaje, incrementando la precisión del modelo resultante.
- Posibilidad de ahorrar recursos en la siguiente recopilación de datos.
- Mayor comprensión de datos y sobre el proceso que los ha generado.

Los algoritmos de selección de características pueden clasificarse en dos grandes grupos, técnicas de filtro y técnicas de envoltorio o *Wrapper* [39]. El enfoque usando filtros básicamente preselecciona las características y, luego, aplica el algoritmo de agrupamiento al subconjunto de características seleccionado. Por otro lado, las técnicas de envoltorio incorporan el algoritmo de agrupamiento en la búsqueda y selección de características.

La selección de funciones basada en filtros proporciona una variedad de métricas para estimar el valor de la información de cada característica. Entre estas métricas destacan:

- **Correlación de Pearson y de Spearman.** Se han detallado en la sección anterior. Un coeficiente de correlación mayor a 0.9 en valor absoluto indicará dependencia lineal muy fuerte entre dos características, por lo que se puede eliminar una de ellas sin pérdida de información relevante.
- **Información mutua.** La puntuación de información mutua mide la contribución de una variable a reducir la incertidumbre (entropía) sobre el valor de otra variable. Por tanto, si dos variables son independientes la información mutua será 0.
- **Chi-cuadrado.** Se ha detallado con anterioridad.

La Figura 7 ilustra el enfoque de envoltorio. La entrada es el conjunto de todas las características y el resultado son las características seleccionadas y los grupos que se encuentran en el subespacio de características.




Figura 7. Técnica de Envoltorio (*Wrapper*) para aprendizaje no supervisado [39].

La idea es buscar en el espacio de características cada subconjunto candidato, agrupando los datos con un algoritmo de *clustering* y posteriormente evaluar los grupos resultantes y el subconjunto de características empleando el criterio de selección de características elegido. Se repetirá este proceso hasta que se encuentre el mejor subconjunto de características con sus grupos correspondientes en función del criterio de evaluación.

El objetivo final es encontrar el subconjunto de características que mejor descubra agrupaciones interesantes a partir de datos.

El enfoque de envoltorio [39], divide la tarea en tres componentes:

- **Búsqueda de características.** Se suelen utilizar técnicas de búsqueda voraz o *greedy*, basadas en elegir la opción óptima en cada paso local con la esperanza de llegar a una solución general óptima:
 - La búsqueda secuencial hacia adelante (SFS) comienza con cero características y agrega secuencialmente una característica en cada iteración. La característica agregada es la que proporciona el mayor valor de criterio cuando se usa en combinación con las características elegidas.

- La búsqueda se detiene cuando agregar más características no mejora el criterio de característica elegido.
- La SFS es un método popular porque es simple, rápido y proporciona una solución razonable. Para los propósitos de este proyecto, el empleo de SFS es suficiente.
- **Algoritmo de agrupamiento.** Se detallarán más adelante los posibles algoritmos de agrupamiento.
- **Criterio de evaluación.** Existen dos enfoques generales sobre la elección del criterio de evaluación. El primero implica que los criterios de selección de subconjuntos de características deben ser los criterios utilizados para la agrupación, mientras que el segundo especifica que los dos criterios no tienen por qué ser iguales.

Para seleccionar un subconjunto de características óptimo, se necesita una medida para evaluar la calidad del agrupamiento realizado. Es importante tener en cuenta en los estudios de agrupamiento que, diferentes clasificaciones, pueden ser adecuadas para diferentes propósitos. Es por esto por lo que no se puede decir que una clasificación sea la mejor de todas [44]. Las técnicas empleadas en la evaluación de los clústeres se detallarán en la siguiente sección.

4.2.3. Normalización

Como se ha definido anteriormente, la normalización busca cambiar los valores de las columnas numéricas en el conjunto de datos para usar una escala común, sin distorsionar las diferencias en los rangos de valores y sin perder información [45]. Los dos métodos de transformación más comunes son:

- **Estandarización Z-score.** Convierte todos los valores en valores normalizados según la media y la desviación típica de la característica. Los valores de las columnas se transforman mediante (9).

$$z = \frac{x - \text{media}(x)}{\text{desv. tip.}(x)} \quad (9)$$

x es el vector columna que contiene todos los registros de una característica. La media y la desviación estándar se calculan para cada columna por separado.

- **Normalización mínimo y máximo (*min-max*).** La normalización *min-max* re-escala linealmente cada característica al intervalo [0,1]. El cambio de escala al intervalo [0,1] se realiza modificando los valores de cada característica de modo que el valor mínimo sea 0, y luego dividiendo por el nuevo valor máximo (la diferencia entre los valores máximo y mínimo originales). Los valores de la columna se transforman empleando (10).

$$z = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (10)$$

4.3. TÉCNICAS DE APRENDIZAJE NO SUPERVISADO

El aprendizaje no supervisado se basa en descubrir propiedades útiles de los datos disponibles. La tarea más popular es buscar grupos, llamados clústeres, de registros similares. Es necesario tener en cuenta que el algoritmo de agrupamiento debe encontrar grupos o clústeres que tengan dos características principales:

- **Los grupos deben ser compactos.** Los clústeres individuales deben ser pequeños, lo que quiere decir que los registros dentro de un clúster deben estar cerca unos de otros, empleando alguna métrica.
- **Los grupos deben estar bien separados los unos de los otros.** Si existen muchos grupos, deben estar separados de alguna forma y no mostrar una gran superposición.

Una vez se obtienen los grupos, es necesario poder evaluar de alguna forma el desempeño del algoritmo. No es tan trivial como contar el número de errores o la precisión y exactitud como ocurre en un algoritmo de clasificación supervisado. Para medir el desempeño de las técnicas de aprendizaje no supervisado es necesario demostrar que los miembros que pertenecen a la misma clase son más similares que los miembros de diferentes clases de acuerdo con alguna métrica de similitud, normalmente expresada mediante índices. Estos índices se pueden emplear también como criterio de selección de características en las técnicas *Wrapper* definidas en la sección anterior.

En la Tabla 7 se muestra un resumen con las técnicas de agrupamiento más empleadas. Posteriormente, se van a definir con mayor detalle en esta sección.

Tabla 7. Algoritmos de agrupamiento

Método	Parámetros	Utilización	Geometría (métrica empleada)
<i>K-Means</i>	Número de clústeres	No demasiados clústeres. Uso general. Tamaño de clúster uniforme. Geometría plana.	Distancias entre puntos.
<i>Hierarchical Clustering</i>	Número de clústeres o umbral de distancia	Muchos clústeres. Posibles limitaciones de conectividad.	Distancias entre puntos.
<i>Spectral Clustering</i>	Número de clústeres	Pocos clústeres. Tamaño de grupo uniforme. Geometría no plana.	Distancia gráfica (por ejemplo, gráfico de vecinos más cercanos).
<i>Affinity propagation</i>	Preferencia y factor de amortiguamiento	Muchos clústeres. Tamaño de grupo desigual. Geometría no plana.	Distancia gráfica (por ejemplo, gráfico de vecinos más cercanos).
<i>Mean-shift</i>	Ancho de banda	Muchos clústeres. Tamaño de grupo desigual. Geometría no plana.	Distancias entre puntos.

4.3.1. Conceptos previos

La mayoría de los algoritmos de agrupamiento se basan en técnicas que emplean métricas sobre el conjunto de datos. A continuación se detallan algunas de las métricas más comunes [42] y conceptos necesarios para entender las técnicas posteriormente descritas.

- **Distancia euclídea.** Es útil cuando las distribuciones de los datos son Gaussianas. El cálculo de esta métrica entre dos registros x e y se realiza en (11).

$$d_E(x, y) = \sqrt{\sum_{i=0}^N (x_i - y_i)^2} \quad (11)$$

- **Distancia Manhattan.** Es útil cuando los datos siguen distribuciones no gaussianas. El cálculo de esta métrica entre dos registros x e y se realiza en (12).

$$d_M(x, y) = \sum_{i=0}^N |x_i - y_i| \quad (12)$$

- **Distancia Mahalanobis.** Trata de modelar la forma del clúster empleando la matriz de covarianza. El cálculo de esta métrica entre dos registros x e y se realiza en (13).

$$d_{MH}(x, y) = \sqrt{(x - y)^T \cdot S^{-1}(x - y)} \quad (13)$$

donde S es la matriz de covarianza de x e y .

- **Distancia Hamming.** Se emplea para el cálculo de la distancia entre dos cadenas de caracteres con la misma longitud. Mide el número mínimo de sustituciones necesarias para cambiar una cadena por otra, o la cantidad mínima de errores que podría haber para transformar una cadena en otra.

Unas métricas que se suelen emplear para establecer la calidad del agrupamiento son la distancia inter-clústeres y la distancia intra-clúster [46].

La distancia entre dos clústeres C_i y C_j , inter-clústeres, puede ser calculada de diferentes formas:

- **Distancia de enlace único.** Es la distancia mínima entre dos registros que pertenecen a C_i y C_j respectivamente.
- **Distancia de vinculación completa.** Es la distancia máxima entre dos registros que pertenecen a C_i y C_j respectivamente.
- **Distancia media de unión.** Es la distancia media entre todos los registros pertenecientes a C_i y C_j respectivamente.
- **Distancia entre centroides.** Es la distancia entre el centroide de los dos clústeres C_i y C_j respectivamente.
- **Ward.** *Ward* establece en [47] la distancia entre dos clústeres C_i y C_j como el aumento de la suma de cuadrados cuando se unen dichos clústeres. Es un enfoque que minimiza la varianza.

La distancia intra-clúster de un clúster C_i puede ser calculada:

- **Diámetro completo.** Es la distancia entre los dos registros más alejados que pertenecen al clúster C_i .
- **Diámetro promedio.** Es la distancia promedio entre todos los registros que pertenecen al clúster C_i .
- **Distancia del centroide al diámetro.** Se calcula como el doble de la distancia promedio entre todos los registros y el centroide del clúster C_i .

4.3.2. Agrupamiento mediante *k-means*

El algoritmo de agrupación *k-means* es un método clásico de aprendizaje no supervisado que agrupa los datos tratando de separar las muestras en k clústeres de igual varianza, minimizando un criterio conocido como inercia o suma de cuadrados dentro del clúster (14).

$$\sum_{i=0}^n \min_{\mu_j \in C} (\|x_i - \mu_j\|^2) \quad (14)$$

El algoritmo *k-means* [28] divide un conjunto de n muestras, denominado x , en k clústeres (C) separados. Cada clúster está descrito por su media μ_j , también denominada centroide del clúster. μ_j se calcula como la media de las muestras del clúster.

Es necesaria la especificación el número de clústeres k , que suele hacerse gracias al conocimiento previo sobre la naturaleza de los datos o por el uso de métricas de evaluación del desempeño.

El algoritmo se puede resumir en una serie de pasos:

- 1) Se eligen los k centroides iniciales. Normalmente se emplean k muestras del conjunto de datos.
- 2) Se calcula la distancia entre cada muestra y los centros de los clústeres.
- 3) Se asigna cada punto al clúster cuya distancia al centro sea el mínima, teniendo en cuenta las distancias a todos los centros de los k clústeres.
- 4) Se vuelven a calcular las posiciones de los k centros como la media de las muestras del clúster.
- 5) Se vuelve a calcular la distancia entre cada registro y los centros recién calculados. Se repiten los pasos 3 y 4 hasta que la posición de los centroides no varía significativamente.

Una variante de este algoritmo es el *k-means-mode*, que puede manejar datos tanto cuantitativos como cualitativos [28]. En este caso, cada centro de clúster es un conjunto de medias y modas para atributos continuos y categóricos, respectivamente.

Los pasos del algoritmo son similares a los del algoritmo *k-means* clásico. Las medias y las modas se calculan para cada grupo como se indicó anteriormente y, luego, cada punto se mueve al grupo con una distancia mínima.

Para variables numéricas, se suele emplear la distancia euclídea y para variables categóricas se suele emplear la distancia de *Hamming*.

4.3.3. Agrupamiento mediante *Hierarchical Clustering*

El agrupamiento jerárquico, también llamado análisis de clústeres jerárquicos o HCA, es un método de análisis de grupos que busca construir una jerarquía de clústeres. Esta jerarquía de grupos se representa en un árbol o dendrograma (Figura 8). Las estrategias para la agrupación jerárquica generalmente se dividen en dos tipos [48]:

- **Divisiva.** En este caso, todas las observaciones comienzan en un grupo y las divisiones se realizan de forma recursiva a medida que se desciende en la jerarquía.
- **Aglomerativa.** Se trata de un enfoque de “abajo hacia arriba” en el que, inicialmente, existen tantos clústeres como registros y en cada iteración se reduce el número de clústeres. Se agrupan en el mismo clúster los registros similares, a medida que se asciende en la jerarquía. Es la estrategia mayormente empleada, por lo que, en esta sección, se tratará el paradigma aglomerativo.




Figura 8. Ejemplo de dendrograma, donde una posible solución al problema son 7 clústeres.

Para decidir qué clústeres deben combinarse, se requiere una medida de disimilitud entre conjuntos de observaciones. Esto se logra mediante el uso de una métrica apropiada, que estima la distancia entre pares de observaciones; y un criterio de vinculación, que especifica la disimilitud de conjuntos en función de las distancias entre pares de observaciones en los conjuntos.

- **Métrica.** La elección de una métrica adecuada influye en la forma de los clústeres, ya que, los elementos pueden estar relativamente más cerca entre sí usando una métrica que empleando otra. Las métricas más empleadas son las distancias euclídea, *Manhattan*, *Mahalanobis* o *Hamming*.
- **Criterio de vinculación.** El criterio de vinculación determina la distancia entre conjuntos de observaciones, en función de las distancias por entre pares de observaciones. Se usan las distancias inter-clústeres como medidas.

El algoritmo de agrupamiento jerárquico aglomerativo [48] se puede sintetizar en las siguientes etapas:

- 1) Se asigna cada registro a un clúster independiente.
- 2) Se calcula la distancia entre cada par de clústeres. Posteriormente se construye una matriz cuyos elementos sean los valores de distancia calculados.
- 3) Se encuentra el par de clústeres con la distancia más corta y se fusionan ambos grupos.

- 4) Se calculan todas las distancias desde este nuevo clúster a todos los demás grupos y se actualiza la matriz de distancias.
- 5) Se repiten estos pasos hasta que la matriz se reduce a un solo elemento, un solo clúster.

4.3.4. Agrupamiento mediante *Spectral Clustering*

El agrupamiento espectral se basa en utilizar los valores propios (espectro) de la matriz de similitud para realizar una reducción de dimensionalidad antes de agrupar los datos [49]. Esta reducción es útil para una mejor interpretación y un mejor rendimiento del algoritmo. Es una técnica que suele emplearse para clústeres que no son compactos o con límites convexos, donde la mayoría de los algoritmos de agrupamiento clásicos fallan. Es necesario establecer el número de clústeres deseados.

En un conjunto de datos, la matriz de similitud puede definirse como una matriz simétrica A , donde $A_{ij} \geq 0$ representa una medida de la similitud entre los registros i y j . El enfoque general para la agrupación espectral es utilizar un método de agrupación, por ejemplo *k-means*, sobre los vectores propios o autovectores relevantes de la matriz Laplaciana de A . De esta forma, se crea un espacio de datos transformado en el que es más fácil resolver el problema.

Dado un conjunto de datos $\{x_1, \dots, x_n\}$ que se quiere agrupar en k clústeres, el algoritmo tradicional se puede sintetizar en los siguientes pasos [49]:

- 1) Se forma la matriz de similitud A_{ij} con una medida de similitud entre los registros (15).

$$A_{ij} = e^{-\frac{\|x_i - x_j\|^2}{2\sigma^2}}, \quad \text{si } i \neq j \quad (15)$$

$$A_{ii} = 0$$

- 2) Se define la matriz diagonal D cuyo elemento de la diagonal (i,i) es la suma de la fila i -ésima de la matriz A . Se construye la matriz Laplaciana L con (16).

$$L = D^{-\frac{1}{2}} \cdot A \cdot D^{-\frac{1}{2}} \quad (16)$$

- 3) Se buscan los k autovectores $\{s_1, \dots, s_k\}$ de la matriz L , que serán ortogonales en el caso de autovalores repetidos. De esta forma, se crea la matriz $S = \{s_1, \dots, s_k\}$ agrupando los autovectores en un vector columna.
- 4) A partir de la matriz de autovectores S , se crea la matriz Y normalizando cada fila de S para que tenga longitud unitaria (17).

$$Y_{ij} = \frac{S_{ij}}{\sqrt{\sum_j S_{ij}^2}} \quad (17)$$

- 5) Si cada fila de Y es un punto en el nuevo espacio de características, se aplica el algoritmo de agrupamiento deseado para agruparlos en k clústeres.
- 6) Finalmente se asigna el punto original x_i al clúster j si la fila i -ésima de la matriz Y ha sido asignada al clúster j .

4.3.5. Agrupamiento mediante *affinity propagation*

La propagación por afinidad o *affinity propagation* (AP) es un algoritmo de agrupación basado en el concepto de "envío de mensajes" entre pares de registros. A diferencia de otros algoritmos de agrupamiento como *k-means*, el algoritmo AP no requiere que se determine o estime el número de clústeres antes de ejecutar el algoritmo. Se basa en encontrar ejemplares, miembros del conjunto de entrada que son representativos de los clústeres [50].

Sea $\{x_1, \dots, x_n\}$ un conjunto de registros, sin suposiciones sobre su estructura interna. Se define S como la matriz de similitud, que se obtiene mediante una función que cuantifica la semejanza entre dos registros cualesquiera, de modo que $s(i, j) > s(i, k)$ si x_i es más similar a x_j que a x_k . Un ejemplo de función para S es la distancia al cuadrado negativa entre dos registros (18).

$$s(i, k) = -\|x_i - x_k\|^2 \quad (18)$$

La diagonal de S , es decir $S(i, i)$, es importante, ya que representa la preferencia de la instancia, es decir, la probabilidad de que una instancia en particular se convierta en un ejemplo. Cuando la preferencia es la misma para todos los registros, controla cuántas clases produce el algoritmo. Un valor cercano a la similitud mínima produce menos clases, mientras que, un valor cercano o mayor a la similitud máxima produce muchas clases. Normalmente se inicializa con la similitud mediana de todos los pares de registros.

El algoritmo procede alternando entre dos pasos de "envío de mensajes", que actualizan dos matrices [50]:

- La matriz de "responsabilidad" R tiene valores $r(i, k)$ que cuantifican cómo de adecuado es x_k para servir como modelo para x_i , en relación con otros ejemplos candidatos para x_i .
- La matriz de "disponibilidad" A contiene valores $a(i, k)$ que representan cómo de apropiado sería para x_i elegir x_k como su ejemplo, teniendo en cuenta la preferencia de otros puntos por x_k como ejemplo.

Ambas matrices se inicializan a cero y se pueden ver como tablas de probabilidad logarítmica. El algoritmo realiza las siguientes actualizaciones de forma iterativa:

- En primer lugar, la responsabilidad de la muestra k para ser el ejemplar de la muestra i , viene dada por (19).

$$r(i, k) \leftarrow s(i, k) - \max[a(i, k') + s(i, k'), \forall k' \neq k] \quad (19)$$

- Posteriormente, se actualiza la matriz de disponibilidad. El cálculo de cómo de apropiado sería para la muestra i , elegir a k como ejemplo se realiza con (20).

$$a(i, k) \leftarrow \min \left[0, r(k, k) + \sum_{i' \notin \{i, j\}} \max(0, r(i, k')) \right], \forall i \neq k \quad (20)$$

$$a(k, k) \leftarrow \sum_{i' \neq k} \max(0, r(i, k')), i = k$$

Se realizan los cálculos en cada iteración del algoritmo hasta alcanzar la convergencia. Con el objetivo de evitar oscilaciones numéricas al actualizar los mensajes, el factor de amortiguación (λ) se introduce en el proceso de iteración (21).

$$\begin{aligned} r_{t+1}(i, k) &= \lambda \cdot r_t(i, k) + (1 - \lambda) \cdot r_{t+1}(i, k) \\ a_{t+1}(i, k) &= \lambda \cdot a_t(i, k) + (1 - \lambda) \cdot a_{t+1}(i, k) \end{aligned} \quad (21)$$

donde t indica la iteración actual y $t+1$ la siguiente.

Por tanto, los dos parámetros que maneja el algoritmo son la preferencia, que está relacionada con el número de clústeres finales; y el factor de amortiguación, que amortigua los mensajes de responsabilidad y disponibilidad para evitar oscilaciones numéricas al actualizar estos mensajes.

4.3.6. Agrupamiento mediante *mean-shift*

La agrupación en clústeres empleando el algoritmo *mean-shift* tiene como objetivo descubrir máximos en las funciones de distribución de los datos. Se trata de un algoritmo basado en centroides, cuyo funcionamiento consiste en actualizar los candidatos para centroides con la media de los puntos dentro de una región determinada [51]. Posteriormente, estos candidatos se filtran en una etapa de postprocesamiento para eliminar duplicados y formar el conjunto final de centroides.

La denominada función *kernel* $K(x_i - x)$ determina el peso de los puntos cercanos en estimación iterativa de las medias. Las funciones *kernel* más empleadas son el *kernel* uniforme (22) y el *kernel Gaussiano* (23).

$$k(x) = \begin{cases} 1, & \text{si } x \leq \lambda \\ 0, & \text{si } x > \lambda \end{cases} \quad (22)$$

$$k(x) = e^{-\frac{x^2}{2\sigma^2}} \quad (23)$$

Dado un centroide candidato x_i ; en la iteración t , el candidato se actualiza de acuerdo con la ecuación (24).

$$x_i^{t+1} = m(x_i^t) \quad (24)$$

donde m es el vector *mean-shift* que se calcula para cada centroide que apunta hacia la región donde hay un aumento en la densidad de puntos máximo. Es calculado utilizando la ecuación (25), actualizando eficientemente el centroide para ser la media de las muestras con su vecindario.

$$m(x_i) = \frac{\sum_{x_j \in N(x_i)} K(x_j - x_i) x_j}{\sum_{x_j \in N(x_i)} K(x_j - x_i)} \quad (25)$$

donde $N(x_i)$ es el vecindario de muestras dentro de una distancia dada alrededor de x_i .

El algoritmo establece automáticamente el número de clústeres, pero es necesario establecer un parámetro denominado ancho de banda, que dicta el tamaño de la región a buscar. De la forma en

que está definido esta técnica, se garantiza que converge, sin embargo, dejará de iterar cuando el cambio en los centroides sea pequeño.

4.3.7. Mapas autoorganizativos

Un mapa autoorganizativo (SOM), desarrollado por *Kohonen* en [52], es un tipo de red neuronal artificial (ANN) que se entrena mediante aprendizaje no supervisado para producir una representación discretizada, de baja dimensión, del espacio de datos de entrada. El SOM reduce las N dimensiones de entrada a una representación en 2 dimensiones, denominada mapa.

No es considerado un algoritmo de agrupamiento como tal, pero es sencillo obtener clústeres con su representación empleando esta técnica. Además, su utilización es bastante útil en casos clínicos debido a la facilidad de interpretación de los resultados. Las principales características de este algoritmo son:

- Es una representación de baja dimensión del espacio de datos original definido en una dimensión superior.
- Muestra relaciones topológicas en el espacio de datos original que se mantienen en el espacio transformado.
- La proyección del mapa sobre las características originales permite inferir relaciones entre ellas de manera sencilla.

La red neuronal propuesta para este algoritmo está formada por dos capas de neuronas. En primer lugar, la capa de entrada tiene N nodos o neuronas representando las N características del conjunto de datos [52]. En segundo lugar, la capa de salida o de *Kohonen* contiene una matriz de $M \times M$ neuronas, que son las encargadas de procesar los datos y formar el mapa [52]. La idea es que cada muestra puede ser representada por una neurona del mapa. Un esquema de la técnica SOM se puede observar en la Figura 9.

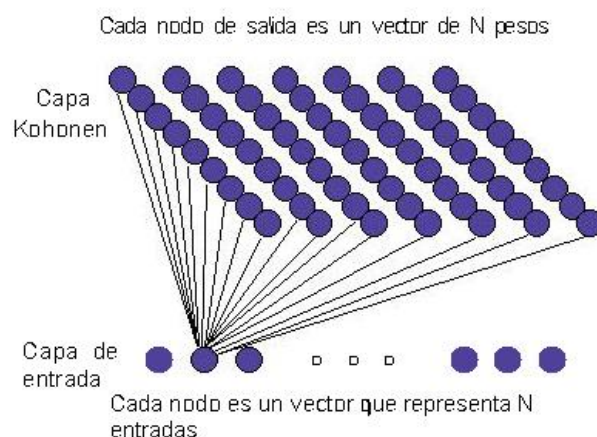


Figura 9. Topología del mapa autoorganizativo.

Cada neurona de la capa de entrada i está conectada con una neurona de la capa de salida j mediante un peso w_{ij} . Por tanto, cada neurona de la capa de salida tiene asociado un vector de pesos W_j llamado vector de referencia o *codebook*. Los vectores de pesos se inicializan con valores aleatorios al comienzo del algoritmo, que va actualizándolos por medio de la función de aprendizaje. El número de nodos de

la capa de salida determina la suavidad de la proyección, lo cual influye en el ajuste y capacidad de generalización del SOM [53].

Existen conexiones laterales de excitación o inhibición entre neuronas de la capa de salida, lo que conlleva que las neuronas tengan cierta influencia sobre las vecinas. Las neuronas adyacentes pertenecen a una vecindad N_j de la neurona j .

El entrenamiento de la red neuronal consta de las siguientes etapas [53]:

- 1) Se selecciona aleatoriamente un registro x del conjunto de datos y se calcula la distancia o similitud con los vectores de referencia W_j de las neuronas de la capa de salida. Para ello, se utiliza una métrica de las definidas en la sección anterior.
- 2) La neurona con menor distancia a la muestra, es decir, la más semejante, se la denomina *BMU* (*Best Matching Unit*). Los pesos de las neuronas de la capa de salida son ajustados empleando (26). La magnitud de los cambios se reduce con el tiempo y con la distancia a la *BMU*.

$$w_j(t+1) = w_j(t) + \gamma(w_j) \cdot \alpha(t) \cdot (x(t) - w_j(t)) \quad (26)$$

donde:

- $x(t)$ es la muestra de entrada.
 - $\alpha(t)$ es la tasa de aprendizaje. Por lo general, disminuye con el número de iteraciones, comienza valiendo 1 en la primera iteración y se va reduciendo. Un ejemplo es la reducción por un factor $1/\text{Número de iteración}$.
 - $\gamma(w_{ij})$ es la función de vecindario. Se emplea para establecer las neuronas vecinas que se actualizan y la forma de actualizarse. Lo más común es utilizar una función *Gaussiana* que decrece con la distancia a la *BMU*. Otras funciones como *Mexican Hat* incluyen penalización negativa, lo que permite una mejor separación entre neuronas vecinas. Se utiliza la misma forma de la función en todo el problema, en las primeras iteraciones se usan funciones más amplias y posteriormente, a medida que pasan las iteraciones, se hacen más estrechas para afectar cada vez a menos neuronas vecinas.
- 3) Se continúa con los pasos 1 y 2 hasta que se cumplen el total de iteraciones preestablecido λ .

4.3.8. Métricas de evaluación del desempeño

Evaluar el rendimiento de un algoritmo de agrupación en clústeres no es una tarea tan sencilla como puede ser el contar el número de errores o la precisión en un algoritmo de clasificación supervisado. Normalmente, no existe una única solución al número de clústeres necesarios para separar los datos, pero pueden usarse algunos índices que ayudan en su determinación.

Las métricas de evaluación del agrupamiento no deben tener en cuenta los valores absolutos de las etiquetas del clúster. Se debe evaluar si el agrupamiento satisface alguna suposición de que los miembros que pertenecen a la misma clase son más similares que los miembros de diferentes clases de acuerdo con alguna métrica de similitud.

Generalmente, las medidas de validez de clústeres [54] se clasifican en 3 clases:

- **Validación de clúster interno.** El resultado de la agrupación se evalúa en función de los datos agrupados en sí, la denominada información interna.
- **Validación de clústeres externos.** Los resultados de los clústeres se evalúan en función de algún resultado conocido externamente, como etiquetas de clase proporcionadas externamente o presentes en los datos.
- **Validación relativa del clúster.** Los resultados del clúster se evalúan variando diferentes parámetros para el mismo algoritmo, por ejemplo, cambiando el número de clústeres.

Los índices o métricas más empleados para evaluar los algoritmos de agrupamiento desde un esquema de evaluación interna, teniendo en cuenta los propios datos y los clústeres obtenidos son:

- **Índice de Dunn.** *J. C. Dunn* propuso en [55] una métrica (27) cuyo objetivo es identificar conjuntos de clústeres que son compactos, con una pequeña varianza entre los miembros del clúster y bien separados, donde las medias de los diferentes clústeres están lo suficientemente alejadas. Cuanto mayor sea el valor del índice de Dunn, mejor será la agrupación.

$$D_M = \min_{j=1,\dots,M} \left\{ \min_{j=1,\dots,M, j \neq i} \left(\frac{d(C_i, C_j)}{\max_{k=1,\dots,M} \text{diam}(C_k)} \right) \right\} \quad (27)$$

- donde:
 - M es el número de clústeres.
 - $d(C_i, C_j)$ es la distancia inter-clústeres entre C_i y C_j .
 - $\text{diam}(C_k)$ es la distancia intra-clúster del clúster C_k

Un inconveniente de esta métrica es que, a medida que aumentan el número de clústeres y la dimensionalidad de los datos, también aumenta el coste computacional. Funciona mejor con distancias grandes entre registros.

- **Índice Davies-Bouldin (DB).** *Davies* y *Bouldin* introdujeron en [56] una métrica que identifica la similitud promedio entre grupos, donde la similitud es una medida que compara la distancia entre grupos con el tamaño de los grupos en sí, utilizando (28). Cuanto menor sea el valor del índice DB, mejor es la agrupación.

$$DB_M = \frac{1}{M} \sum_{i=1}^M \max_{i \neq j} \left\{ \frac{\text{diam}(C_i) + \text{diam}(C_j)}{d(C_i, C_j)} \right\} \quad (28)$$

- donde:
 - M es el número de clústeres.
 - $d(C_i, C_j)$ es la distancia inter-clústeres entre C_i y C_j .
 - $\text{diam}(C_M)$ es la distancia intra-clúster del clúster C_M

El inconveniente del índice DB es que un buen valor obtenido por este método no implica que se obtenga la mayor información en los clústeres. Funciona mejor con distancias cortas entre registros.

- **Índice *Calinski-Harabasz*.** Fue propuesto por *Calinski y Harabasz* en [57]. También conocido como criterio de relación de varianza, ya que el índice es la relación de la suma de la dispersión inter-clústeres y la dispersión intra-clúster de todos los clústeres. La dispersión en este caso se define como la suma de distancias al cuadrado. Una puntuación de *Calinski-Harabasz* más alta implica un modelo con grupos mejor definidos.

La principal ventaja es que el índice es rápido de calcular aunque los valores que toma son generalmente más altos para los clústeres convexos que para otras morfologías diferentes.

Para un conjunto de datos de tamaño N que ha sido agrupado en M clústeres, la puntuación de *Calinski-Harabasz* se define como la relación entre la dispersión entre grupos y la dispersión dentro del grupo (29).

$$s = \frac{SS_B}{SS_W} \cdot \frac{N - M}{M - 1} \quad (29)$$

donde SS_W es la varianza general dentro del grupo (30), y SS_B es la varianza general entre grupos (31).

$$SS_W = \sum_{q=1}^M \sum_{x \in C_q} (x - c_q)(x - c_q)^T \quad (30)$$

$$SS_B = \sum_{q=1}^M n_q (c_q - c_N)(c_q - c_N)^T \quad (31)$$

donde C_q es el conjunto de registros del clúster q , c_q es el centro del clúster q , c_N es el centro del conjunto de datos N , y n_q el número de puntos del clúster q .

- **Coefficiente de Silueta (*Silhouette*).** El coeficiente de Silueta fue propuesto por *Rousseeuw* en [58] y relaciona la distancia de una muestra con los puntos de su clase y la distancia con puntos de la clase más cercana. Una mayor puntuación del coeficiente de silueta se relaciona con un modelo con clústeres mejor definidos.

La principal ventaja es que el índice se encuentre en el intervalo $[-1,1]$, siendo -1 para un agrupamiento incorrecto y $+1$ para clústeres bien separados y de alta densidad. Las puntuaciones en torno a 0 indican clústeres que se solapan. El inconveniente de esta métrica es que el índice es generalmente más alto para los clústeres convexos que los de otras morfologías diferentes.

El coeficiente de silueta se define para cada muestra y se compone de dos puntuaciones:

- a. Es la distancia promedio desde un punto a otros miembros de esa clase. Es una medida de la compactibilidad del clúster.

- **b.** Es la distancia promedio desde un punto hasta los miembros de la clase adyacente. Es una medida de separación entre grupos.

El coeficiente de silueta de una muestra viene dado por (32) y, el coeficiente de silueta global para un conjunto de muestras se obtiene como la media del coeficiente de silueta para cada muestra.

$$s = \frac{b - a}{\max(a, b)} \quad (32)$$

Los índices mencionados permiten comparar [54]:

- Distintos algoritmos de agrupamiento.
- Conjuntos de clústeres obtenidos con diferentes algoritmos o parámetros.
- Dos clústeres en sí para saber cuál es mejor en términos de compactibilidad y conectividad.

Además, permiten determinar si existe una estructura aleatoria en los datos debido a alguna fuente de ruido.

5. RESULTADOS Y DISCUSIÓN

5.1. EXPLORACIÓN DE LOS DATOS

En esta sección se van a mostrar los resultados obtenidos en la exploración de los datos y se discutirá su implicación en el resto de las fases del estudio.

5.1.1. Síndrome de Túnel Carpiano

En la Tabla 8 se muestran las características cuantitativas del conjunto de datos de pacientes aquejados de STC. De estas características, se muestra el valor medio, desviación estándar, valor máximo y mínimo, el número de pacientes que no presentan dato en dicha característica y el número de valores atípicos (*outliers*) detectados. Existen un total de 222 registros de pacientes diferentes.

Tabla 8. Parámetros obtenidos de las variables cuantitativas de pacientes con STC.

Característica	Media \pm std.	Max	Min	Nº pacientes sin dato	Nº de <i>outliers</i>
edad	45 \pm 8	64	21	0	0
yearswithpain	3 \pm 3	18,0	0,5	0	6
doloractual	4 \pm 2	10	0	0	0
dolorpeorsemana	6 \pm 2	10	0	0	0
CTSfunction	2 \pm 0	4,62	1,0	0	0
CTSseveridad	2 \pm 2	31,0	1,27	0	2
PPTmedianoaffected	193 \pm 55	431,0	58,3	0	1
PPTmedianounaffected	192 \pm 54	387,0	57,0	0	1
PPTcubitalaffected	290 \pm 77	478,0	93,0	0	0
PPTcubitalunaffected	296 \pm 78	564,0	114,0	0	1
PPTradialaffected	225 \pm 68	552,0	89,0	0	2
PPTradialunaffected	227 \pm 64	408,5	88,0	0	0
PPTcuelloaffected	170 \pm 51	307,0	63,0	0	0
PPTcuellounaffected	174 \pm 69	901,0	51,0	0	1
PPTcarpoaffected	352 \pm 101	677,0	127,0	0	1
PPTcaporunaffected	344 \pm 98	785,0	121,0	0	2
PPTpiernaaffected	328 \pm 86	705,0	101,0	0	1
PPTpiernaunaffected	320 \pm 88	600,0	102,0	0	1
UDCtunelafecto	39 \pm 2	48,9	34,37	3	0
UDCtunelunaffected	39 \pm 2	48,35	34,2	2	0
UDCpalmaafecta	40 \pm 3	48,65	33,1	3	0
UDCpalmaunaffected	39 \pm 3	50,0	25,6	3	0
UDFtunelafecto	21 \pm 12	99,0	5,0	0	4
UDFtunelunaffected	19 \pm 7	30,1	5,0	4	0
UDFpalmaafecta	19 \pm 6	30,33	5,0	4	0
UDFpalmaunaffected	19 \pm 6	29,57	5,0	4	0
Pinzaindexedrcha	4 \pm 2	10,0	0,0	1	0
Pinzazorazondrcha	3 \pm 2	12,0	0,0	1	0

DESARROLLO DE PERFILES DE PACIENTES AFECTADOS POR SÍNDROME DE TÚNEL CARPIANO Y CEFALEA TENSIONAL MEDIANTE EL USO DE TÉCNICAS DE APRENDIZAJE AUTOMÁTICO

Característica	Media \pm std.	Max	Min	Nº pacientes sin dato	Nº de outliers
Pinzaanulardrcha	2 \pm 1	7,0	0,0	1	0
Pinzameñiquedrcha	1 \pm 0	6,7	0,0	2	0
Pinzaindiceizqda	4 \pm 1	9,0	0,5	1	0
Pinzacorazonizqda	4 \pm 1	10,0	0,0	1	0
Pinzaanularizqda	2 \pm 1	7,7	0,0	1	0
Pinzameñiqueizqueda	1 \pm 0	4,3	0,0	1	0
Depresion	4 \pm 2	15,0	0,0	1	0

La Tabla 8 permite comparar el rango de valores de las diferentes características del conjunto de datos de pacientes con STC. Se puede observar que existen rangos de valores muy diferentes entre distintas características, por ejemplo, entre las presiones en los umbrales de dolor por presión y el rango de valores de depresión obtenidos con la prueba BDI-II. También, permite identificar algunos *outliers*, como el valor máximo del umbral de dolor al frío en el conjunto de datos, que es 99. Este valor no es correcto porque la temperatura en esta prueba es descendente y nunca puede llegar un valor tan elevado. Por lo tanto, este valor anómalo es detectado como un *outlier* que será procesado posteriormente.

La Figura 10 muestra los diagramas de cajas o *boxplot* de los umbrales de dolor por frío y calor, donde se puede observar que no hay diferencias significativas en la distribución de los datos entre el lado afectado por STC y el lado no afectado. Lo mismo ocurre en la Figura 11, donde se observan los *boxplot* de los umbrales de dolor por presión. No existen grandes diferencias entre los valores obtenidos en el lado afectado por STC y el lado sin afectar.




Figura 10. Diagrama de cajas de los Umbrales de Dolor por Calor (UDC) y Umbrales de Dolor por Frío (UDF).

En la Figura 11 se puede observar también que existen diferentes zonas de la mano más sensibles a la presión, como el caso de la zona del nervio mediano, donde los valores de presión para el umbral de dolor son más bajos que en la zona del nervio cubital o de la pierna. Esta representación también

permite detectar los *outliers* de forma gráfica (diamantes negros). Se puede observar un valor anómalo en el umbral de dolor por presión de cuello no afectado que también está presente en la Tabla 8.




Figura 11. Diagrama de cajas de los umbrales de dolor por presión (PPT).

Los *boxplots* de las distintas características cuantitativas agrupadas por “Grados” y “Lado” de afectación se detallan en la Figura 12. De estas gráficas se puede extraer información interesante, como que la presión necesaria para el umbral de dolor por presión en el nervio mediano y en la zona del túnel carpiano es menor en pacientes con grado de STC leve que con grado moderado o importante. También, puede observarse que no existen grandes diferencias entre los valores de presión obtenidos en el pinzamiento entre el dedo índice y pulgar de la mano derecha con STC en el lado izquierdo en comparación con el pinzamiento entre el dedo índice y pulgar de la mano izquierda.

La Figura 12 muestra que los valores de severidad de los síntomas y depresión son menores en STC de lado derecho e izquierdo para pacientes con grados leves de STC que en STC de grados moderados o importantes. Esta diferencia no se aprecia para STC bilateral. Sin embargo, no se encuentran diferencias entre los distintos grupos para los umbrales de dolor por calor y por frío en el túnel carpiano de las manos afectada y sin afectar.

DESARROLLO DE PERFILES DE PACIENTES AFECTADOS POR SÍNDROME DE TÚNEL CARPIANO Y CEFALEA TENSIONAL MEDIANTE EL USO DE TÉCNICAS DE APRENDIZAJE AUTOMÁTICO

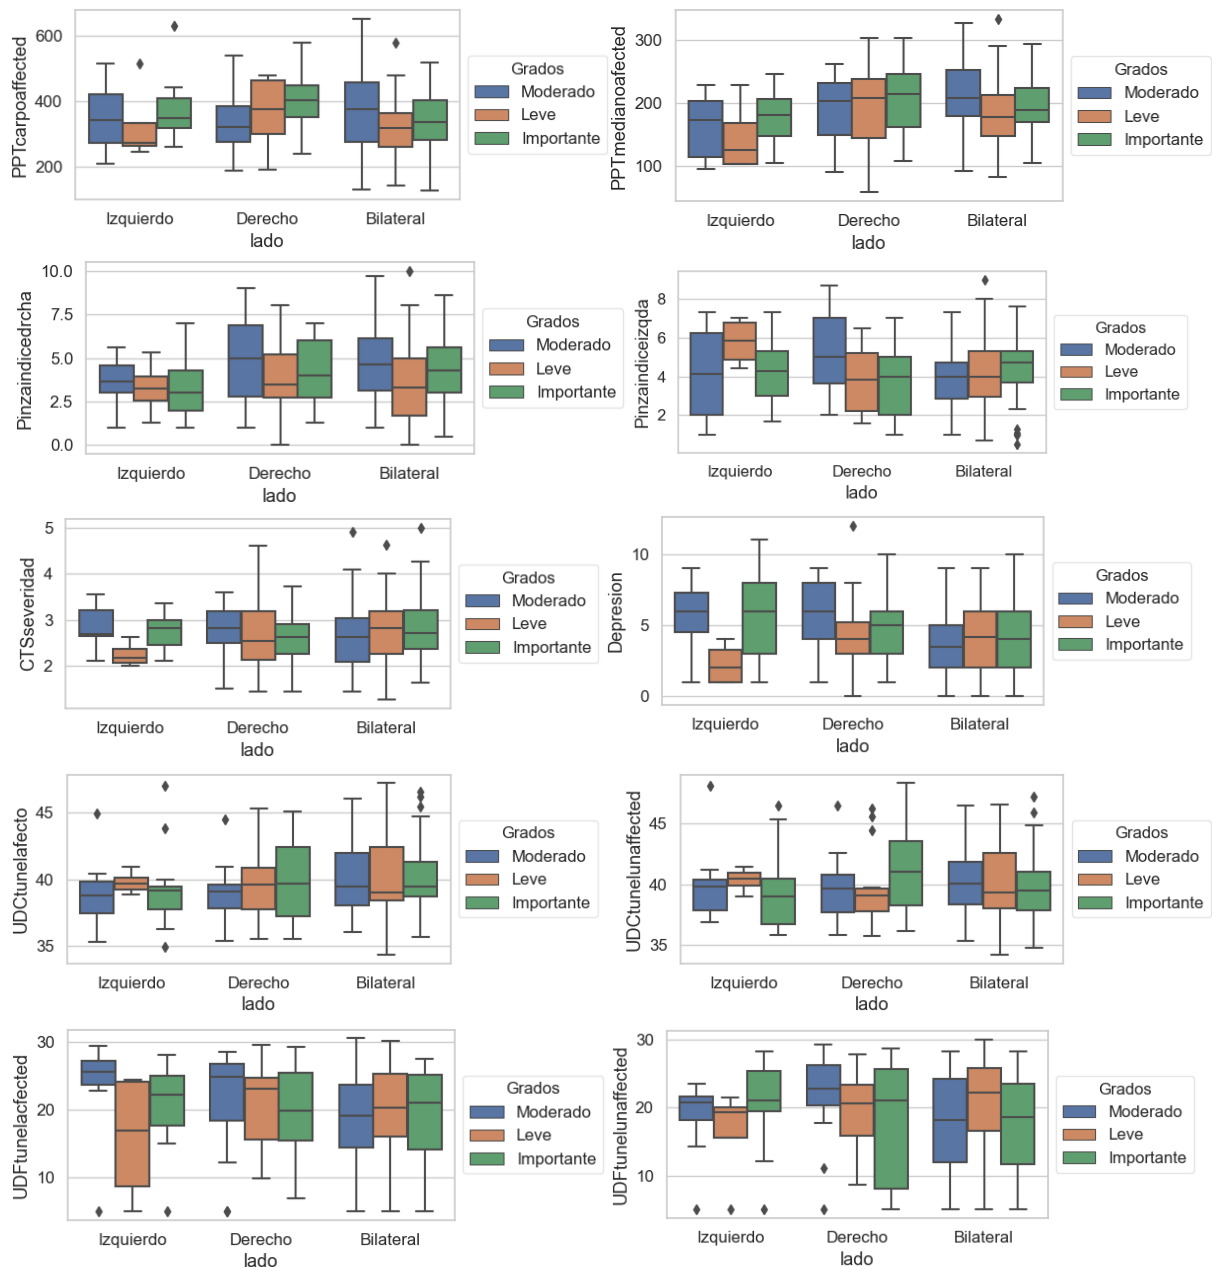


Figura 12. Diagrama de cajas de diferentes características agrupadas por “Grados” y “Lados”.

En cuanto a la distribución de los datos, se puede comprobar en la Figura 13 que la mayor parte de las características sigue una distribución estimada (KDE) normal. Las características relativas a la severidad de los síntomas, los umbrales de dolor por presión y por calor muestran una distribución normal de los datos.

Se puede apreciar también que algunas distribuciones no son simétricas y se encuentran desviadas hacia la derecha, como es el caso del peor dolor de la semana o el umbral de dolor al frío en la zona del túnel carpiano. Otras distribuciones se encuentran desviadas hacia la izquierda, como los años con dolor o la presión por pinzamiento en diferentes dedos como el meñique. En la distribución de presión por pinzamiento del dedo meñique además se pueden observar dos modos, pacientes en torno a 0,5 kg de presión y otros alrededor de 2 kg de presión.

DESARROLLO DE PERFILES DE PACIENTES AFECTADOS POR SÍNDROME DE TÚNEL CARPIANO Y CEFALEA TENSIONAL MEDIANTE EL USO DE TÉCNICAS DE APRENDIZAJE AUTOMÁTICO

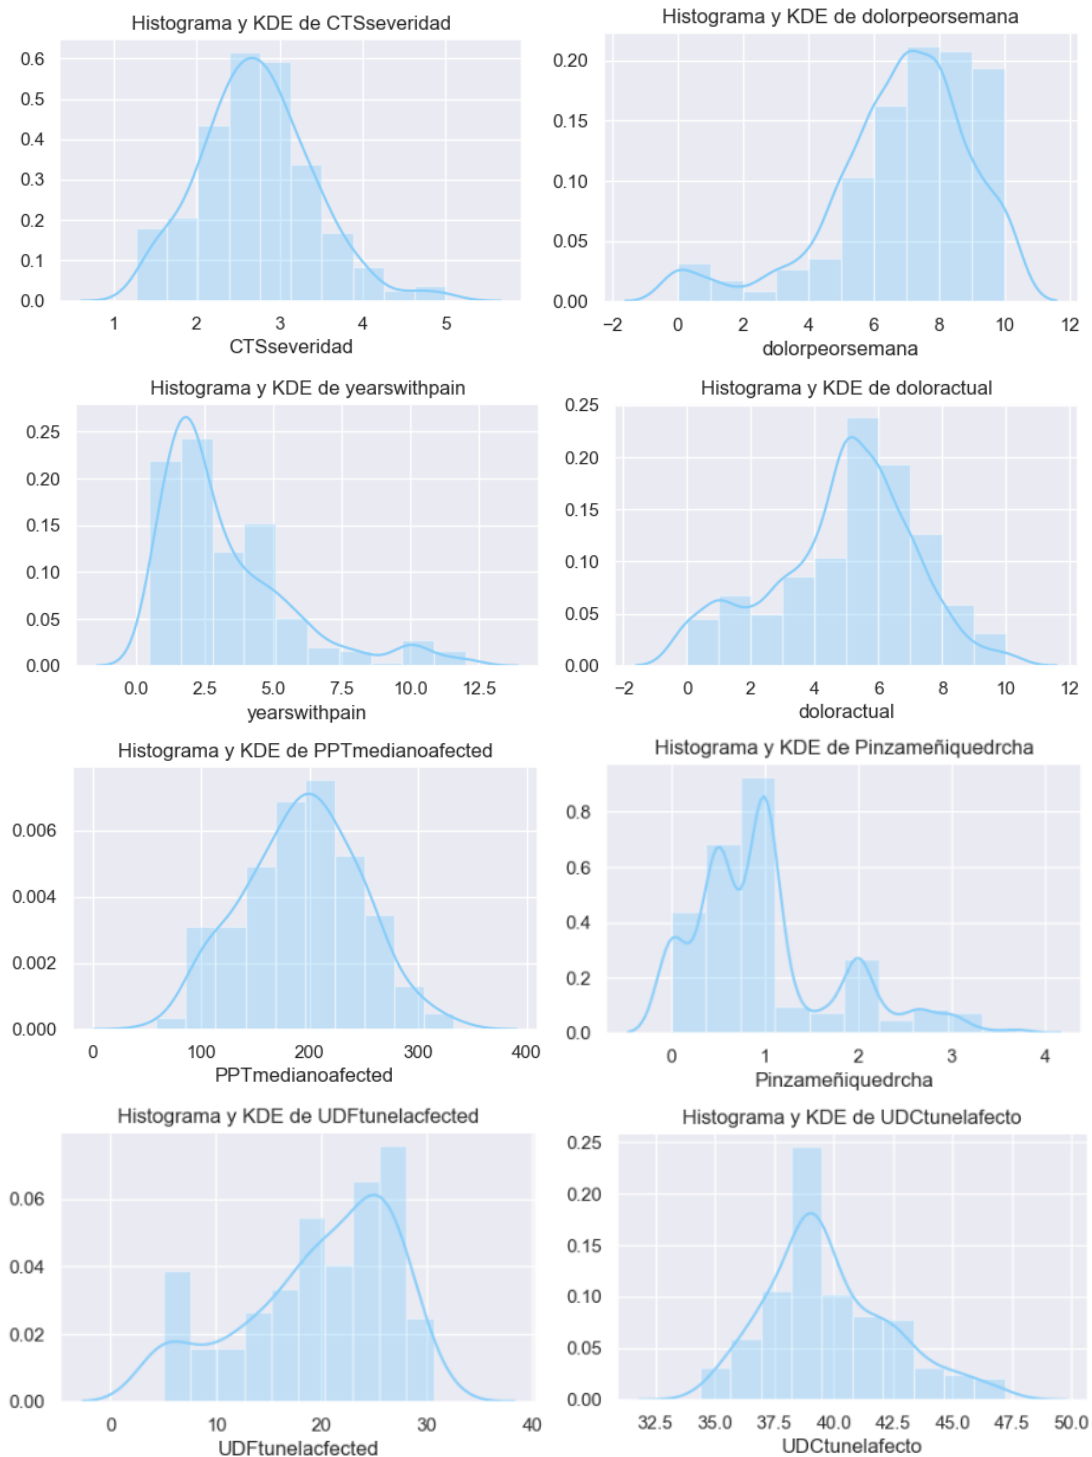


Figura 13. Histogramas y KDE de características del conjunto de datos de STC.

Se ha calculado el coeficiente de correlación de *Pearson* entre todos los pares de características que conforman el conjunto de datos de STC. Estos valores se han dibujado empleando un mapa de calor otorgando diferentes intensidades de color según el valor del coeficiente de correlación (Figura 15).

Analizando la Figura 15, se puede establecer que existen ciertas relaciones lineales entre algunas características, como el dolor actual y el peor dolor de la semana, el umbral de dolor al frío de la palma afectada y la no afectada o el valor de fuerza de pinzamiento de los dedos índice y anular de la misma

mano. Aunque existe relación lineal directa entre estas variables porque el coeficiente de correlación se encuentra entre 0,7 y 0,9, ninguno supera el límite de 0,9. Este es el valor a partir del cual se podría decir que las características son muy dependientes y, por tanto, se podría eliminar una de las características redundantes en la realización del modelo. En este caso, al no superar ningún coeficiente de correlación el valor de $|0,9|$, se ha decidido mantener el conjunto de características cuantitativas completo.

Es importante destacar también que existe una cierta correlación directa entre el dolor actual y el peor dolor de la semana y entre los umbrales de dolor por presión, independientemente del lugar en que se realice. Los umbrales de dolor por calor también muestran correlación directa entre ellos e inversa con los umbrales de dolor por frío. De la misma forma, las presiones del pinzamiento con los distintos dedos presentan correlación directa entre sí, independientemente del dedo con el que se realice.

En cuanto a las características cualitativas del conjunto de datos de pacientes con STC, se ha realizado una tabla de frecuencias (Tabla 9) con los posibles valores y la frecuencia de aparición. Se puede comprobar que la afectación de STC más común en el conjunto de datos es la “Bilateral”, que afecta a ambas manos; mientras que, la distribución de los grados del STC está repartida entre las tres categorías diferentes. Esto también se puede observar de forma más visual en el diagrama de barras de la Figura 14.

Tabla 9. Tabla de frecuencias de las características cualitativas de pacientes con STC.

Variable	Categoría 1 (total)	Categoría 2 (total)	Categoría 3 (total)	Total de datos
Grados	Importante (83)	Moderado (74)	Leve (65)	222
Lado	Bilateral (139)	Derecho (58)	Izquierdo (25)	222

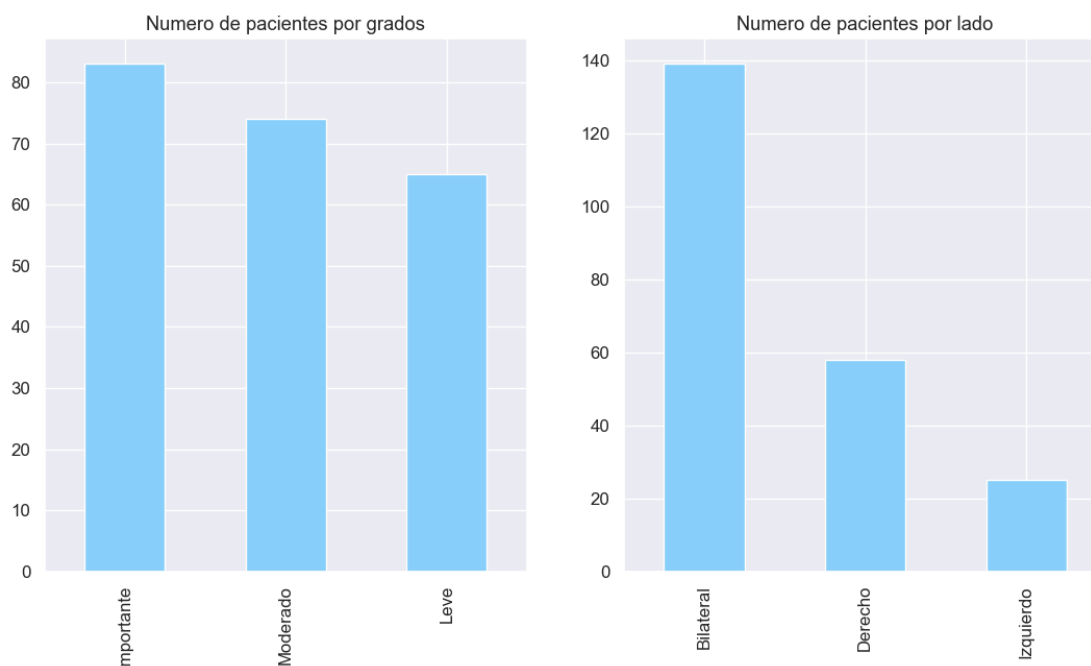


Figura 14. Diagrama de barras con las características cualitativas del conjunto de datos de STC.

DESARROLLO DE PERFILES DE PACIENTES AFECTADOS POR SÍNDROME DE TÚNEL CARIPIANO Y CEFALEA TENSIONAL MEDIANTE EL USO DE TÉCNICAS DE APRENDIZAJE AUTOMÁTICO

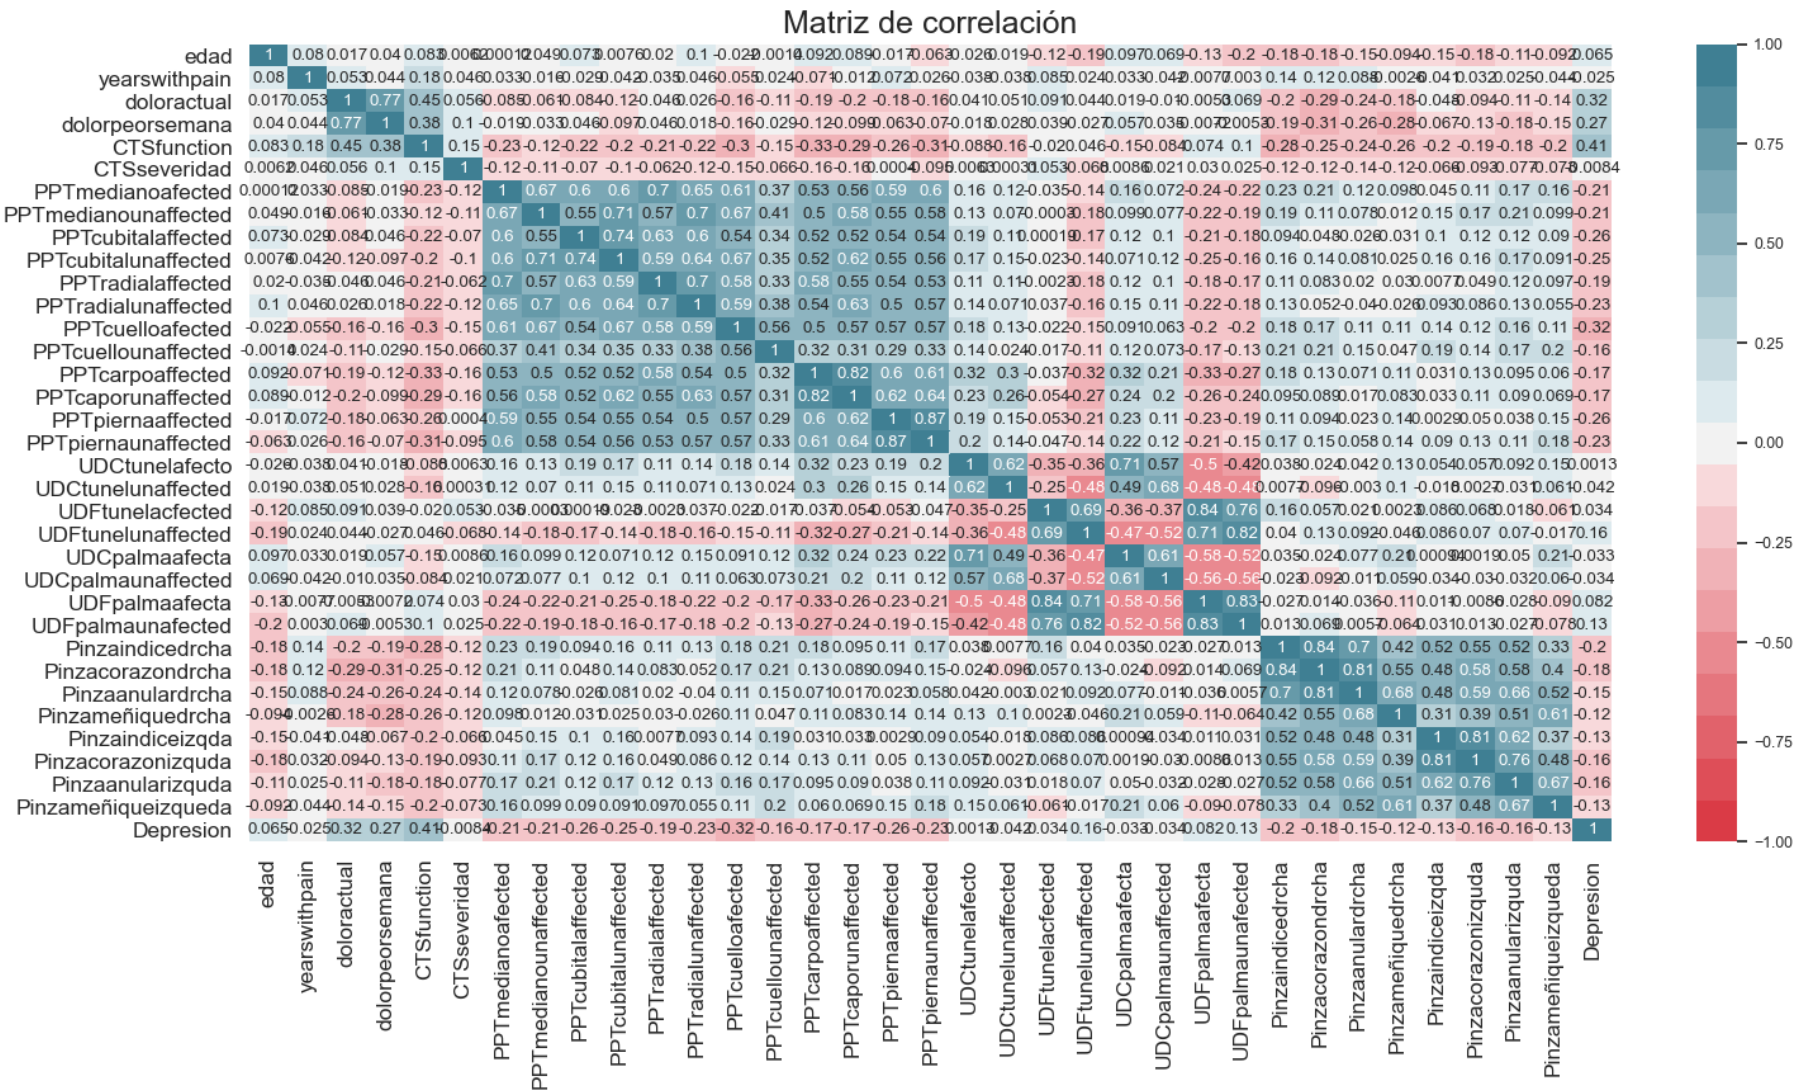


Figura 15. Mapa de calor de coeficientes de correlación de Pearson para las características del STC.

La tabla de contingencia que contiene las variables cualitativas “Lado” y “Grados” (Tabla 10) muestra que el conjunto de datos tiene aproximadamente la misma cantidad de pacientes con diferentes grados de STC para cada lado de afectación salvo en el lado izquierdo, que tiene significativamente menos pacientes leves que del resto de grados.

En cuanto a la prueba χ^2 realizada sobre las dos variables cualitativas, los resultados se encuentran en la Tabla 11. Los resultados obtenidos en cuanto al valor del Chi-cuadrado y al p-valor indican que no se puede rechazar la hipótesis nula, por lo que no se puede indicar nada sobre la independencia de las características “Lado” y “Grados”.

Tabla 10. Tabla de contingencia de variables “Lado” y “Grados” en pacientes con STC

		Lado			Total
		Bilateral	Derecho	Izquierdo	
Grados	Importante	49	21	13	83
	Leve	43	18	4	74
	Moderado	47	19	8	65
	Total	139	58	25	222

Tabla 11. Valores obtenidos en la prueba Chi-cuadrado sobre las variables “Grados” y “Lado”

Valor χ^2	3,3445
p-valor	0,5019
V (Cramer)	0,0868

5.1.2. Cefalea Tensional

En la Tabla 12 se muestran las características cuantitativas del conjunto de datos de pacientes aquejados de CT. De estas características, se muestra el valor medio, desviación estándar, valor máximo y mínimo, el número de pacientes que no presentan dato en dicha característica y el número de valores atípicos (*outliers*) detectados. Existen un total de 208 registros de pacientes diferentes.

Tabla 12. Parámetros obtenidos de las variables cuantitativas de pacientes con CT.

Característica	Media \pm std.	Max	Min	Nº pacientes sin dato	Nº de outliers
Edad	44 \pm 14	83,0	18,0	1	0
Tiempo_comienzo	10 \pm 11	60,0	0,0	8	0
EVA	6 \pm 2	31,0	0,0	0	1
Duracion	7 \pm 4	24,0	0,5	16	0
FreqMONT	16 \pm 9	30,0	1,0	5	0
TrPsactivos	4 \pm 2	11,0	0,0	3	0
TrPslatentes	1 \pm 2	11,0	0,0	3	0
TOTALTrPs	6 \pm 3	11,0	0,0	3	0
UDP_C5C6_Dcha	234 \pm 144	863,0	0,0	0	5
UDP_C5C6_Izda	221 \pm 132	733,0	0,0	0	3
UDP_Temporal_Dcho	221 \pm 98	541,0	0,0	0	2

DESARROLLO DE PERFILES DE PACIENTES AFECTADOS POR SÍNDROME DE TÚNEL CARPIANO Y CEFALEA TENSIONAL MEDIANTE EL USO DE TÉCNICAS DE APRENDIZAJE AUTOMÁTICO

Característica	Media ± std.	Max	Min	Nº pacientes sin dato	Nº de outliers
UDP_Temporal_Izdo	205 ± 96	716,0	0,0	0	1
UDP_IIMeta_Dcho	264 ± 113	672,5	0,0	0	2
UDP_IIMeta_Izdo	252 ± 104	586,5	0,0	2	0
UDP_Tibial_Dcho	430 ± 220	1375,0	0,0	0	4
UDP_Tibial_Izdo	416 ± 210	1266,0	0,0	2	0
HDI_Emcional	19 ± 13	52,0	0,0	39	0
HDI_Fisico	22 ± 12	52,0	0,0	39	0
Funcion_fisica	78 ± 24	100,0	0,0	2	0
Rol_fisico	51 ± 40	100,0	0,0	2	0
Dolor_corporal	50 ± 23	100,0	0,0	2	0
Salud_general	56 ± 22	100,0	0,0	2	0
Vitalidad	48 ± 22	100,0	0,0	2	0
Funcion_social	66 ± 25	100,0	0,0	2	0
Rol_emocional	62 ± 40	100,0	0,0	2	0
Salud_mental	57 ± 22	100,0	0,0	3	0
globalsueño	8 ± 4	20,0	0,0	21	0
HADS_depresión	7 ± 4	20,0	1,0	39	0
HADS_ansiedad	9 ± 4	19,0	0,0	39	0
STAI_estado	21 ± 4	33,0	9,0	95	0
STAI_rasgo	23 ± 6	39,0	11,0	95	0
RollerDRCHOUMBRAL	1164 ± 745	3350,0	450,0	8	0
RollerIZDOUMBRAL	1178 ± 822	5300,0	450,0	9	0
DolorRollerDRCHOUMBRAL	2 ± 1	9,0	0,5	9	0
DolorRollerIZDOUMBRAL	2 ± 1	10,0	0,0	9	0

Analizando la Tabla 12 se pueden descubrir algunos detalles importantes del conjunto de datos, como la ausencia de valores de la escala STAI, donde faltan datos para el 46% de los pacientes. También, se encuentra algún valor anómalo, como que el valor máximo de la escala de dolor EVA sea 31, que es detectado como un *outlier*.

La Figura 16 muestra los diagramas de cajas o *boxplot* de los umbrales de dolor por presión en distintas zonas, donde se puede observar que no hay diferencias significativas en la distribución de los datos entre el lado derecho o lado izquierdo. Se puede comprobar que los umbrales de dolor son más bajos en las zonas cercanas a la zona de afectación del CT, como en la zona temporal, que en zonas alejadas donde este valor umbral es mayor, por ejemplo, en la zona tibial.

En la Figura 17a, se puede observar también que existe un mayor impacto de la CT autopercibido en cuanto a la vitalidad y el dolor corporal que en cuanto a la salud mental. Esto también se refleja en un mayor HDI físico en términos de la mediana de la población si se compara con el HDI emocional (Figura 17b).




Figura 16. Diagrama de cajas de los Umbrales de Dolor por Presión (UDP).

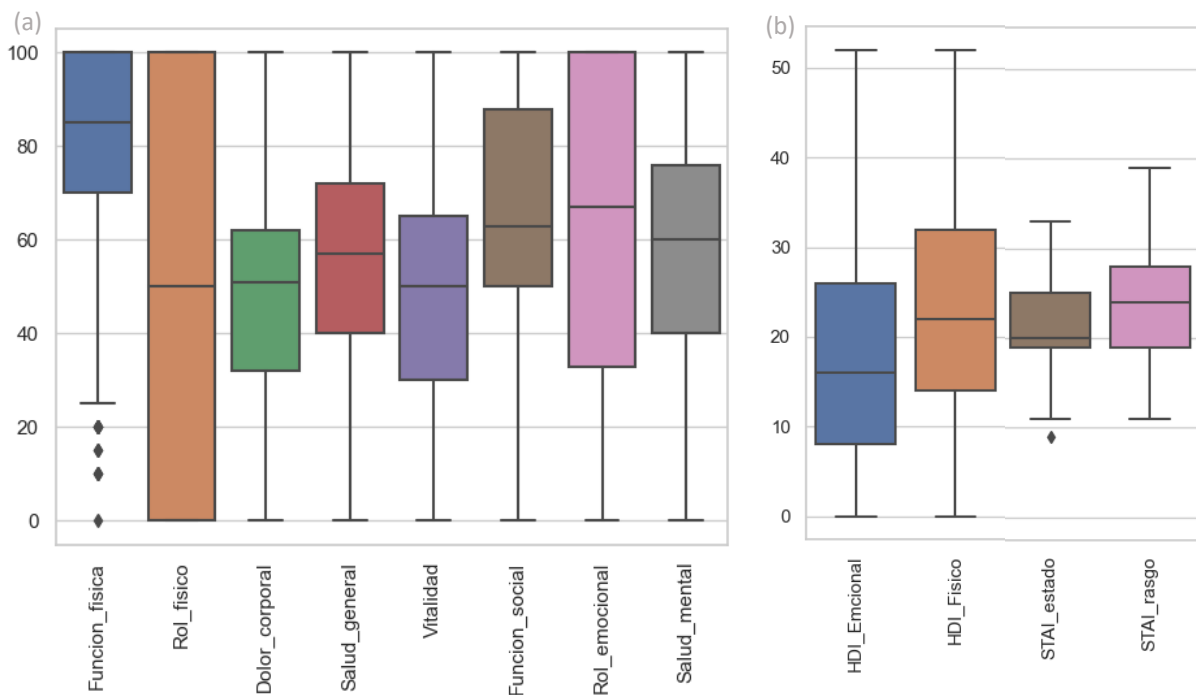


Figura 17. Diagrama de cajas de (a) la valoración psicométrica SF-36 y (b) las escalas HDI y STAI.

La Figura 18 muestra los diagramas de cajas de las diferentes características cuantitativas agrupadas por “Medicación preventiva” y “Tratamiento sintomático”. De estas gráficas destaca que el uso de medicación preventiva, sobre todo, en pacientes con un dolor mayor (EVA), una duración mayor de los episodios de CT y una mayor frecuencia mensual de los mismos. También, es destacable el número de

Trigger Points latentes y totales, que son menores en pacientes con medicación preventiva, no habiendo diferencias significativas en el número de *Trigger Points* activos en pacientes con medicación preventiva o tratamiento sintomático.

En cuanto a los umbrales de dolor por presión en las distintas zonas, o los distintos parámetros estudiados de la prueba SF-36, como la salud general, no se encuentran diferencias significativas en los valores entre pacientes con medicación preventiva o tratamiento sintomático. Se observan valores menores de depresión y de problemas emocionales autopercebidos en pacientes que no reciben medicación preventiva si se compara con aquellos que sí reciben dicha medicación. En la prueba de dolor empleando el *roller*, se observan valores de presión menores en pacientes que no presentan tratamiento sintomático que en aquellos que si presentan dicho tratamiento, independientemente del uso de medicación preventiva.

En cuanto a la distribución de los datos, se puede comprobar en la Figura 19 que la mayor parte de las características del conjunto de datos de CT también sigue una distribución estimada (KDE) normal. Las características relativas a los umbrales de dolor por presión, la mayor parte de las características obtenidas del informe SF-36 y las escalas HADS y HDI tienen una distribución normal de los datos.

Se puede apreciar también que algunas distribuciones no son simétricas y se encuentran desviadas hacia la derecha, como es el caso de la “Funcion_fisica” y “Funcion_social” del informe SF-36. Otras características, presentan distribuciones desviadas hacia la izquierda, como el tiempo desde el comienzo de los síntomas o el dolor umbral aplicando el *roller*.

Se ha calculado el coeficiente de correlación de *Pearson* entre todos los pares de características que conforman el conjunto de datos de CT. Estos valores se han dibujado empleando un mapa de calor otorgando diferentes intensidades de color según el valor del coeficiente de correlación (Figura 20).

Analizando la Figura 20, se puede establecer que existen ciertas relaciones lineales entre algunas características, como el dolor umbral por presión entre los lados izquierdo y derecho en todas las zonas probadas. Además, existe también una relación lineal importante entre el valor umbral de dolor con el *roller* en el lado izquierdo y derecho. En estos casos descritos, el coeficiente de correlación es superior a $|0,9|$, por lo cual, se puede inferir que las características son linealmente dependientes y, por tanto, se puede eliminar una de las características redundantes. Esto es debido a que el uso de las dos características no aportaría información adicional para la realización del modelo y daría mayor peso a dichas características sin ser necesario.

A parte de esta correlación directa muy elevada entre los umbrales de dolor por presión derecha e izquierdo en distintas zonas, existe una correlación algo inferior entre todos los umbrales de dolor y los obtenidos del *roller*. Los distintos aspectos analizados en la valoración psicométrica también presentan correlaciones directas entre sí.

DESARROLLO DE PERFILES DE PACIENTES AFECTADOS POR SÍNDROME DE TÚNEL CARPIANO Y CEFALEA TENSIONAL MEDIANTE EL USO DE TÉCNICAS DE APRENDIZAJE AUTOMÁTICO

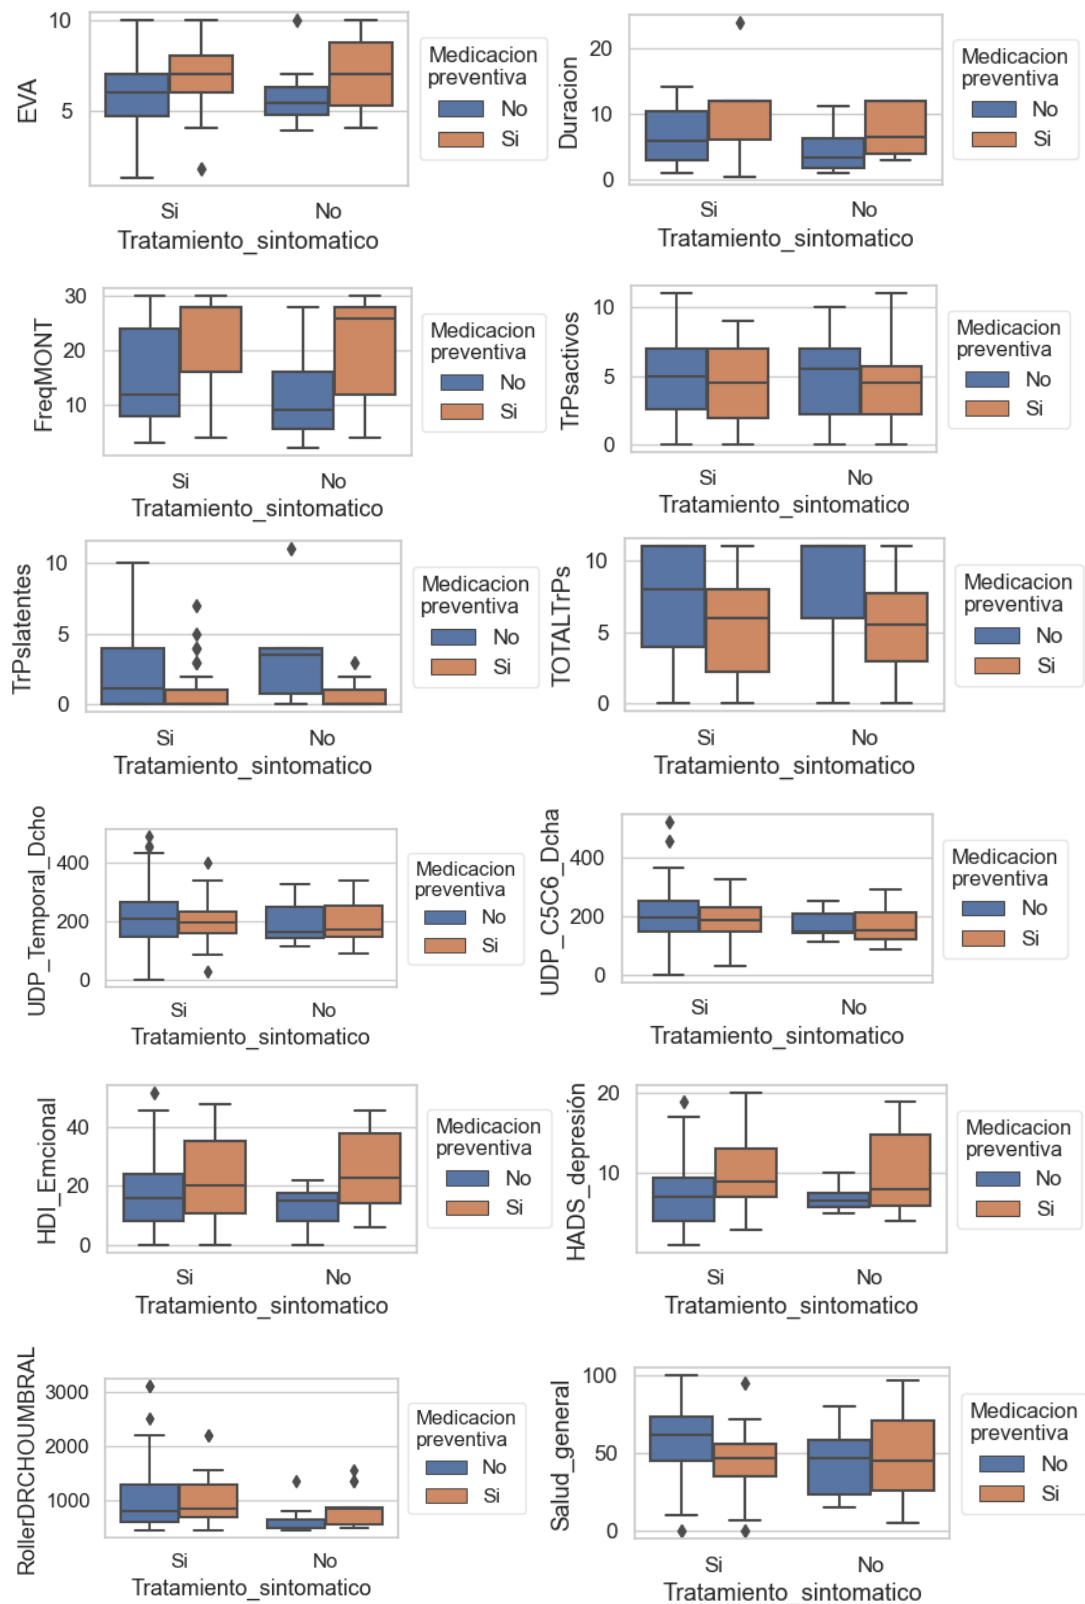


Figura 18. Diagrama de cajas de las características cualitativas del conjunto de datos de CT agrupadas por "Tratamiento Sintomático" y "Medicación preventiva".

DESARROLLO DE PERFILES DE PACIENTES AFECTADOS POR SÍNDROME DE TÚNEL CARIANO Y
CEFALEA TENSIONAL MEDIANTE EL USO DE TÉCNICAS DE APRENDIZAJE AUTOMÁTICO

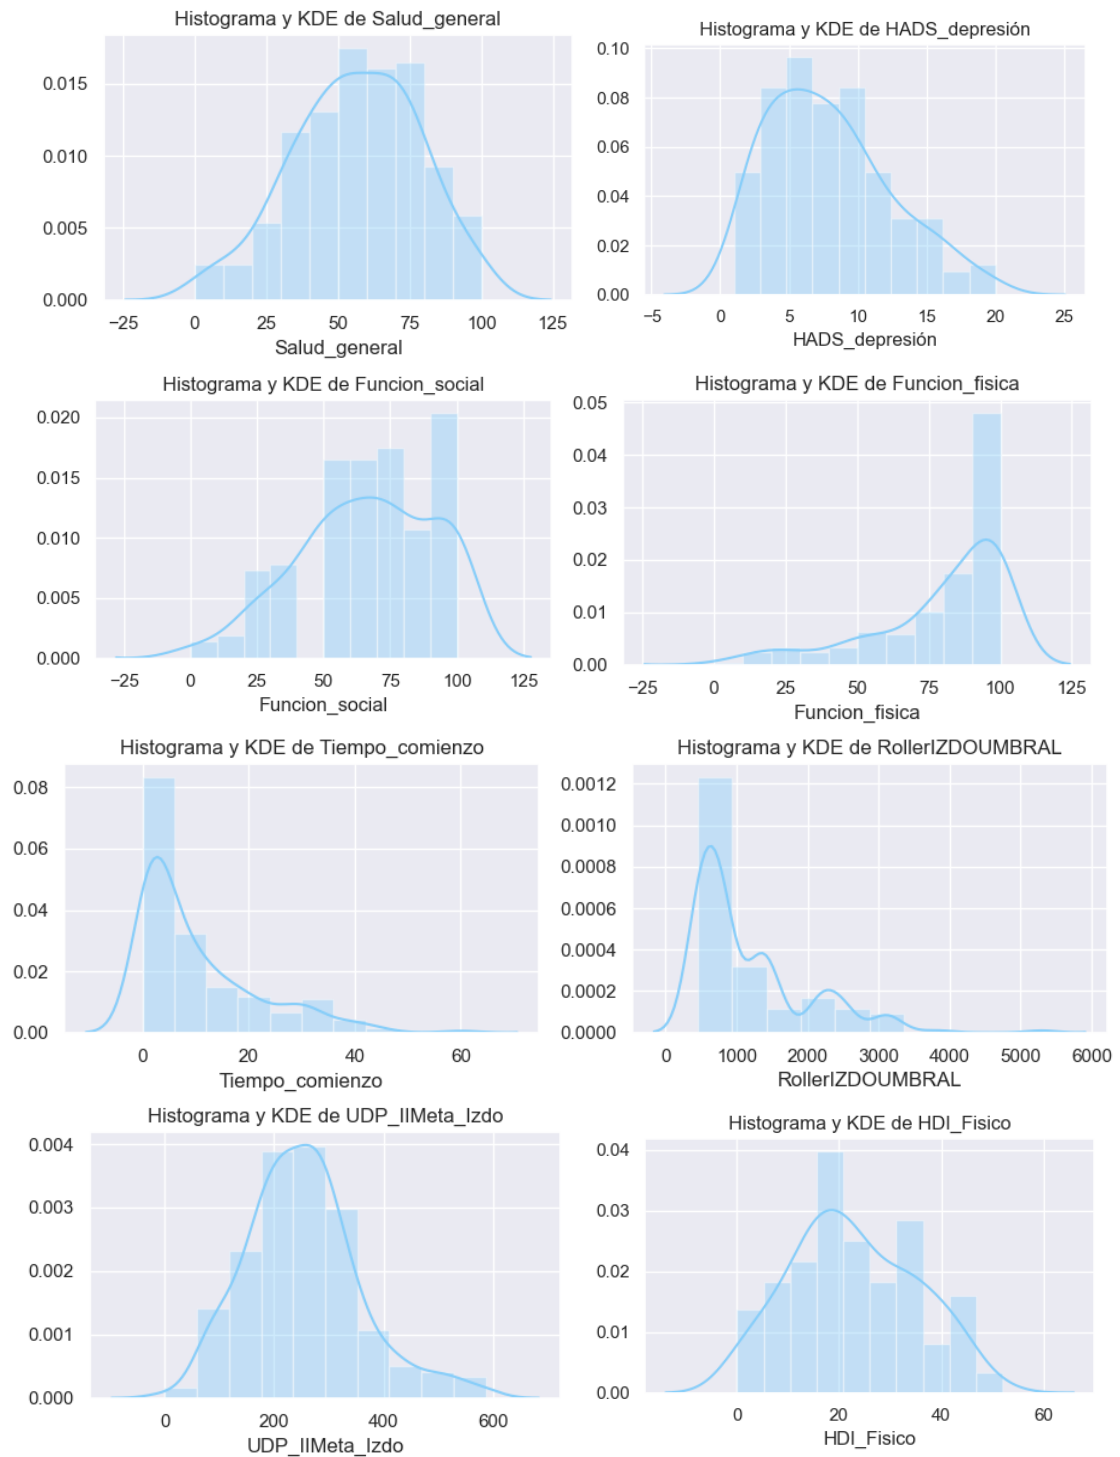


Figura 19. Histogramas y KDE de características del conjunto de datos de CT.

DESARROLLO DE PERFILES DE PACIENTES AFECTADOS POR SÍNDROME DE TÚNEL CARIPIANO Y CEFALEA TENSIONAL MEDIANTE EL USO DE TÉCNICAS DE APRENDIZAJE AUTOMÁTICO




Figura 20. Mapa de calor de coeficientes de correlación de Pearson para las características del conjunto de datos de CT.

En cuanto a las características cualitativas del conjunto de datos de pacientes con CT, se ha realizado una tabla de frecuencias (Tabla 13) con los posibles valores y la frecuencia de aparición. Se puede comprobar que existe un 31% de pacientes que no tienen recogido el valor de medicación preventiva y un 21% que no presenta el valor de tratamiento sintomático, lo cual es bastante elevado. Además, en este conjunto de datos existe un mayor número de mujeres que padecen esta patología y un 87% del total toma tratamiento cuando padece CT. Sin embargo, el uso de medicación preventiva solamente se da en el 42% de los pacientes.

Tabla 13. Tabla de frecuencias de las características cualitativas de pacientes con STC.

Variable	Categoría 1 (total)	Categoría 2 (total)	Total de datos	Nº pacientes sin dato
Sexo	Mujer (149)	Varón (59)	208	0
Medicacion_preventiva	No (83)	Si (60)	143	65
Tratamiento_sintomático	No (22)	Si (142)	164	44

La tabla de contingencia (Tabla 14) que contiene las variables cualitativas del conjunto de datos de CT muestra que, solamente un 5,6% de los pacientes no tiene ningún tipo de tratamiento, y es más común el tratamiento sintomático que la medicación preventiva. No se observan grandes diferencias en el grupo de varones con respecto al de mujeres en cuanto al tratamiento se refiere.

Tabla 14. Tabla de contingencia conjunta de las características “Tratamiento_sintomatico”, “Medicación_preventiva” y “Sexo” en pacientes con CT.

		Sexo		
		Mujer	Varón	Total
Tratamiento_sintomatico	Medicacion_preventiva			
	No	6	2	8
Si	No	53	22	75
	Si	36	10	46
Total		105	38	143

En cuanto a la prueba χ^2 realizada sobre las variables cualitativas dos a dos, los resultados se encuentran en la Tabla 15. Los resultados obtenidos en cuanto al valor del Chi-cuadrado y al p-valor indican que se puede rechazar la hipótesis nula en la relación entre “Tratamiento_sintomatico” y “Medicacion_preventiva”, por lo que se puede decir que dichas variables no son independientes.

Tabla 15. Valores obtenidos en la prueba Chi-cuadrado sobre las variables cualitativas

	Medicacion_preventiva – Tratamiento_sintomatico	Sexo – Tratamiento_sintomatico	Sexo – Medicacion_preventiva
Valor χ^2	5,0173	0,0146	0,5562
p-valor	0,0251	0,9039	0,4558
Φ (Cramer)	0,1873	0,0094	0,0624

5.2. PREPROCESADO DE LOS DATOS

5.2.1. Valores ausentes y anómalos

En el conjunto de datos de STC, no existen una gran cantidad de valores nulos, por lo que se podrían eliminar. Si esto se hiciera, el *dataset* perdería solamente 8 registros y pasaría de 222 pacientes a 214. Como al registro que más características le faltan son solamente 8, se ha decidido imputar el valor de las características vacías, empleando el algoritmo de los k-vecinos más próximos, con $k=6$, empleando la distancia heterogénea HEOM .

Sin embargo, el conjunto de datos de CT presenta muchos más valores vacíos. Por lo tanto, es necesario eliminar algunas de esas características para entrenar el modelo de aprendizaje automático. En concreto se ha decidido eliminar las variables relacionadas con la escala STAI, ya que, presenta casi la mitad de los valores vacíos.

Las variables categóricas “Tratamiento_sintomatico” y “Medicacion_preventiva” se han decidido eliminar también porque supondría la imputación de un 21% y 31% de los valores, respectivamente, lo cual se considera que puede perjudicar al modelo realizado. El resto de las características se han conservado y los valores no registrados se han imputado con el algoritmo de los k-vecinos más próximos, con $k=6$, empleando la distancia heterogénea HEOM.

En cuanto a los valores anómalos o *outliers*, si se eliminasen los registros que contienen dichos *outliers* en ambos conjuntos de datos, supondría una reducción bastante considerable de los datos. Por esto, se han decidido imputar los valores anómalos empleando en ambos conjuntos de datos, el algoritmo de los k-vecinos más próximos, con $k=6$, y distancia heterogénea HEOM.

5.2.2. Codificación de características cualitativas

En el caso de las características categóricas del conjunto de datos de pacientes con STC se realizan dos tipos de codificación. La codificación ordinal para la característica “Grados” se realiza otorgando el valor 0 a “Leve”, 1 a “Moderado” y 2 a “Importante”. De esta forma, se aumenta la distancia desde “Leve” a “Importante” , ya que, en la mayoría de los casos de STC la transición natural de la sintomatología es de “Leve” a “Moderado” y de “Moderado” a “Importante”. En cuanto a la característica “Lado”, se ha codificado con tipo *One-Hot*.

En cuanto a las características categóricas del conjunto de datos de pacientes con CT, al eliminar el “Tratamiento_sintomatico” y “Medicacion_preventiva”, solamente queda la variable “Sexo” que, como tiene solamente dos posibles valores, se ha decidido emplear codificación ordinal.

5.2.3. Selección de características y estandarización

La selección de características se ha realizado empleando las técnicas de filtros en los dos conjuntos de datos. Se ha decidido emplear solamente estas técnicas porque las métricas de evaluación de los algoritmos de agrupamiento no supervisados no aportan información lo suficientemente fiable para la extracción de características. Además, de esta forma, se aplican los mismos criterios a ambos conjuntos de datos.

Debido a los valores obtenidos en las diferentes pruebas como los coeficientes de correlación se ha decidido eliminar las características “UDP_C5C6_Izda”, “UDP_Temporal_Izdo”, “UDP_IIMeta_Izdo”, “UDP_Tibial_Izdo” y “RollerIZDOUMBRA” del conjunto de datos de CT. Sin embargo, en cuanto a las características del conjunto de datos de STC, se ha decidido mantener todas las presentes, ya que, los coeficientes de correlación no superan el valor $|0,9|$ y el test de χ^2 no aporta un p-valor significativo.

En cuanto a la normalización/estandarización, se ha decidido emplear la estandarización *z-score* en ambos conjuntos de datos para todas las características.

5.3. CLÚSTERES EN CONJUNTO DE DATOS DE SÍNDROME DE TÚNEL CARPIANO

En esta sección se tratarán los resultados obtenidos tras la aplicación de distintos algoritmos de agrupamiento para el conjunto de datos de pacientes con Síndrome de Túnel Carpiano.

5.3.1. Obtención del número de clústeres

La elección del número de clústeres en los que agrupar el conjunto de dato es uno de los principales problemas a la hora de resolver el problema, ya que, los principales métodos de agrupamiento requieren la elección previa de los mismos. Se incluye en este grupo el agrupamiento por *k-means*, aglomerativo y espectral. Otros métodos como el *MeanShift* o el *AffinityPropagation* requieren fijar otros parámetros definidos en el capítulo anterior.

En la Tabla 16 se muestran los valores obtenidos de las distintas métricas de desempeño en función del número de clústeres elegido en los métodos que requieren de su selección previa. En primer lugar, es destacable que el valor del índice *Calinski Harabasz* es bastante inferior en el algoritmo aglomerativo en comparación con el espectral o el *k-means*. Esto puede ser debido a la forma de los clústeres obtenidos. Si se comparan los valores del índice de *Dunn*, se observan mejores valores cuanto mayor es el número de clústeres en el caso de los algoritmos *k-means* y aglomerativo. Esto es algo que no concuerda con el resto de los valores de los índices, por lo que se intuye que el valor de este índice no es representativo en estos casos. En general, las métricas presentan mejores valores en la técnica de agrupamiento espectral, lo cual hace de esta una buena candidata a tener en cuenta a la hora de agrupar los datos.

Si se contrastan los valores en función del número de clústeres, se puede probar que dos es el número de clústeres que mejores índices obtiene, aunque no está muy lejano de los valores de los índices obtenidos para tres clústeres.

Tabla 16. Métricas de desempeño obtenidas por diferentes algoritmos de agrupamiento en función del número de clústeres elegido.

Algoritmo	Métrica	Número de clústeres (k)						
		K=2	K=3	K=4	K=5	K=6	K=7	K=8
k-means	Índice de Dunn	0,2634	0,2646	0,2758	0,3144	0,2989	0,2993	0,2943
	Índice Calinski Harabasz	41,0636	31,5863	26,6319	23,9789	21,6017	19,5911	17,9289
	Coefficiente de Silueta	0,1347	0,1165	0,1044	0,0959	0,0896	0,0891	0,0751
	Índice Davies Bouldin	2,2762	2,3162	2,4212	2,2496	2,2524	2,3184	2,318
Clustering aglomerativo	Índice de Dunn	0,2891	0,2946	0,3187	0,3268	0,3268	0,3459	0,36
	Índice Calinski Harabasz	25,7893	22,6773	21,2052	19,1802	17,9325	16,996	16,2438
	Coefficiente de Silueta	0,1101	0,0662	0,0724	0,0736	0,0799	0,0844	0,0742
	Índice Davies Bouldin	2,355	2,8877	2,4699	2,2898	2,2677	2,2103	2,3086
Clustering espectral	Índice de Dunn	0,2606	0,2606	0,163	0,1995	0,2746	0,2746	0,2681
	Índice Calinski Harabasz	40,0256	30,3951	22,0135	22,0127	20,4697	17,4642	15,6986
	Coefficiente de Silueta	0,1369	0,1165	0,0799	0,0856	0,0876	0,0825	0,0779
	Índice Davies Bouldin	2,2613	2,2949	2,4217	2,48	2,313	2,2474	2,3009

En la Tabla 17, se muestran los valores de las métricas obtenidas y el número de clústeres para el método de agrupamiento mediante *AffinityPropagation*, en función del valor de preferencia. El algoritmo *MeanShift* se ha empleado también para la obtención de clústeres, pero los resultados modelan la mayor parte de las muestras en el mismo grupo y se obtienen otros grupos con una o dos muestras solamente, lo cual aporta resultados sin relevancia. Es por esto por lo que el algoritmo *MeanShift* se ha descartado en el estudio.

En este caso, el índice de *Dunn* y el índice de *Davies Bouldin* muestran mejores valores de métrica para una preferencia de -300, que proporciona 5 clústeres potenciales. Teniendo en cuenta el resto de las métricas y que las diferencias entre ellas no son muy grandes, los mejores valores se obtienen también

para dos clústeres con una preferencia de -760, aunque las métricas para tres clústeres confieren también valores similares. Es importante resaltar que estas métricas no son muy diferentes a las obtenidas con los algoritmos anteriores.

Tabla 17. Métricas de desempeño y número de clústeres obtenidos por el algoritmo de *Affinity Propagation* en función del valor de preferencia.

	Preferencia						
	-760	-650	-450	-300	-250	-200	-170
Número de clústeres	2	3	4	5	6	7	9
Índice de Dunn	0,2634	0,2646	0,2758	0,3144	0,2989	0,2993	0,2943
Índice Calinski Harabasz	41,0636	31,5863	26,6319	23,9789	21,6017	19,5911	17,9289
Coefficiente de Silueta	0,1347	0,1165	0,1044	0,0959	0,0896	0,0891	0,0751
Índice Davies Bouldin	2,2762	2,3162	2,4212	2,2496	2,2524	2,3184	2,318

Con el objetivo de obtener información adicional antes de realizar los grupos, se ha realizado un dendrograma, que se puede observar en la Figura 21, aplicando el algoritmo de *clustering* aglomerativo sobre el conjunto de datos de STC.

En el dendrograma, se pueden observar los diferentes clústeres que se van formando en cada nivel dependiendo de las distancias entre los datos. Así, en la parte superior del diagrama de árbol o dendrograma hay solamente un clúster, que es el obtenido tras la unión de todos los clústeres que ha ido realizando el algoritmo. El gráfico indica que una posible solución es emplear dos, tres o incluso cuatro clústeres para agrupar los datos.

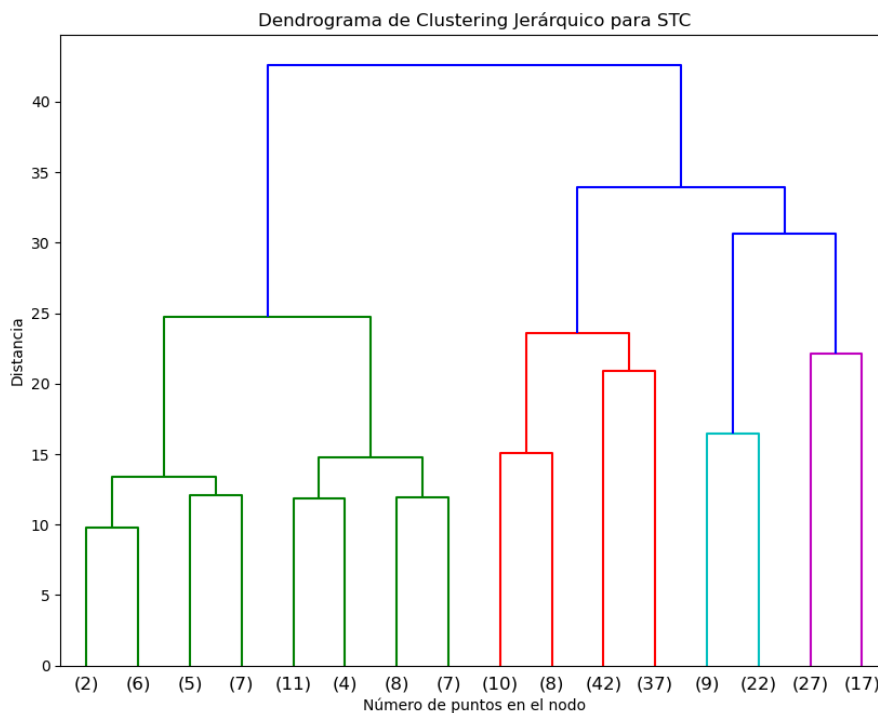


Figura 21. Dendrograma del *clustering* aglomerativo aplicado al conjunto de datos de STC.

5.3.2. Mapas autoorganizativos

En la Figura 22 se muestra la distancia media entre los parámetros de cada nodo y sus vecinos utilizando un mapa de color. Los hexágonos de color azul oscuro representan valores más bajos, es decir, los nodos vecinos son similares al nodo dado; mientras que los hexágonos amarillos representan valores más altos, es decir, zonas donde los nodos vecinos son diferentes. Por lo tanto, los registros similares se agrupan en las áreas azul oscuro, mientras que las áreas amarillas actúan como barreras que separan los diferentes grupos potenciales. Se trata de una técnica que permite identificar clústeres de forma gráfica. Puede observarse una zona de color azul intenso en el centro y otras dos zonas de color azul, algo menos oscuro en la parte superior, separadas por zonas más claras. Si combinamos esta información con la obtenida anteriormente, se han decidido elegir dos y tres clústeres como posible solución al problema.




Figura 22. Mapa autoorganizativo de la diferencia de pesos en el conjunto de datos de STC.

A parte de este gráfico de diferencia de pesos, es posible representar mediante mapas autoorganizativos (SOM) un mapa de colores de la componente del vector de pesos de cada característica incluida en el estudio (Figura 23). Si se considera el mapa asociado con la variable “Edad”, situada en la esquina superior izquierda de la Figura 23, las áreas azules corresponden a la edad más joven mientras que las áreas amarillas corresponden a la edad más avanzada. Por lo tanto, las muestras que se sitúan en la franja superior corresponden a pacientes mayores, como lo demuestra la mancha amarilla en el mapa autoorganizativo de la edad.

Cabe destacar que todos los mapas autoorganizativos de las características de los umbrales de dolor por presión son muy similares. Las zonas donde el umbral de dolor por presión (PPT) sobre el nervio mediano tiene valores altos, las características restantes relacionadas con PPT también tienen valores altos. Lo mismo ocurre en los lugares donde el PPT sobre el nervio mediano tienen valores bajos, ya que, las características restantes de PPT también tienen valores bajos. Por lo tanto, estos mapas autoorganizativos demuestran visualmente que las características de PPT están correlacionadas de manera muy positiva, independientemente de la zona testada.

DESARROLLO DE PERFILES DE PACIENTES AFECTADOS POR SÍNDROME DE TÚNEL CARPIANO Y CEFALEA TENSIONAL MEDIANTE EL USO DE TÉCNICAS DE APRENDIZAJE AUTOMÁTICO

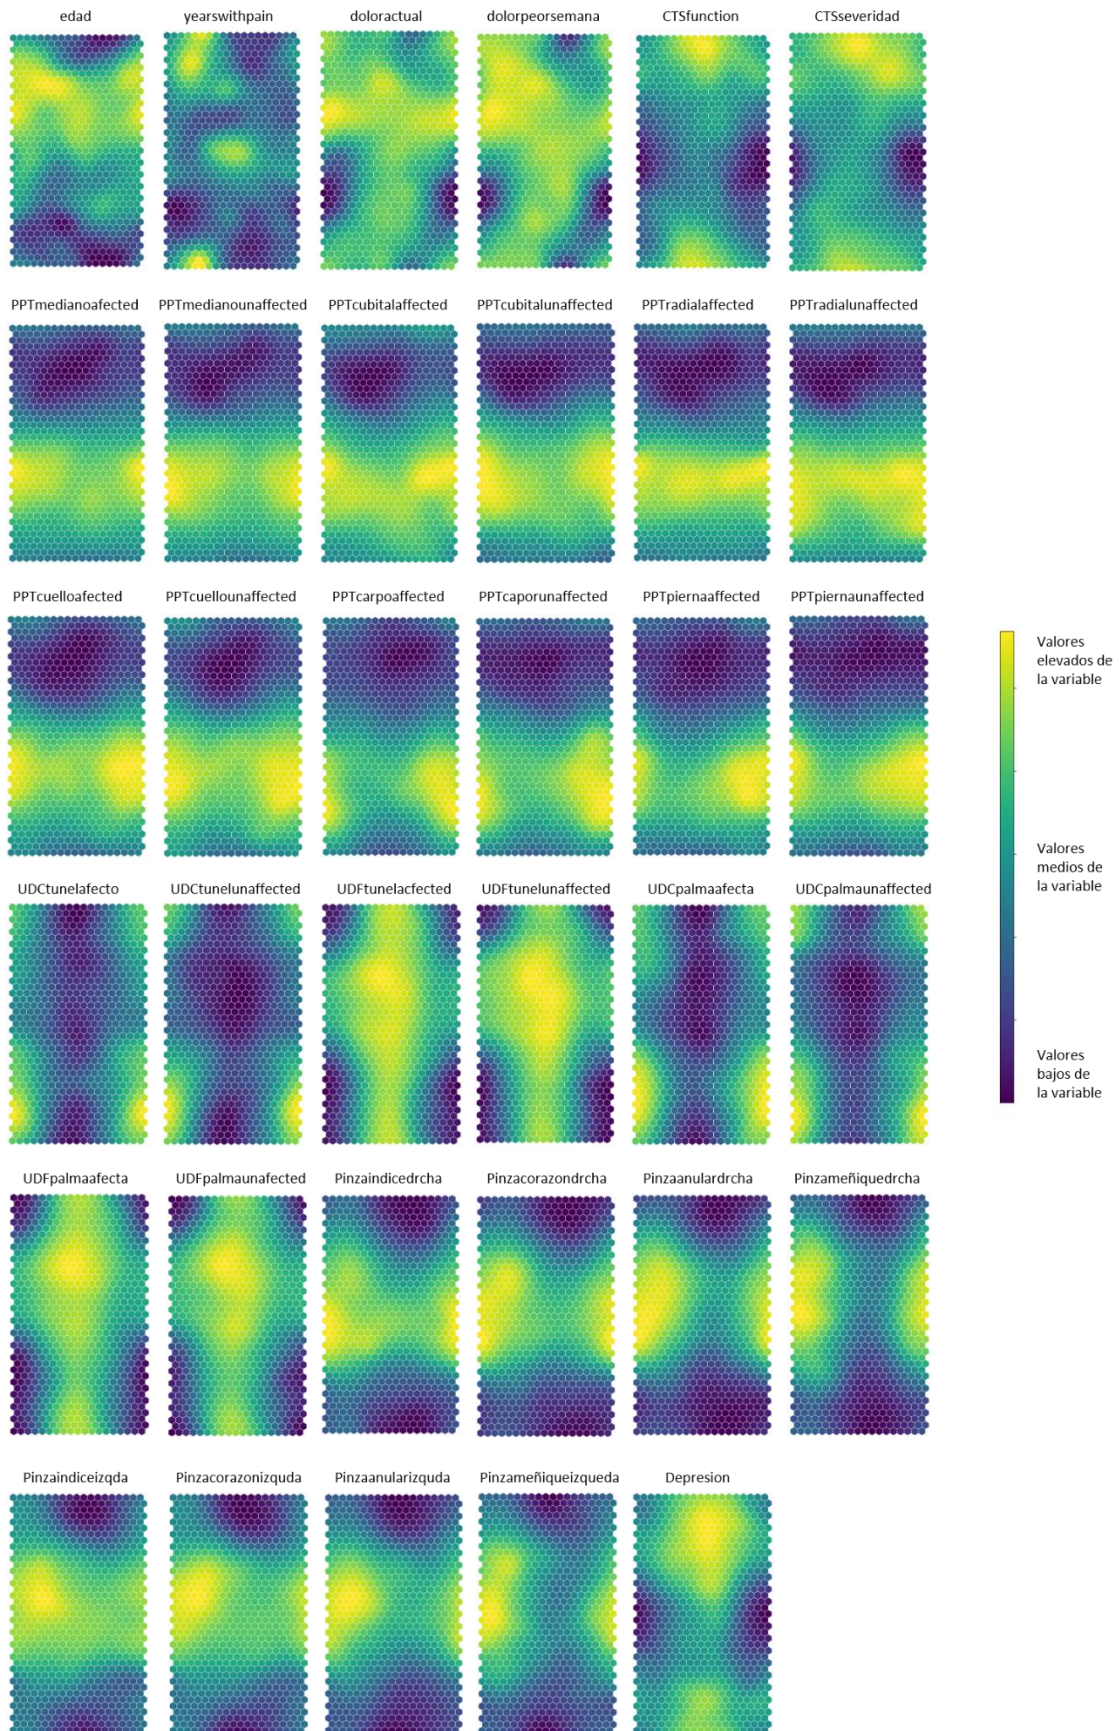


Figura 23. Mapa autoorganizativo de las características del conjunto de datos de pacientes con STC.

Los mapas autoorganizativos de la Figura 23 también muestran que las características relacionadas con el umbral de dolor por calor (UDC) están correlacionadas negativamente con las características de umbral de dolor por frío (UDF). Además, los SOM de los UDC son bastante similares entre sí y opuestos a los SOM de los UDF. Se encuentra también correlación entre los valores de fuerza aplicada en el pinzamiento, independientemente del dedo en el que se registre la medida.

Se pueden diferenciar distintos grupos de pacientes con STC, por ejemplo, en la parte superior de los mapas hay pacientes con peor función y síntomas más graves y con mayor sensibilidad al dolor por presión, es decir, UDP más bajos y menor fuerza de agarre en la prueba de pinzamiento. También puede observarse un grupo de pacientes con una menor severidad de los síntomas y una mejor funcionalidad en los laterales del SOM. Además, estos pacientes muestran una mayor tolerancia al dolor, con un UDP mayor y más fuerza ejercida en el pinzamiento. Esto sugiere que existe relación entre las características clínicas, neurológicas, sensitivas y motoras.

5.3.3. Clústeres obtenidos mediante agrupamiento espectral

Se ha decidido emplear el algoritmo de *clustering* espectral para la obtención de los grupos de pacientes debido a que, en comparación con los algoritmos tradicionales, como *k-means*, el agrupamiento espectral presenta muchas ventajas. Los resultados obtenidos por agrupamiento espectral a menudo superan a los enfoques tradicionales, obteniendo mejores resultados a costa de una mayor carga computacional [59].

En primer lugar, se ha realizado el algoritmo con dos clústeres y se han obtenido 89 pacientes que pertenecen al clúster 1 y 133 que pertenecen al clúster 2.

La Figura 24a muestra un diagrama de dispersión tridimensional de las características de umbral de dolor por presión en el nervio mediano, fuerza de pinzamiento entre el dedo índice y pulgar de la mano derecha y depresión, agrupadas por clúster con diferente color. Se puede apreciar claramente la separación existente entre estos dos grupos de forma visual, lo que indica que estas tres características que evalúan diferentes ambientes de los pacientes como el sensitivo, motor y neurológico, son capaces de separar correctamente estos dos grupos de pacientes. En la Figura 24b, se representa el diagrama de dispersión bidimensional entre ciertas características de los pacientes, características clínicas, neurológicas, sensitivas y motoras. En todas ellas, se puede observar una buena separación de los pacientes en los dos grupos, teniendo en cuenta de las limitaciones de la visualización.

DESARROLLO DE PERFILES DE PACIENTES AFECTADOS POR SÍNDROME DE TÚNEL CARPIANO Y CEFALEA TENSIONAL MEDIANTE EL USO DE TÉCNICAS DE APRENDIZAJE AUTOMÁTICO

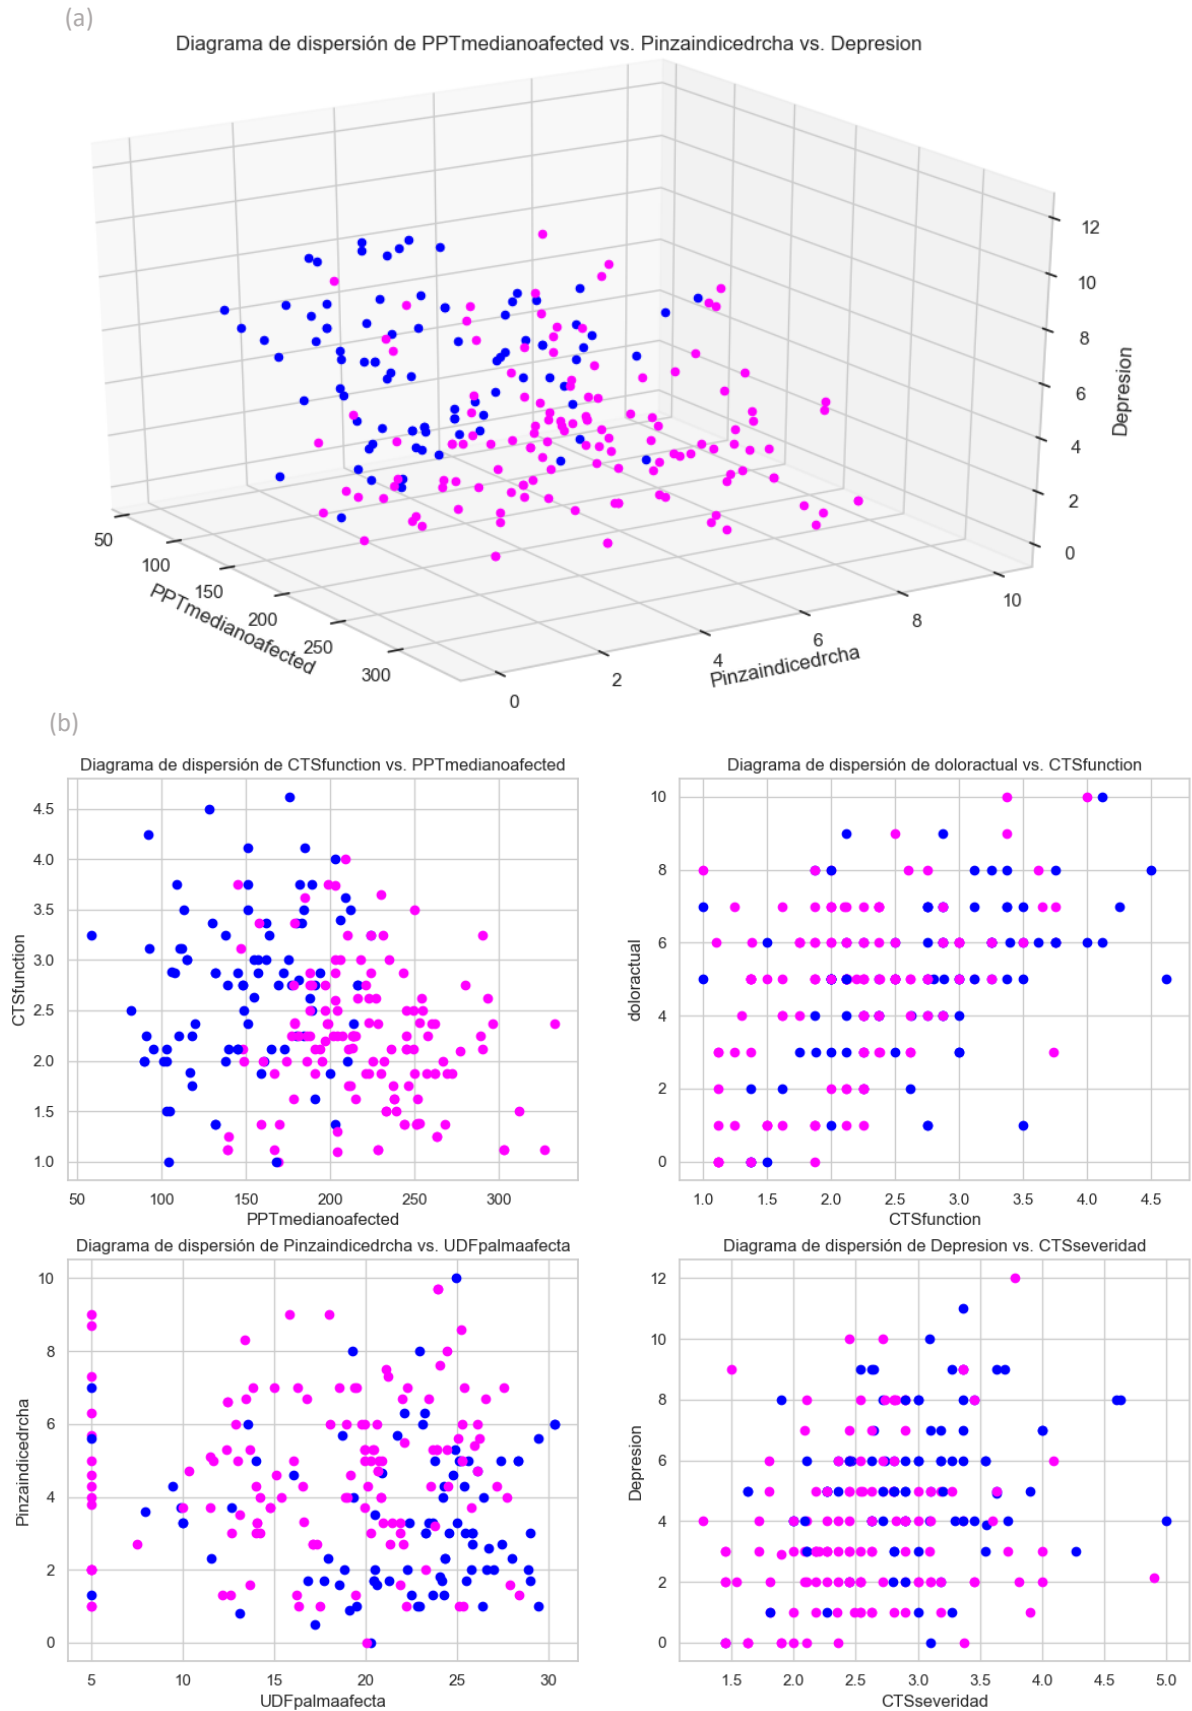


Figura 24. Diagrama de dispersión de características de STC agrupadas según el clúster obtenido.

La Tabla 18 recoge los valores medios y la desviación estándar de las características del conjunto de datos de pacientes con STC agrupadas por clúster obtenido. Es importante tener en cuenta que, al hacer la comparación de esta manera, utilizando medias y desviaciones típicas, se está perdiendo parte de la potencia del método, ya que, el clúster puede tomar cualquier forma y, por lo tanto, al analizar la media, se podría concluir que no hay diferencia entre los grupos, aunque gráficamente si se vean dichas diferencias.

Tabla 18. Valores medios y desviación estándar de las características de STC agrupadas por clúster.

Característica	Clúster 1	Clúster 2
	Media \pm std.	Media \pm std.
edad	46,1 \pm 9,98	45,3 \pm 8,2
yearswithpain	3,5 \pm 2,82	3,1 \pm 2,12
doloractual	5,04 \pm 2,13	4,71 \pm 2,28
dolorpeorsemana	6,87 \pm 2,25	6,62 \pm 2,27
CTSfunction	2,71 \pm 0,78	2,19 \pm 0,67
CTSseveridad	2,96 \pm 0,66	2,56 \pm 0,64
PPTmedianoaffected	149,76 \pm 38,51	221,83 \pm 40,46
PPTmedianounaffected	146,42 \pm 35,35	221,54 \pm 41,07
PPTcubitalaffected	237,7 \pm 72,82	326,63 \pm 56,6
PPTcubitalunaffected	230,56 \pm 52,07	339,04 \pm 56,88
PPTradialaffected	178,53 \pm 47,31	252,49 \pm 53,68
PPTradialunaffected	174,29 \pm 48,98	262,61 \pm 47,81
PPTcuelloaffected	126,35 \pm 29,01	199,59 \pm 40,93
PPTcuellounaffected	128,75 \pm 32,27	198,88 \pm 37,83
PPTcarpoaffected	280,73 \pm 74,53	398,69 \pm 84,9
PPTcaporunaffected	270,14 \pm 62,36	389,57 \pm 74,92
PPTpiernaaffected	270,86 \pm 68,58	364,58 \pm 70,52
PPTpiernaunaffected	256,48 \pm 67,07	362,25 \pm 71,24
UDCtunelafecto	39,22 \pm 2,44	40,16 \pm 2,66
UDCtunelunaffected	39,23 \pm 2,76	40,47 \pm 2,95
UDCpalmaafecta	21,83 \pm 6,54	18,33 \pm 7,14
UDCpalmaunaffected	20,94 \pm 6,63	17,77 \pm 7,38
UDFtunelafecto	39,58 \pm 3,11	40,64 \pm 2,99
UDFtunelunaffected	39,42 \pm 3,0	40,37 \pm 2,86
UDFpalmaafecta	21,72 \pm 6,01	17,67 \pm 6,52
UDFpalmaunaffected	21,31 \pm 6,17	17,67 \pm 6,57
Pinzaindicedrcha	3,38 \pm 1,94	4,63 \pm 2,12
Pinzacorazondrcha	3,24 \pm 2,13	4,27 \pm 2,09
Pinzaanulardrcha	2,02 \pm 1,35	2,38 \pm 1,52
Pinzameñiquedrcha	0,89 \pm 0,76	1,05 \pm 0,77
Pinzaindiceizqda	3,63 \pm 1,89	4,56 \pm 1,71
Pinzacorazonizqda	3,52 \pm 2,14	4,56 \pm 1,73
Pinzaanularizqda	2,12 \pm 1,45	2,83 \pm 1,45
Pinzameñiqueizqueda	0,98 \pm 0,75	1,19 \pm 0,77
Depresion	5,31 \pm 2,33	3,66 \pm 2,53

La Figura 25 muestra los diagramas de cajas de las diferentes características numéricas del STC agrupando los pacientes que corresponden al mismo clúster.

Analizando la Tabla 18 y la Figura 25, se observa que existen diferencias significativas entre los dos grupos en características como la funcionalidad y severidad de los síntomas, en las pruebas de umbral de dolor por presión y en la prueba de pinzamiento de los dedos índice y corazón. Las pruebas de pinzamiento en el resto de los dedos parecen no tener diferencias significativas entre los dos grupos.

Cabe destacar que las técnicas de aprendizaje no supervisado han detectado un grupo de pacientes con peor función y síntomas más graves, que presentan una mayor sensibilidad al dolor por presión, es decir, UDP más bajos, mayor sensibilidad al frío y al calor, menor fuerza de agarre en la prueba de pinzamiento y valores más elevados de depresión.

Por otro lado, el segundo grupo de pacientes obtenido muestra una menor severidad de los síntomas, mayor funcionalidad, con una mejor tolerancia a dolor, UDP mayor, mayor fuerza ejercida en el pinzamiento de los dedos índice y corazón con el pulgar y valores más bajos de depresión.

Estos resultados coinciden con los grupos de pacientes observados empleando SOM, por lo que está bastante claro que existen relaciones entre características clínicas, neurológicas, sensitivas y motoras en pacientes aquejados de STC.

DESARROLLO DE PERFILES DE PACIENTES AFECTADOS POR SÍNDROME DE TÚNEL CARPIANO Y CEFALEA TENSIONAL MEDIANTE EL USO DE TÉCNICAS DE APRENDIZAJE AUTOMÁTICO

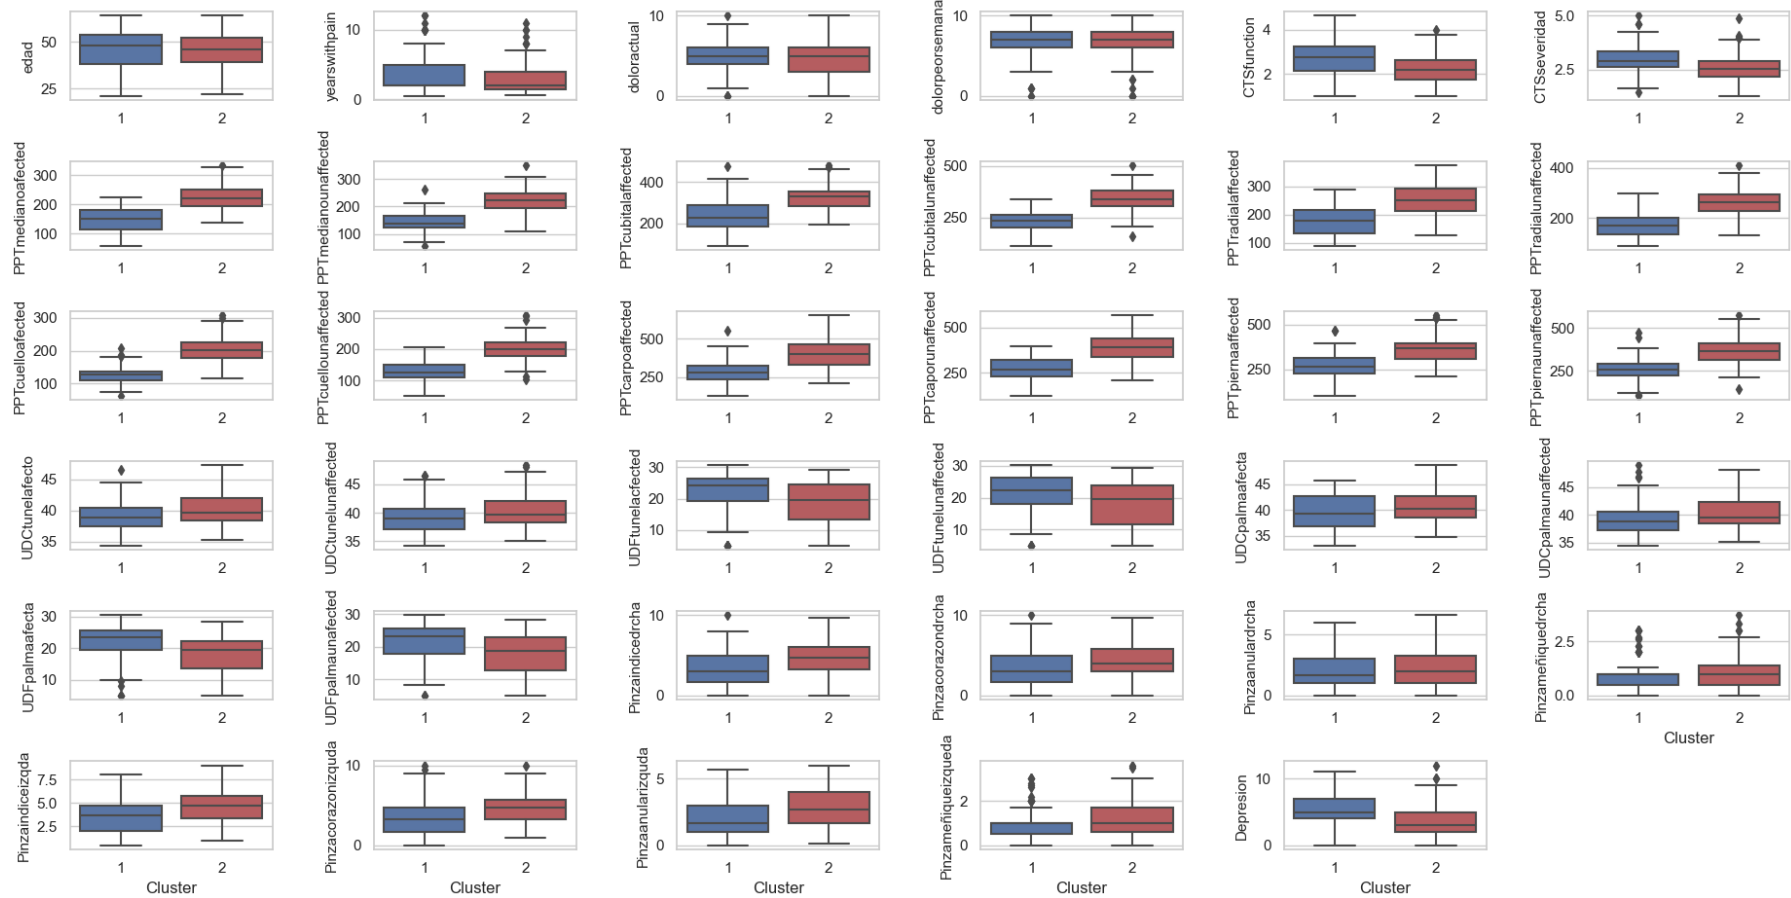


Figura 25. Diagrama de cajas de características de STC según el clúster al que pertenecen.


Por otro lado, se ha probado a realizar el agrupamiento empleando tres grupos y se han obtenido 46 pacientes que pertenecen al clúster 1, 102 pacientes que pertenecen al clúster 2 y 74 que pertenecen al clúster 3.

La Figura 26a muestra un diagrama de dispersión tridimensional de las características de umbral de presión en el nervio mediano, fuerza de pinzamiento entre el dedo índice y pulgar de la mano derecha y depresión, agrupadas por clúster con diferente color. Se puede apreciar, al igual que ocurre en el caso anterior, que existe separación entre estos tres grupos de forma visual. Si se realiza la comparación con la Figura 24a, cabe destacar que el grupo representado en color magenta es similar al obtenido con el modelo de dos clústeres, y la mayoría de los puntos de los clústeres azul y verde de la Figura 26a provienen de dividir el clúster azul de la Figura 24a. Esto sugiere que las tres características que evalúan diferentes ambientes de los pacientes influyen en la separación de los datos en tres grupos de pacientes.

En la Figura 26b, se representa el diagrama de dispersión bidimensional entre características de los pacientes. Se puede comprobar que las características sensitivas y motoras, como el umbral de dolor al frío en la palma afectada y el pinzamiento en el dedo índice de la mano derecha, muestran grandes diferencias entre los tres clústeres obtenidos. Sin embargo, si solamente se emplean características clínicas, como la depresión o la funcionalidad, no se observan diferencias apreciables entre los distintos grupos.

DESARROLLO DE PERFILES DE PACIENTES AFECTADOS POR SÍNDROME DE TÚNEL CARPIANO Y CEFALEA TENSIONAL MEDIANTE EL USO DE TÉCNICAS DE APRENDIZAJE AUTOMÁTICO

(a) Diagrama de dispersión de PPTmedianoafected vs. Pinzaindicedrcha vs. Depression



(b) Diagrama de dispersión de CTSfunction vs. PPTmedianoafected


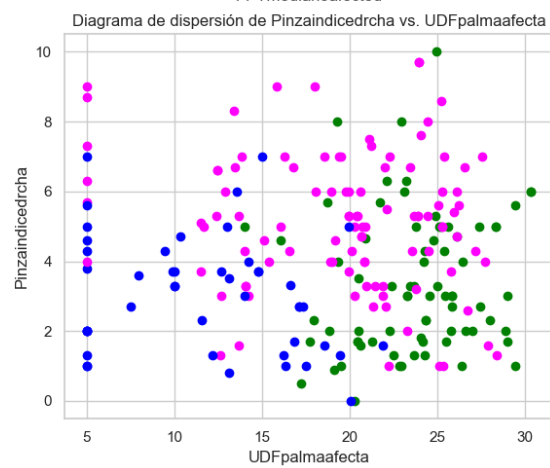
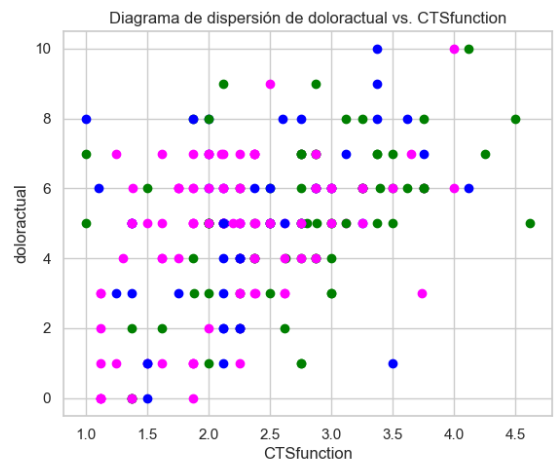



Figura 26. Diagrama de dispersión de características de STC agrupadas según el clúster obtenido.

DESARROLLO DE PERFILES DE PACIENTES AFECTADOS POR SÍNDROME DE TÚNEL CARIPIANO Y
CEFALEA TENSIONAL MEDIANTE EL USO DE TÉCNICAS DE APRENDIZAJE AUTOMÁTICO

La Tabla 19 recoge los valores medios y desviación estándar de las características del conjunto de datos de pacientes con STC agrupadas por clúster obtenido. La Figura 27 muestra los diagramas de cajas de las diferentes características numéricas del STC, agrupando los pacientes según el clúster al que pertenecen.

Tabla 19. Valores medios y desviación estándar de las características de STC agrupadas por clúster.

Característica	Clúster 1	Clúster 2	Clúster 3
	Media ± std.	Media ± std.	Media ± std.
edad	49,22 ± 6,47	44,43 ± 8,58	45,03 ± 10,2
yearswithpain	3,12 ± 2,11	3,19 ± 2,19	3,44 ± 2,89
doloractual	4,98 ± 2,44	4,57 ± 2,18	5,14 ± 2,13
dolorpeorsemana	6,85 ± 1,95	6,52 ± 2,39	6,92 ± 2,26
CTSfunction	2,35 ± 0,73	2,19 ± 0,69	2,72 ± 0,77
CTSseveridad	2,75 ± 0,59	2,53 ± 0,66	2,97 ± 0,68
PPTmedianoaffected	187,89 ± 43,37	226,15 ± 41,69	150,31 ± 39,73
PPTmedianounaffected	190,93 ± 50,05	223,98 ± 40,97	146,87 ± 36,31
PPTcubitalaffected	293,19 ± 61,64	333,84 ± 55,01	230,52 ± 71,8
PPTcubitalunaffected	287,4 ± 71,04	347,92 ± 50,12	228,43 ± 51,83
PPTradialaffected	218,28 ± 54,39	258,16 ± 53,82	177,0 ± 46,77
PPTradialunaffected	232,5 ± 63,93	263,1 ± 46,99	174,43 ± 50,05
PPTcuelloaffected	174,68 ± 47,74	200,35 ± 41,55	125,94 ± 29,99
PPTcuellounaffected	179,85 ± 47,53	197,72 ± 37,95	127,97 ± 33,57
PPTcarpoaffected	394,45 ± 107,5	389,47 ± 76,99	272,18 ± 70,8
PPTcaporunaffected	366,47 ± 104,15	384,78 ± 66,85	266,89 ± 61,1
PPTpiernaaffected	342,79 ± 97,13	363,3 ± 61,78	267,16 ± 65,98
PPTpiernaunaffected	327,92 ± 95,68	363,32 ± 64,2	254,89 ± 66,84
UDCtunelafecto	41,79 ± 2,76	39,56 ± 2,37	38,83 ± 2,13
UDCtunelunaffected	42,57 ± 3,22	39,78 ± 2,43	38,63 ± 2,32
UDCpalmaafecta	11,96 ± 5,82	20,48 ± 6,21	23,54 ± 4,98
UDCpalmaunaffected	9,93 ± 5,58	20,24 ± 5,85	23,05 ± 4,64
UDFtunelafecto	42,81 ± 2,28	39,92 ± 2,76	39,0 ± 3,01
UDFtunelunaffected	42,81 ± 3,12	39,68 ± 2,48	38,68 ± 2,21
UDFpalmaafecta	11,68 ± 5,28	19,49 ± 5,78	23,75 ± 3,49
UDFpalmaunaffected	11,18 ± 5,09	19,67 ± 5,47	23,32 ± 4,25
Pinzaindicedrcha	3,06 ± 1,67	5,16 ± 1,98	3,38 ± 1,98
Pinzacorazondrcha	2,38 ± 1,47	4,87 ± 1,9	3,37 ± 2,18
Pinzaanulardrcha	1,39 ± 1,0	2,74 ± 1,5	2,06 ± 1,38
Pinzameñiqueidrcha	0,82 ± 0,6	1,16 ± 0,8	0,87 ± 0,77
Pinzaindiceizqda	3,26 ± 1,52	5,05 ± 1,46	3,57 ± 1,97
Pinzacorazonizqda	3,26 ± 1,47	5,05 ± 1,56	3,43 ± 2,22
Pinzaanularizqda	1,77 ± 0,9	3,19 ± 1,41	2,14 ± 1,52
Pinzameñiqueizqueda	0,91 ± 0,58	1,29 ± 0,79	0,97 ± 0,79
Depresion	3,8 ± 2,74	3,62 ± 2,47	5,62 ± 2,13

Analizando la Tabla 19 y la Figura 27, se encuentran las diferencias más significativas entre los tres grupos en los resultados de las pruebas sensitivas de umbral de dolor con frío y calor.

Sin embargo, en características clínicas como la funcionalidad y severidad de los síntomas, en las pruebas de umbral de dolor por presión o en la prueba de pinzamiento de los dedos índice y corazón, existen diferencias entre dos grupos, pero el tercer grupo muestra valores similares a uno de los otros dos grupos.

De los tres grupos, cabe destacar que existen dos grupos de pacientes detectados aplicando dos clústeres y se añade un nuevo grupo.

Es importante destacar que las técnicas de aprendizaje no supervisado han detectado un grupo de pacientes con peor función y síntomas más graves, que presentan una mayor sensibilidad al dolor por presión, es decir, UDP más bajos, mayor sensibilidad al frío y al calor, menor fuerza de agarre en la prueba de pinzamiento y valores más elevados de depresión.

Por otro lado, el segundo grupo de pacientes obtenido muestra una severidad menor de los síntomas, mayor funcionalidad, con una menor sensibilidad al dolor, UDP mayor, mayor fuerza ejercida en el pinzamiento de los dedos índice y corazón con el pulgar y valores más bajos de depresión.

Por último, el tercer grupo detectado presenta una severidad de los síntomas y funcionalidad intermedia entre los dos grupos anteriores, con menor sensibilidad al dolor por presión, la mejor tolerancia ante las pruebas de frío y calor, pero con una fuerza ejercida en las pruebas de pinzamiento muy baja y valores bajos de depresión.

DESARROLLO DE PERFILES DE PACIENTES AFECTADOS POR SÍNDROME DE TÚNEL CARPIANO Y CEFALEA TENSIONAL MEDIANTE EL USO DE TÉCNICAS DE APRENDIZAJE AUTOMÁTICO

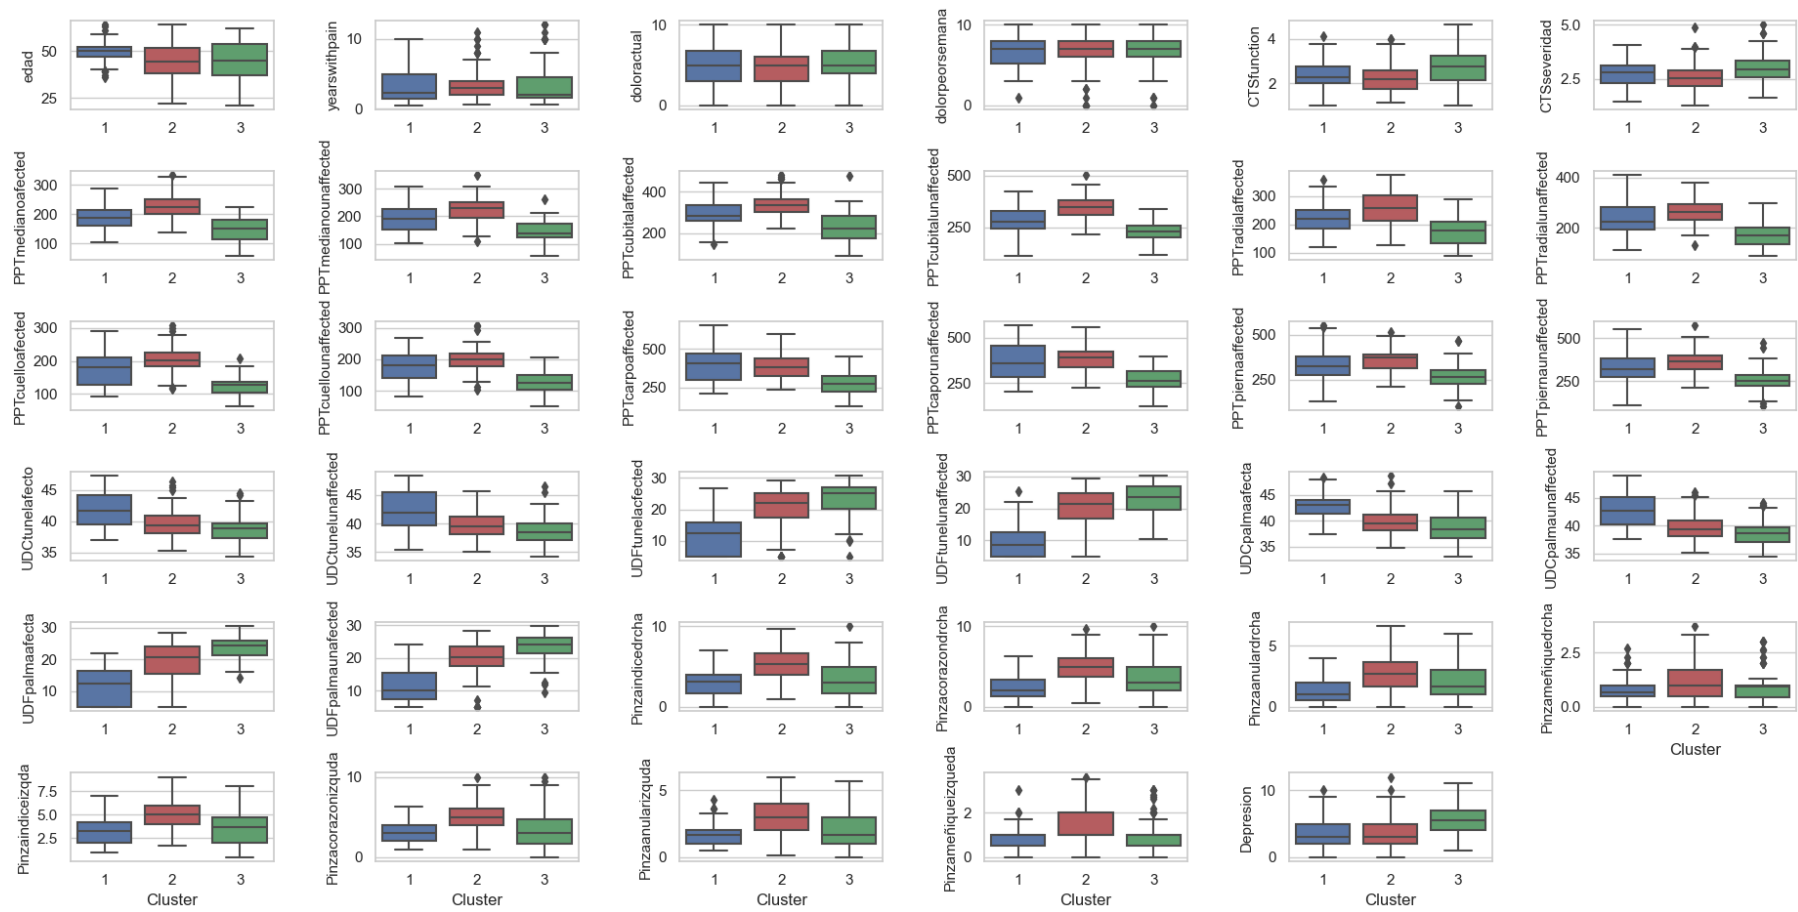


Figura 27. Diagrama de cajas de características de STC según el clúster al que pertenecen.

5.4. CLÚSTERES EN CONJUNTO DE DATOS DE CEFALEA TENSIONAL

En esta sección se tratarán los resultados obtenidos tras la aplicación de distintos algoritmos de agrupamiento para el conjunto de datos de pacientes aquejados de Cefalea Tensional.

5.4.1. Obtención del número de clústeres

La Tabla 20 muestra los valores obtenidos de las distintas métricas de desempeño en función del número de clústeres elegido en los métodos que requieren de su selección previa. En primer lugar, es destacable, al igual que ocurría en el conjunto de datos anterior, si se comparan los valores del índice de *Dunn*, se observan mejores valores cuanto mayor es el número de clústeres en el caso de los algoritmos *k-means* y algomerativo. Esto es algo que no concuerda con el resto de los valores de los índices, por lo que, se intuye que el valor de este índice no es representativo en estos casos. En general, las métricas presentan valores muy similares independientemente de la técnica de agrupamiento empleada.

Si se contrastan los índices obtenidos en función del número de clústeres, se puede probar que tres es el número de clústeres que mejores índices obtiene, aunque no está muy lejano de las métricas obtenidas para dos y cuatro clústeres.

Tabla 20. Métricas de desempeño obtenidas por diferentes algoritmos de agrupamiento en función del número de clústeres elegido.

Algoritmo	Métrica	Número de clústeres (k)						
		K=2	K=3	K=4	K=5	K=6	K=7	K=8
k-means	<i>Índice de Dunn</i>	0,2362	0,2623	0,2871	0,306	0,3089	0,3057	0,3337
	<i>Índice Calinski Harabasz</i>	41,7835	35,7508	30,3561	27,0023	23,8153	21,6012	19,1711
	<i>Coefficiente de Silueta</i>	0,1566	0,1345	0,1254	0,1156	0,0992	0,0985	0,082
	<i>Índice Davies Bouldin</i>	2,1215	1,9294	2,2171	2,2846	2,26	2,3556	2,2825
Clustering aglomerativo	<i>Índice de Dunn</i>	0,2454	0,2454	0,254	0,2898	0,2898	0,2916	0,2916
	<i>Índice Calinski Harabasz</i>	34,0619	30,9531	26,2701	23,0187	20,7508	19,1716	17,7412
	<i>Coefficiente de Silueta</i>	0,1233	0,1102	0,1016	0,0956	0,0896	0,0902	0,0867
	<i>Índice Davies Bouldin</i>	2,4174	1,9808	2,1332	2,2179	2,2994	2,4985	2,4076

DESARROLLO DE PERFILES DE PACIENTES AFECTADOS POR SÍNDROME DE TÚNEL CARIANO Y CEFALEA TENSIONAL MEDIANTE EL USO DE TÉCNICAS DE APRENDIZAJE AUTOMÁTICO

Clustering espectral	<i>Índice de Dunn</i>	0,2405	0,2841	0,3053	0,2916	0,2882	0,2704	0,2633
	<i>Índice Calinski Harabasz</i>	22,3617	34,686	28,7578	25,9031	22,167	19,9014	18,1121
	<i>Coefficiente de Silueta</i>	0,0778	0,1308	0,1236	0,1122	0,0859	0,0732	0,069
	<i>Índice Davies Bouldin</i>	2,2504	1,9476	2,1017	2,1607	2,3444	2,3116	2,2093

En la Tabla 21, se muestran los valores de las métricas obtenidas y el número de clústeres para el método de agrupamiento mediante *Affinity Propagation*, en función del valor de preferencia. El algoritmo *MeanShift* se ha empleado también para la obtención de clústeres, pero los resultados modelan la mayor parte de las muestras en el mismo grupo y se obtienen otros grupos con una o dos muestras solamente, lo cual aporta resultados sin relevancia. Es por esto por lo que el algoritmo *MeanShift* se ha descartado en el estudio.

En este caso todos los índices muestran mejores valores de métricas para una preferencia de -650, que genera 3 clústeres potenciales. La siguiente preferencia que obtiene mejores valores en las métricas es -250, que proporciona un total de 5 clústeres. Los valores de métricas obtenidos son similares a los obtenidos con los métodos anteriores.

Tabla 21. Métricas de desempeño y número de clústeres obtenidos por el algoritmo de *Affinity Propagation* en función del valor de preferencia.

	Preferencia						
	-750	-650	-450	-250	-150	-120	-100
<i>Número de clústeres</i>	2	3	4	5	6	7	9
<i>Índice de Dunn</i>	0,2233	0,2552	0,2658	0,2852	0,281	0,3174	0,3362
<i>Índice Calinski Harabasz</i>	22,5371	29,9688	25,7031	23,9338	20,888	18,7752	15,2364
<i>Coefficiente de Silueta</i>	0,0918	0,1176	0,0972	0,1042	0,0882	0,0766	0,0746
<i>Índice Davies Bouldin</i>	2,5187	2,2524	2,4661	2,2107	2,4125	2,481	2,5443

Con el objetivo de obtener información adicional antes de realizar los grupos, se ha realizado un dendrograma, que se puede observar en la Figura 28 aplicando el algoritmo de *clustering* aglomerativo sobre el conjunto de datos de CT.

En el dendrograma, se pueden observar los diferentes clústeres que se van formando en cada nivel, dependiendo de las distancias entre los datos. Así, en la parte superior del diagrama de árbol o dendrograma hay solamente un clúster, que es el obtenido tras la unión de todos los clústeres que ha ido realizando el algoritmo. El gráfico indica que una posible solución al problema consiste en emplear dos o tres clústeres para agrupar los datos.




Figura 28. Dendrograma del *clustering* aglomerativo aplicado al conjunto de datos de CT.

5.4.2. Mapas autoorganizativos

La Figura 29 muestra la distancia media entre los parámetros de cada nodo y sus vecinos empleando un mapa de color. Los registros similares se agrupan en las áreas azul oscuro, mientras que las áreas amarillas actúan como barreras que separan los diferentes grupos potenciales. Es una técnica que permite identificar clústeres de forma gráfica.




Figura 29. Mapa autoorganizativo de la diferencia de pesos en el conjunto de datos de CT.

En el gráfico de la Figura 29, pueden observarse dos zonas de color azul intenso en el centro, separadas por zonas de color verdoso. Además, se pueden distinguir otras dos zonas en las esquinas superior izquierda y derecha del gráfico SOM. Esto podría dar un total de dos, tres o cuatro clústeres potenciales en el conjunto de datos de pacientes con CT. Si se combina esta información con la obtenida anteriormente, se han decidido emplear dos y tres clústeres como posible solución al problema.

A parte de este gráfico de diferencia de pesos, se ha representado el mapa de colores de la componente del vector de pesos de cada característica incluida en el estudio (Figura 30). Cabe destacar que todos los SOM de las características de los umbrales de dolor por presión (UDP) y la presión del *roller* en el umbral de dolor son muy similares. Las zonas del SOM donde el UDP en la zona temporal tiene valores altos, en la zona central inferior, aunque el resto de las características relacionadas con UDP y el *roller* también tienen valores altos. Lo mismo ocurre en los lugares del SOM donde el UDP temporal tiene valores bajos, las características relacionadas con umbrales de dolor y el *roller* también tienen valores bajos.

Por lo tanto, estos mapas autoorganizativos demuestran visualmente que las características de umbral de dolor por presión y el valor del *roller* están correlacionadas de manera muy positiva, independientemente de la zona testada. Además, existe una relación inversa entre los UDP y los puntos gatillo activos y latentes. Se observa que los valores menores de UDP (mayor sensibilidad) se asocian con un mayor número de puntos gatillo, y los valores mayores de UDP con menor número de puntos gatillo.

Algo similar ocurre con las características de estado emocional y físico relativas a la escala HDI, la calidad de sueño global y la depresión relativa a la escala HADS, ya que se obtiene una correlación entre dichas variables muy positiva. Además, es importante resaltar que estas características están correlacionadas negativamente con las características relativas a la escala SF-36. Donde los valores de estado emocional son elevados (mayor incapacidad emocional autopercebida por la enfermedad), menores son los valores de función física, por ejemplo, ya que la escala SF-36 indica mayor incapacidad en valores pequeños. Se observa una relación entre la valoración del dolor, la frecuencia mensual y duración de los episodios.

Analizando la Figura 30, se pueden identificar diferentes grupos de pacientes con CT. Un grupo de pacientes situados en la zona central del SOM, son pacientes que presentan un mayor dolor, duración y frecuencia de las cefaleas, con número de puntos gatillo medio y, por tanto una tolerancia media a la presión. A su vez, tienen malos valores de estado emocional, calidad de sueño, depresión y escala SF-36.

También puede observarse un grupo de pacientes en las esquinas del SOM, pacientes con bajo dolor, duración y frecuencia de las cefaleas, un gran número de puntos gatillo latentes, activos y totales que coinciden con la zona del SOM donde los umbrales de dolor por presión son menores, por lo que tienen una menor tolerancia al dolor. Estos presentan buenos valores de estado emocional, calidad de sueño, depresión y escala SF-36.

En la zona central inferior, existe otro grupo de pacientes con número pequeño de puntos gatillo que muestran una mayor tolerancia al dolor con umbrales de dolor por presión mayores. Tienen unos valores medios de estado emocional, calidad de sueño, depresión y escala SF-36. Esto implica que existen ciertas relaciones entre las características clínicas, neurológicas y sensitivas en pacientes con CT.

DESARROLLO DE PERFILES DE PACIENTES AFECTADOS POR SÍNDROME DE TÚNEL CARIANO Y
CEFALEA TENSIONAL MEDIANTE EL USO DE TÉCNICAS DE APRENDIZAJE AUTOMÁTICO

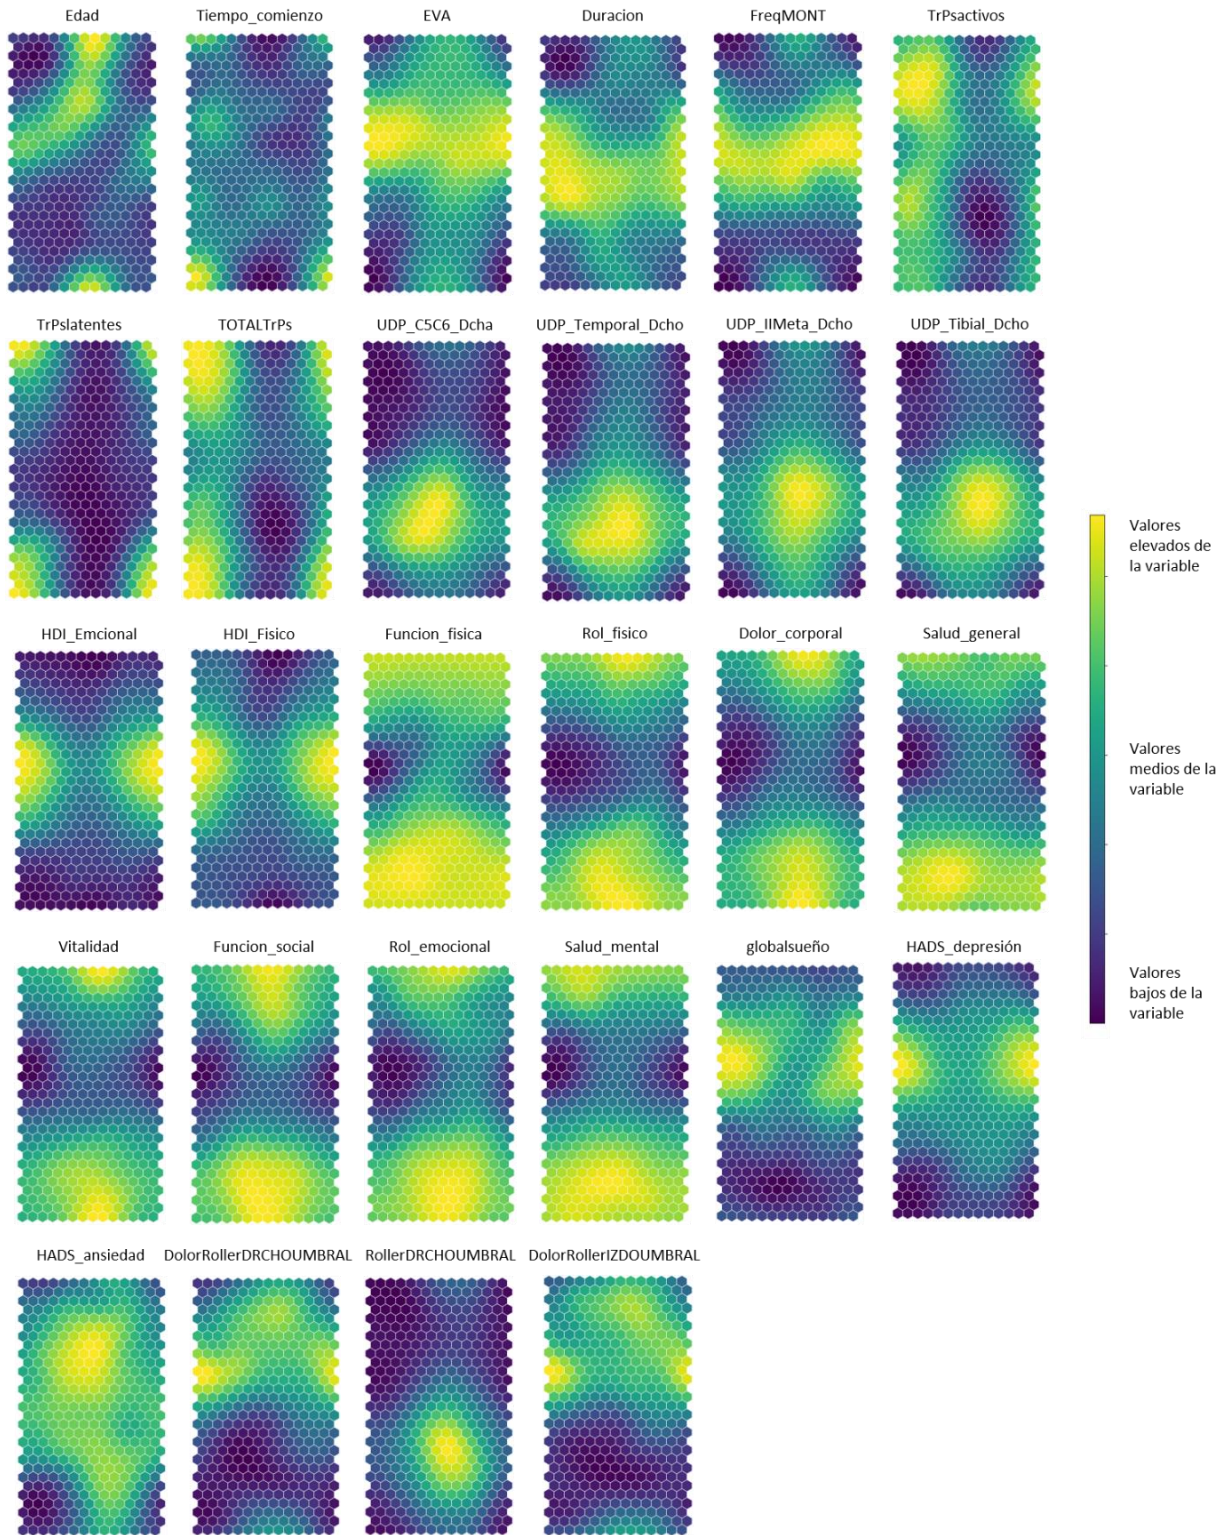


Figura 30. Mapa autoorganizativo de las características del conjunto de datos de pacientes con CT.

5.4.3. Clústeres obtenidos mediante agrupamiento espectral

Se ha decidido emplear el algoritmo de *clustering* espectral para la obtención de los grupos de pacientes debido a lo expuesto en la sección anterior. Además, de esta forma, se emplea la misma técnica de agrupamiento para ambos conjuntos de datos.


En primer lugar, se ha realizado el algoritmo con dos clústeres y se han obtenido 162 pacientes que pertenecen al clúster 1 y 46 que pertenecen al clúster 2.

La Figura 31a muestra un diagrama de dispersión tridimensional de las características de frecuencia mensual de los episodios de cefaleas, umbral de dolor por presión en el lóbulo temporal y depresión medida con la escala HADS, agrupadas por clúster con diferente color. Las formas indican si el CT es frecuente o crónico, representándose con un círculo y un triángulo respectivamente. Se puede apreciar claramente la separación existente entre estos dos grupos de forma visual, lo que indica que estas tres características que evalúan diferentes ambientes de los pacientes como el sensitivo, el grado de cefalea que está relacionado con la frecuencia mensual y el plano neurológico, son capaces de separar correctamente estos dos grupos de pacientes. Además, si se analiza el tipo de CT presente en cada clúster, el algoritmo ha separado en un clúster pacientes solamente con CT crónica (magenta) y en el otro clúster pacientes con ambos grados de CT.

En la Figura 31b, se representa el diagrama de dispersión bidimensional entre ciertas características de los pacientes, características clínicas, neurológicas y sensitivas. En todas ellas, se puede observar una buena separación de los pacientes en los dos grupos, teniendo en cuenta de las limitaciones de la visualización.

DESARROLLO DE PERFILES DE PACIENTES AFECTADOS POR SÍNDROME DE TÚNEL CARIANO Y CEFALEA TENSIONAL MEDIANTE EL USO DE TÉCNICAS DE APRENDIZAJE AUTOMÁTICO

(a) Diagrama de dispersión de FreqMONT vs. UDP_Temporal_Dcho vs. HADS_depresión



(b)

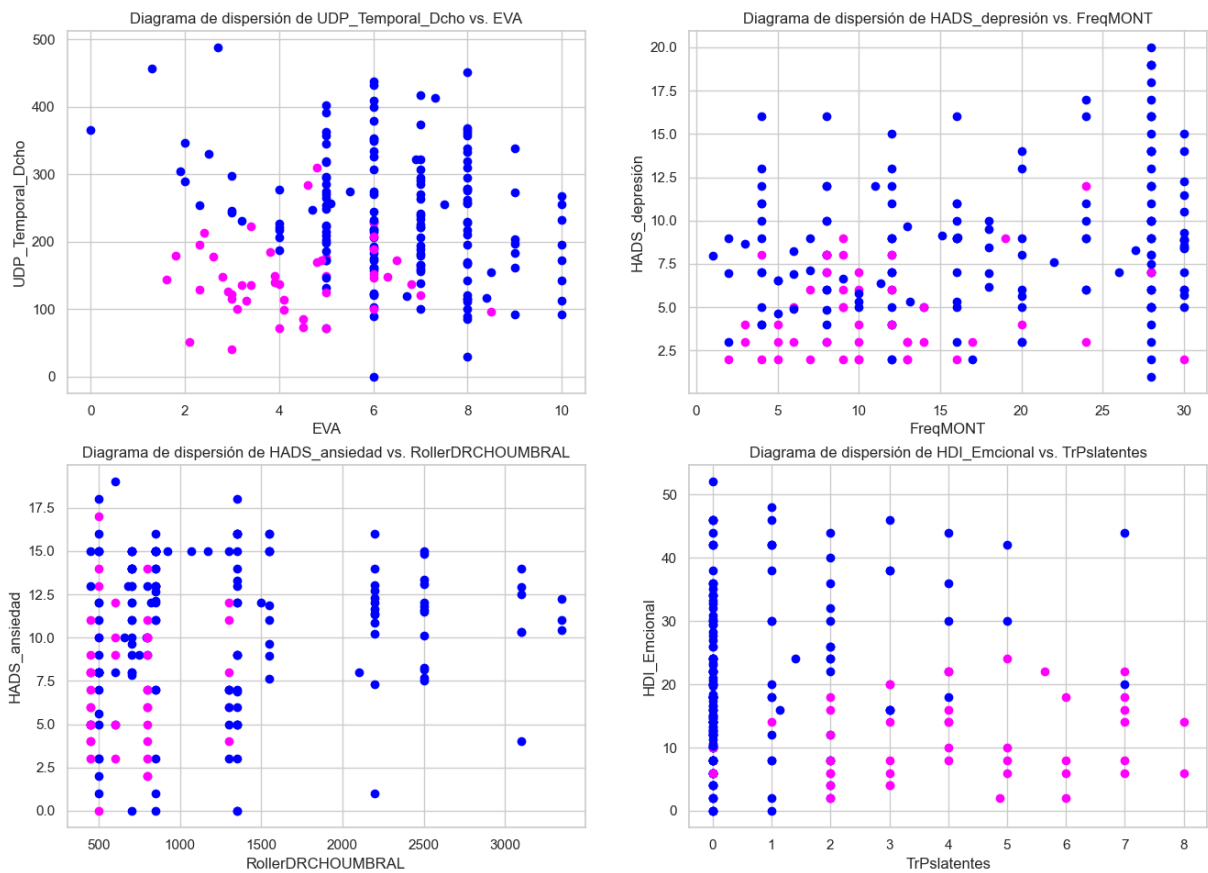


Figura 31. Diagrama de dispersión de características de CT agrupadas según el clúster obtenido.

La Tabla 22 recoge los valores medios y la desviación estándar de las características del conjunto de datos de pacientes con CT agrupadas por clúster obtenido, de igual forma, la Figura 32 muestra los diagramas de cajas de las variables cuantitativas agrupadas por clúster.

Tabla 22. Valores medios y desviación estándar de las características de CT agrupadas por clúster.

Característica	Clúster 1	Clúster 2
	Media \pm std.	Media \pm std.
Edad	46,4 \pm 14,7	38,63 \pm 11,21
Tiempo_comienzo	8,95 \pm 10,0	12,61 \pm 10,6
EVA	6,42 \pm 1,88	4,35 \pm 1,6
Duracion	8,04 \pm 4,0	4,74 \pm 3,13
FreqMONT	18,38 \pm 9,45	11,07 \pm 6,32
TrPsactivos	4,27 \pm 2,99	5,96 \pm 2,34
TrPslatentes	0,64 \pm 1,3	4,1 \pm 2,06
TOTALTrPs	4,96 \pm 3,28	10,28 \pm 0,96
UDP_C5C6_Dcha	243,58 \pm 120,26	153,05 \pm 69,65
UDP_Temporal_Dcho	240,23 \pm 92,89	146,15 \pm 54,38
UDP_IIMeta_Dcho	291,77 \pm 98,68	154,77 \pm 55,76
UDP_Tibial_Dcho	458,13 \pm 185,18	279,27 \pm 137,55
HDI_Emocional	21,2 \pm 12,9	11,91 \pm 6,45
HDI_Fisico	23,57 \pm 12,18	20,0 \pm 7,92
Funcion_fisica	76,74 \pm 25,64	88,15 \pm 9,15
Rol_fisico	48,67 \pm 41,37	62,5 \pm 33,23
Dolor_corporal	50,97 \pm 25,59	50,57 \pm 12,77
Salud_general	53,77 \pm 22,83	65,0 \pm 17,06
Vitalidad	48,1 \pm 24,3	50,98 \pm 13,11
Funcion_social	65,82 \pm 27,25	68,63 \pm 16,99
Rol_emocional	61,69 \pm 42,11	67,26 \pm 35,43
Salud_mental	54,96 \pm 22,54	67,95 \pm 16,55
globalsueño	8,24 \pm 4,52	6,39 \pm 2,66
HADS_depresión	8,78 \pm 3,99	4,65 \pm 2,51
HADS_ansiedad	10,72 \pm 4,22	7,7 \pm 3,81
RollerDRCHOUMBRAL	1280,31 \pm 773,33	702,17 \pm 276,28
DolorRollerDRCHOUMBRAL	3,16 \pm 1,8	2,33 \pm 1,38
DolorRollerIZDOUMBRAL	3,05 \pm 1,77	2,54 \pm 1,78

Analizando la Tabla 22 y la Figura 32, se puede extraer un grupo de pacientes con mayor dolor, duración y frecuencia mensual de las cefaleas y, por lo general, menor número de puntos gatillo activos y latentes, lo que provoca una mayor tolerancia a las pruebas sensitivas de umbral de dolor por presión. Este grupo de pacientes además tiene una peor calidad de sueño, un mayor grado de depresión y ansiedad, con una percepción mala de la salud emocional.

El otro grupo obtenido de pacientes obtenido tiene menor dolor, duración y frecuencia de las cefaleas, con un mayor número de puntos gatillo activos y latentes y menor tolerancia a las pruebas de presión. Al contrario que el otro grupo de pacientes, este grupo presenta una mejor calidad de sueño, valores menores de depresión y ansiedad con una percepción buena de su salud emocional. En cuanto a la valoración psicométrica realizada con el test SF-36, no se encuentran diferencias significativas en los resultados entre los dos grupos de pacientes encontrados.

DESARROLLO DE PERFILES DE PACIENTES AFECTADOS POR SÍNDROME DE TÚNEL CARPIANO Y CEFALEA TENSIONAL MEDIANTE EL USO DE TÉCNICAS DE APRENDIZAJE AUTOMÁTICO

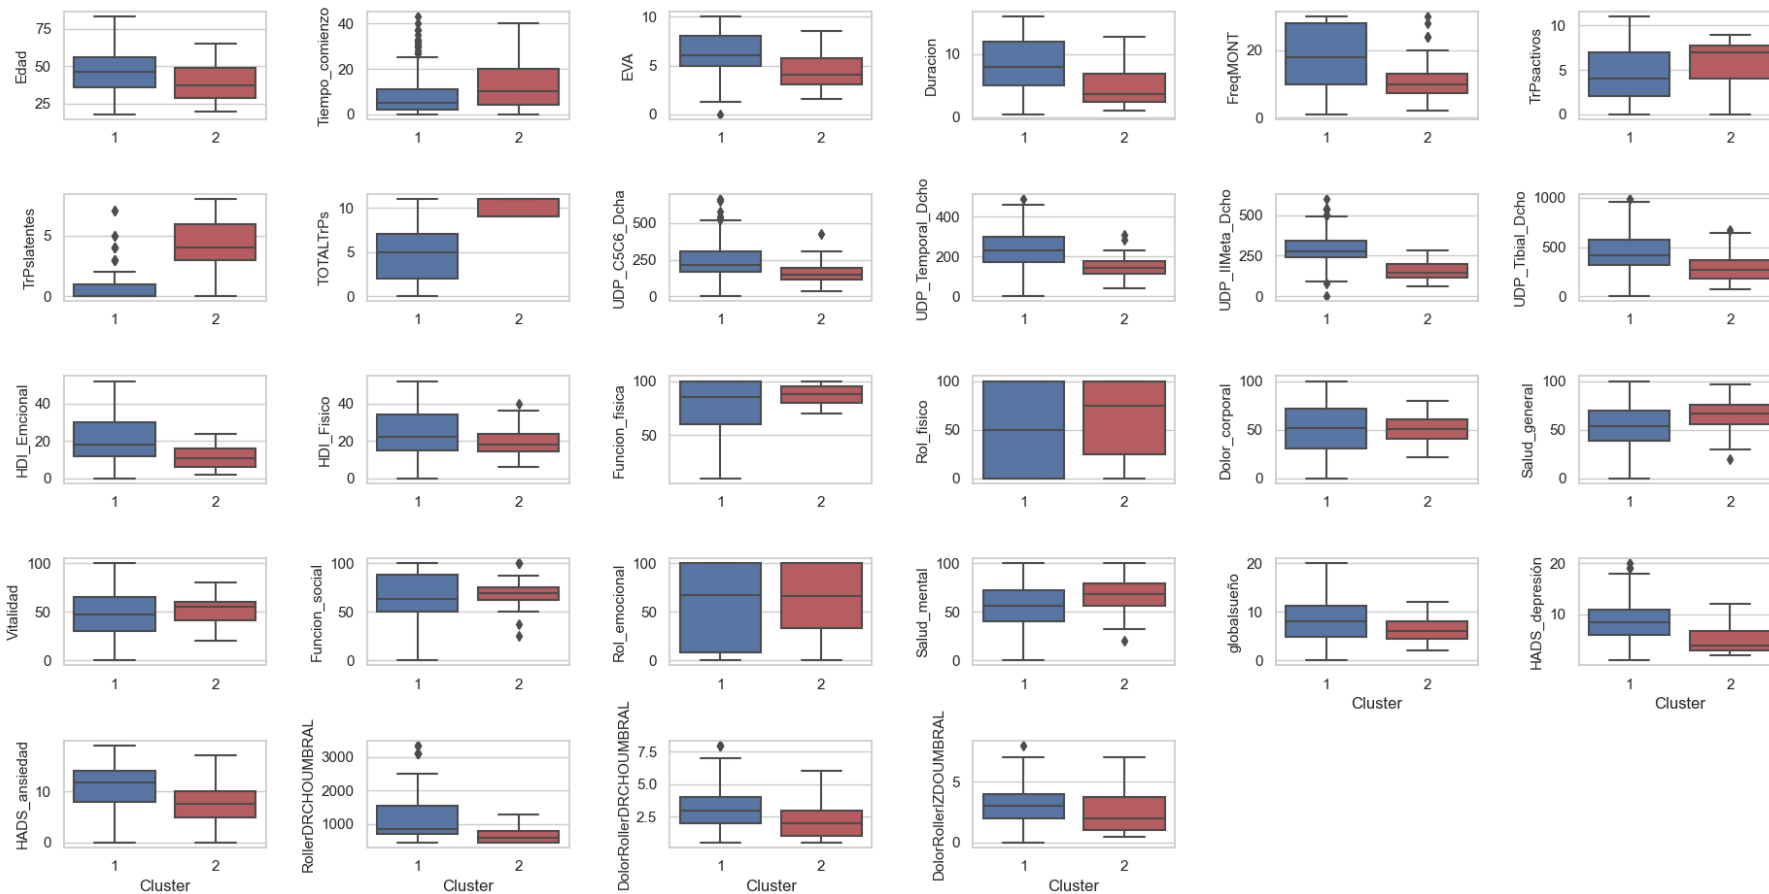


Figura 32. Diagrama de cajas de características de CT según el clúster al que pertenecen.


En segundo lugar, se ha probado a realizar el agrupamiento empleando tres clústeres y se han obtenido 85 pacientes que pertenecen al clúster 1, 76 pacientes que pertenecen al clúster 2 y 47 que pertenecen al clúster 3.

La Figura 33a muestra un diagrama de dispersión tridimensional de las características de frecuencia mensual de los episodios de cefaleas, umbral de dolor por presión en el lóbulo temporal y depresión mediada con la escala HADS agrupadas por clúster con diferente color. Las formas indican si el CT es frecuente o crónico, representándose con un círculo y un triángulo respectivamente.

Se puede apreciar claramente la separación existente entre estos tres grupos de forma visual, lo que indica que estas tres características, que evalúan diferentes ambientes de los pacientes como el sensitivo, el grado de cefalea, relacionado con la frecuencia mensual, y el plano neurológico; son capaces de separar correctamente estos tres grupos de pacientes. Si se realiza la comparación con la Figura 31a, cabe destacar que el grupo representado en color magenta es similar al obtenido con el modelo de dos clústeres, y la mayoría de los puntos de los clústeres azul y verde de la Figura 33a provienen de dividir el clúster azul previo. Si se analiza el tipo de CT presente en cada clúster, el algoritmo ha separado en un clúster pacientes solamente con CT crónica (magenta), otro clúster con la mayoría de los CT frecuentes (verde) y otro clúster (azul) con pacientes con ambos grados de CT.

En la Figura 33b, se representa el diagrama de dispersión bidimensional entre ciertas características de los pacientes, características clínicas, neurológicas y sensitivas. La separación entre los tres grupos se puede observar correctamente en estos diagramas, aunque se puede intuir que hay características, como la escala de dolor, que permite separar bastante bien el clúster magenta del verde y azul; y otras, como la depresión, que permite separar el clúster verde del magenta y azul.

(a) Diagrama de dispersión de FreqMONT vs. UDP_Temporal_Dcho vs. HADS_depresión



(b) Diagrama de dispersión de UDP_Temporal_Dcho vs. EVA




Diagrama de dispersión de HADS_depresión vs. FreqMONT

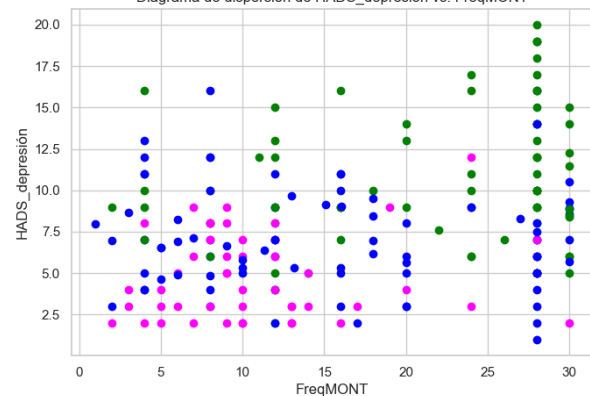


Diagrama de dispersión de HADS_ansiedad vs. RollerDRCHOUMBRAL




Diagrama de dispersión de HDI_Emocional vs. TrPslatentes




Figura 33. Diagrama de dispersión de características de CT agrupadas según el clúster obtenido.

La Tabla 23 recoge los valores medios y la desviación estándar de las características del conjunto de datos de pacientes con CT agrupadas por clúster obtenido, de igual forma, la Figura 34 muestra los diagramas de cajas de las variables cuantitativas agrupadas por clúster.

Tabla 23. Valores medios y desviación estándar de las características de CT agrupadas por clúster.

Característica	Clúster 1	Clúster 2	Clúster 3
	Media ± std.	Media ± std.	Media ± std.
Edad	46,86 ± 15,64	45,92 ± 13,77	38,72 ± 11,11
Tiempo_comienzo	7,9 ± 8,6	10,06 ± 11,37	12,61 ± 10,49
EVA	5,83 ± 1,73	7,09 ± 1,84	4,36 ± 1,59
Duracion	7,62 ± 4,03	8,6 ± 3,86	4,66 ± 3,14
FreqMONT	15,57 ± 9,29	21,67 ± 8,58	10,98 ± 6,27
TrPsactivos	3,05 ± 2,62	5,54 ± 2,75	6,06 ± 2,43
TrPslatentes	0,39 ± 1,06	0,93 ± 1,48	4,01 ± 2,12
TOTALTrPs	3,45 ± 2,94	6,57 ± 2,77	10,3 ± 0,95
UDP_C5C6_Dcha	290,81 ± 126,18	190,19 ± 88,18	155,89 ± 71,59
UDP_Temporal_Dcho	282,55 ± 86,91	192,8 ± 75,85	148,31 ± 55,79
UDP_IIMeta_Dcho	323,92 ± 89,78	256,77 ± 96,91	156,14 ± 55,95
UDP_Tibial_Dcho	517,97 ± 173,11	385,59 ± 168,05	292,14 ± 162,18
HDI_Emcional	13,97 ± 8,3	29,54 ± 12,06	11,7 ± 6,54
HDI_Fisico	16,5 ± 8,71	31,52 ± 10,61	20,0 ± 7,84
Funcion_fisica	90,2 ± 13,83	62,04 ± 27,62	87,34 ± 10,62
Rol_fisico	73,63 ± 34,75	20,72 ± 28,69	62,23 ± 32,92
Dolor_corporal	66,8 ± 20,59	33,39 ± 18,22	50,36 ± 12,71
Salud_general	65,19 ± 18,83	40,91 ± 20,13	64,91 ± 16,89
Vitalidad	60,86 ± 21,59	33,95 ± 18,91	50,74 ± 13,06
Funcion_social	80,24 ± 21,56	49,91 ± 24,04	68,23 ± 17,03
Rol_emocional	82,58 ± 30,1	37,83 ± 41,23	67,96 ± 35,37
Salud_mental	66,34 ± 17,59	41,95 ± 20,49	68,12 ± 16,41
globalsueño	6,68 ± 3,59	9,99 ± 4,85	6,42 ± 2,64
HADS_depresión	6,96 ± 2,94	10,82 ± 4,06	4,74 ± 2,57
HADS_ansiedad	10,43 ± 4,6	11,1 ± 3,75	7,68 ± 3,77
RollerDRCHOUMBRAL	1608,11 ± 849,81	920,02 ± 467,5	704,26 ± 273,63
DolorRollerDRCHOUMBRAL	2,65 ± 1,54	3,77 ± 1,9	2,3 ± 1,37
DolorRollerIZDOUMBRAL	2,57 ± 1,6	3,6 ± 1,82	2,53 ± 1,76

Analizando la Tabla 23 y la Figura 34, se observa que un grupo obtenido tiene sujetos con menor dolor, duración y frecuencia de las cefaleas, un mayor número de puntos gatillo activos y latentes, con menor tolerancia a las pruebas de presión. Este grupo muestra una mejor calidad de sueño, valores menores de depresión y ansiedad, con una percepción buena de su salud emocional y física y buenos resultados en su valoración psicométrica realizada con el test SF-36.

El segundo de los grupos muestra pacientes con un dolor, duración y frecuencia de las cefaleas elevados, con un alto número de puntos gatillo latentes, pero bajo número de puntos gatillo activos, lo cual conlleva una menor tolerancia en las pruebas de umbral de dolor por presión. Además, este grupo tiene una alta incapacidad física y emocional autopercibida, una valoración psicométrica y calidad de sueño peores, así como un mayor grado de depresión.

Por último, el tercer grupo comparte características de los dos grupos anteriores, con valores elevados de dolor, duración y frecuencia de las cefaleas aunque ligeramente inferior que los del segundo grupo. Además, presenta un número bajo de puntos gatillo activos y latentes, por lo que tiene una mayor

DESARROLLO DE PERFILES DE PACIENTES AFECTADOS POR SÍNDROME DE TÚNEL CARPIANO Y CEFALEA TENSIONAL MEDIANTE EL USO DE TÉCNICAS DE APRENDIZAJE AUTOMÁTICO

tolerancia a las pruebas de presión. Por último, tiene una buena salud emocional y física autopercebida, buena calidad de sueño, con muy buenos resultados en la evaluación psicométrica.

Estos grupos obtenidos son muy similares a los que se han obtenido mediante mapas autoorganizativos.

DESARROLLO DE PERFILES DE PACIENTES AFECTADOS POR SÍNDROME DE TÚNEL CARIANO Y CEFALEA TENSIONAL MEDIANTE EL USO DE TÉCNICAS DE APRENDIZAJE AUTOMÁTICO

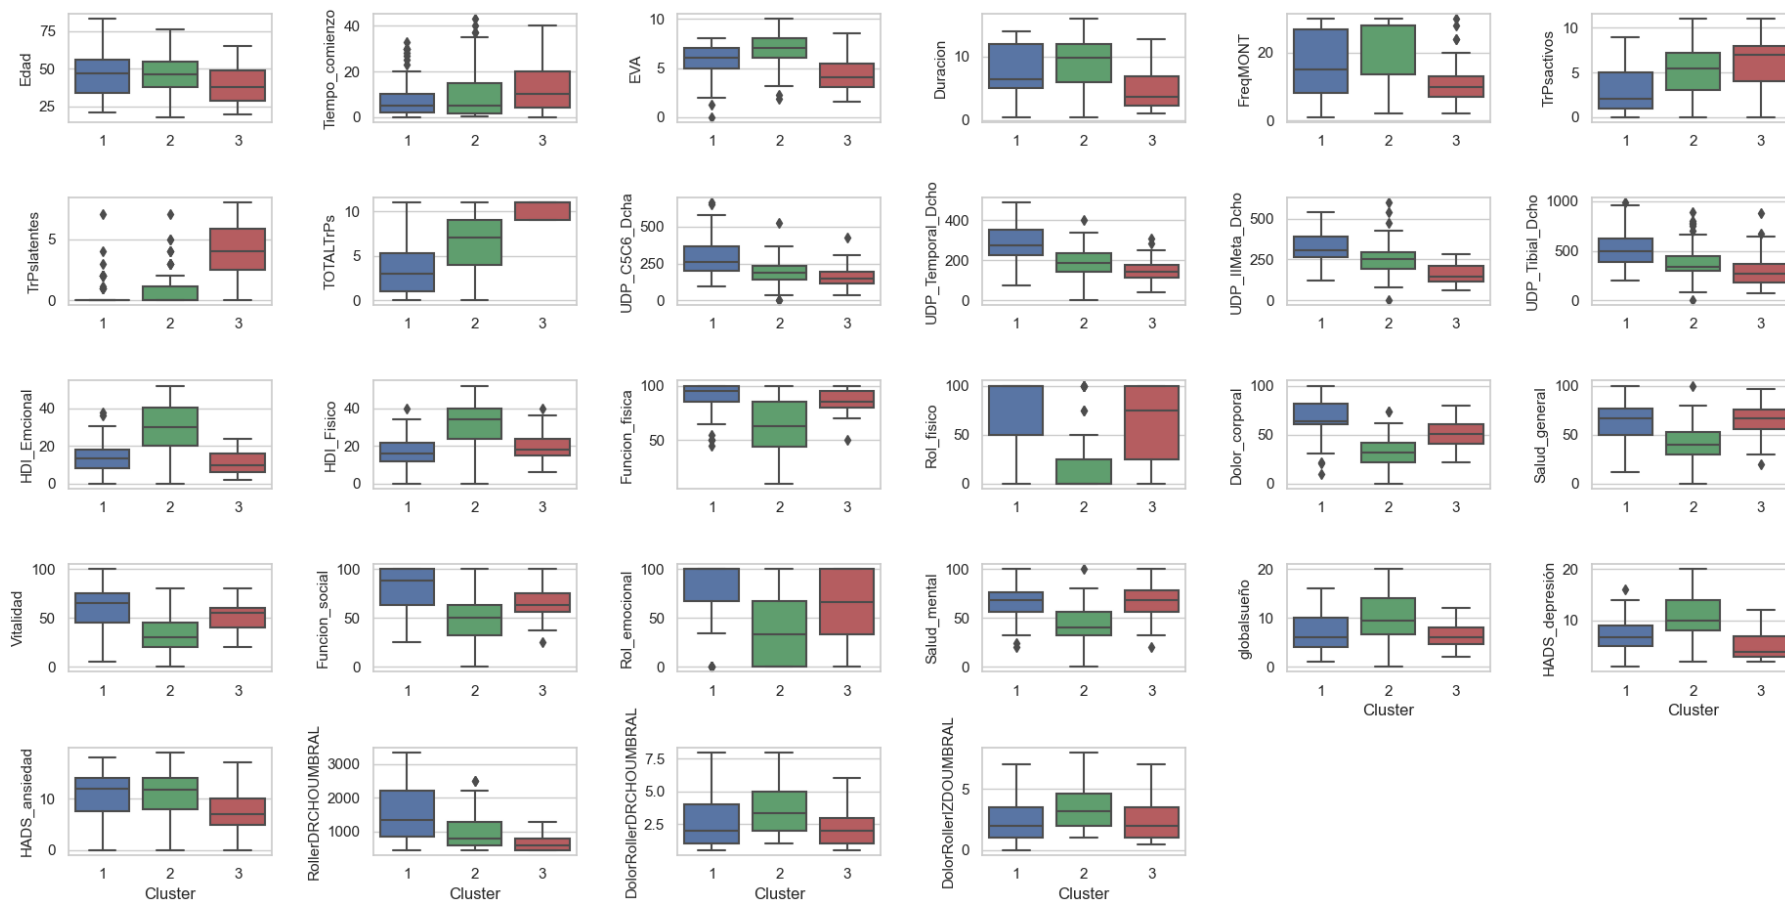


Figura 34. Diagrama de cajas de características de CT según el clúster al que pertenecen.

6. CONCLUSIONES Y LÍNEAS FUTURAS

6.1. CONCLUSIONES

El estudio actual ha permitido detectar grupos potenciales en dos conjuntos de datos, el primero, con pacientes que padecen Síndrome de Túnel Carpiano y, el segundo, con pacientes aquejados de Cefalea Tensional. Estos grupos han sido obtenidos mediante técnicas de aprendizaje automático, en concreto, mediante la aplicación de mapas autoorganizativos (SOM) y agrupamiento espectral.

Antes de aplicar las técnicas de aprendizaje no supervisado, se han explorado y procesado las características de cada uno de los conjuntos de datos, detectando y eliminando valores anómalos y no recogidos. La utilización de estas técnicas ha permitido comprender en profundidad los datos, su distribución y detectar correlaciones y dependencias entre distintas características.

De esta forma, se han encontrado correlaciones muy fuertes entre diferentes características como los umbrales de dolor por presión, tanto en el conjunto de datos de CT como STC. Existe una correlación entre las distintas valoraciones psicológicas en pacientes con CT y correlaciones inversas entre umbral de dolor por calor y por frío en pacientes con STC. Gracias a esto, se ha podido eliminar información redundante antes de realizar los modelos.

Las técnicas de agrupamiento espectral y SOM han permitido agrupar los pacientes e identificar distintas interacciones entre las características de los conjuntos de datos.

En el caso del STC, se ha detectado una relación entre la funcionalidad de la mano afectada y la gravedad de los síntomas que, a su vez, se encuentran relacionadas con otras variables, como el umbral de dolor por presión medido en diferentes zonas, el grado de depresión de los pacientes y la fuerza aplicada en la prueba de pinzamiento. Esto demuestra que, existen correlaciones entre diferentes tipos de características extraídas, las propiamente clínicas, neurológicas, sensitivas y motoras.

En el caso de la CT, se ha manifestado una relación entre los puntos gatillo presentes y el umbral de dolor por presión en las diferentes zonas. Además, se ha identificado que la intensidad del dolor, duración y frecuencia de las CT están relacionados con el estado emocional, calidad de sueño, depresión y la valoración psicométrica SF-36. Sin embargo, no se ha encontrado una relación fuerte entre estos últimos y los puntos gatillo o umbrales de dolor por presión. De esto se extrae que existe relación entre ciertas características clínicas y las sensitivas y entre otras características clínicas y neurológicas.

En cuanto a los perfiles de pacientes detectados, en el caso del STC, existe un primer grupo de pacientes con peor función y síntomas más graves, que presentan una mayor sensibilidad al dolor por presión, es decir, UDP más bajos, mayor sensibilidad al frío y al calor, menor fuerza de agarre en la prueba de pinzamiento y valores más elevados de depresión. El segundo grupo obtenido es opuesto a este, con una severidad menor de los síntomas, mayor funcionalidad, una mejor tolerancia a dolor, mayor fuerza ejercida en el pinzamiento de los dedos índice y corazón con el pulgar y valores más bajos de depresión.

El estudio de los perfiles de pacientes con CT ha mostrado un grupo de pacientes con menor dolor, duración y frecuencia de las cefaleas, un mayor número de puntos gatillo activos y latentes, con mayor sensibilidad a las pruebas de presión y mejores valores en los tests psicológicos realizados. El segundo de los grupos muestra pacientes con un dolor, duración y frecuencia de las cefaleas elevados, con un alto número de puntos gatillo latentes, pero bajo número de puntos gatillo activos, lo cual conlleva una mayor sensibilidad en las pruebas de dolor por presión y peores valores en los tests psicológicos realizados. Se puede incluir un tercer grupo, con valores elevados de dolor, duración y frecuencia de las cefaleas, un número bajo de puntos gatillo activos y latentes, por lo que tiene una mayor tolerancia a las pruebas de presión y muy buenos resultados en las pruebas psicológicas.

Es por esto por lo que es necesario que estas patologías se aborden desde distintos ámbitos, ya que, a parte del dolor que provoca la enfermedad, existen efectos neurológicos derivados y relacionados, así como distintos efectos físicos, que afectan en mayor o menor medida a la calidad de vida de los pacientes.

Tras la obtención de los resultados de este estudio, se ha demostrado que estas patologías conllevan factores físicos y psicológicos asociados que pueden limitar la vida de las personas. Por lo tanto, es importante que el abordaje del tratamiento de los pacientes se haga teniendo en cuenta todos estos ámbitos para que el tratamiento sea completo, tratando de eliminar las causas que lo producen y minimizando el efecto de las patologías.

6.2. LÍNEAS FUTURAS

En el presente trabajo se han detectado grupos potenciales de pacientes con patologías de Cefalea Tensional y Síndrome de Túnel carpiano obtenidos mediante técnicas de aprendizaje automático. Como posibles mejoras en futuros estudios se propone:

- Analizar en profundidad las dependencias de las características y su importancia, ya que, por lo que se ha podido comprobar, existen características muy correlacionadas que no parecen aportar más información al problema. Si realmente no aportan información a mayores, se podría simplificar mucho el problema, simplificando los modelos y reduciendo considerablemente el tiempo de obtención de los datos de los pacientes.
- Comprobar si los perfiles de pacientes obtenidos para las diferentes patologías presentan relevancia clínica y si es posible utilizarlos para personalizar los diferentes tratamientos.
- Probar la obtención de un mayor número de clústeres, ya que se obtenían valores de métricas buenas para cuatro o cinco clústeres según el algoritmo empleado. Esto permitiría seguir profundizando en más grupos con diferencias más sutiles entre pacientes, con el objetivo de conseguir grupos de pacientes a los que aplicar tratamientos más específicos y personalizados.
- Por último, continuar recopilando un mayor grupo de pacientes. Por ejemplo, en el caso de Cefalea Tensional, solamente existen pacientes con patología frecuente y crónica, pero no poco frecuente. Esto permitiría construir una herramienta de clasificación más robusta y con más grupos que permitan acercarse al objetivo del tratamiento personalizado.

7. BIBLIOGRAFÍA

- [1] L. Padua, R. Padua, I. Aprile, P. D'Amico, y P. Tonali, «Carpal tunnel syndrome: Relationship between clinical and patient-oriented assessment», *Clin. Orthop. Relat. Res.*, n.º 395, pp. 128-134, 2002.
- [2] S. Aroori y R. A. Spence, «Carpal Tunnel Syndrome», *Ulster Med. Soc.*, vol. 77, n.º November 2007, pp. 6-17, 2008.
- [3] K. Redzwan Habib, «Estimation of Carpal Tunnel Syndrome (CTS) Prevalence in Adult Population in Western European Countries: A Systematic Review», *Eur. J. Clin. Biomed. Sci.*, vol. 3, n.º 1, pp. 13-18, 2017.
- [4] L. Padua, D. Coraci, C. Erra, C. Pazzaglia, I. Paolasso, C. Loreti, P. Caliandro, y L. D. Hobson-Webb, «Carpal tunnel syndrome: clinical features, diagnosis, and management», *Lancet Neurol.*, vol. 15, n.º 12, pp. 1273-1284, 2016.
- [5] J. C. Stevens, «AAEM minimonograph 26: The electrodiagnosis of carpal tunnel syndrome», *Muscle and Nerve*, vol. 20, n.º 12, pp. 1477-1486, 1997.
- [6] J. D. P. Bland, «A neurophysiological grading scale for carpal tunnel syndrome», *Muscle and Nerve*, vol. 23, n.º 8, pp. 1280-1283, 2000.
- [7] B. M. Sucher, «Grading severity of carpal tunnel syndrome in electrodiagnostic reports: Why grading is recommended», *Muscle and Nerve*, vol. 48, n.º 3, pp. 331-333, 2013.
- [8] A. Fumal y J. Schoenen, «Tension-type headache : current research and clinical management», *Lancet Neurol.*, vol. 7, n.º January, pp. 70-83, 2008.
- [9] L. J. Stovner, K. Hagen, R. Jensen, Z. Katsarava, R. B. Lipton, A. I. Scher, T. J. Steiner, y J. A. Zwart, «The global burden of headache: A documentation of headache prevalence and disability worldwide», *Cephalalgia*, vol. 27, n.º 3, pp. 193-210, 2007.
- [10] International Headache Society, «The International Classification of Headache Disorders: 3rd edition. (ICHD-III).», *Cephalalgia*, vol. 38, n.º 1, pp. 1-211, 2018.
- [11] A. Ultsch y J. Lotsch, «Machine learning in pain research», *Pain*, vol. 159, n.º 4, pp. 623-630, 2018.
- [12] A. Friedman y J. Hodapp, «Carpal Tunnel Syndrome», *Practical Pain Management*, 2015. <https://www.practicalpainmanagement.com/pain/neuropathic/carpal-tunnel-syndrome/carpal-tunnel-syndrome-0> (accedido ago. 10, 2020).
- [13] United States Department Of Labor, «Lost-worktime injuries and illnesses: characteristics and resulting days away from work, 2002», *Bur. Labor Stat.*, n.º 20212, pp. 1-23, 2002.
- [14] M. S. Aboonq, «Pathophysiology of carpal tunnel syndrome», *Neurosciences*, vol. 20, n.º 1, pp. 4-9, 2015.
- [15] R. Shiri, M. H. Pourmemari, K. Falah-Hassani, y E. Viikari-Juntura, «The effect of excess body mass on the risk of carpal tunnel syndrome: A meta-analysis of 58 studies», *Obes. Rev.*, vol. 16, n.º 12, pp. 1094-1104, 2015.
- [16] J. Becker, D. B. Nora, I. Gomes, F. F. Stringari, R. Seitensus, J. S. Panosso, y J. A. C. Ehlers, «An evaluation of gender, obesity, age and diabetes mellitus as risk factors for carpal tunnel syndrome», *Clin. Neurophysiol.*, vol. 113, n.º 9, pp. 1429-1434, 2002.
- [17] L. Padua, R. Padua, M. Lo Monaco, I. Aprile, y P. Tonali, «Multiperspective assessment of carpal

- tunnel syndrome. Italian CTS Study Group», *Neurology*, vol. 53, n.º 8, pp. 1654-1659, 1999.
- [18] R. Bingham, J. Rosecrance, y T. Cook, «Prevalence of abnormal median nerve conduction in applicants for industrial jobs.», *Am. J. Ind. Med.*, vol. 3, n.º 30, pp. 355-361, 1996.
- [19] I. Atroshi, C. Gummesson, R. Johnsson, E. Ornstein, J. Ranstam, y I. Rosén, «Prevalence of Carpal Tunnel Syndrome in a General Population», *Jama*, vol. 2, n.º 282, pp. 153-158, 1999.
- [20] L. J. Stovner y C. Andree, «Prevalence of headache in Europe: A review for the Eurolight project», *J. Headache Pain*, vol. 11, n.º 4, pp. 289-299, 2010.
- [21] D. Chowdhury, «Tension type headache», *Ann. Indian Acad. Neurol.*, vol. 15, n.º SUPPL., pp. 83-88, 2012.
- [22] L. Bendtsen, «Central sensitization in tension-type headache & possible pathophysiological mechanisms», *Cephalalgia*, vol. 20, pp. 486-508, 2000.
- [23] B. K. Rasmussen, R. Jensen, M. Schroll, y J. Olesen, «Interrelations Between Migraine and Tension-Type Headache in the General Population», *Arch. Neurol.*, vol. 49, n.º 9, pp. 914-918, 1992.
- [24] B. K. Rasmussen, R. Jensen, M. Schroll, y J. Olesen, «Epidemiology of headache in a general population-A prevalence study», *J. Clin. Epidemiol.*, vol. 44, n.º 11, pp. 1147-1157, 1991.
- [25] D. B. Penzien, J. C. Rains, G. L. Lipchik, y T. L. Creer, «Behavioral interventions for tension-type headache: overview of current therapies and recommendation for a self-management model for chronic headache.», *Curr. Pain Headache Rep.*, vol. 8, n.º 6, pp. 489-499, 2004.
- [26] J. Carlsson, A. Fahlcrantz, y L. E. Augustinsson, «Muscle tenderness in tension headache treated with acupuncture or physiotherapy», *Cephalalgia*, vol. 10, n.º 3, pp. 131-141, 1990.
- [27] A. M. Turing, «Computing Machinery and Intelligence», *Oxford Univ. Press behalf Mind Assoc.*, vol. 59, n.º 236, pp. 433-460, 1950.
- [28] H. Alashwal, M. El Halaby, J. J. Crouse, A. Abdalla, y A. A. Moustafa, «The application of unsupervised clustering methods to Alzheimer's disease», *Front. Comput. Neurosci.*, vol. 13, n.º May, pp. 1-9, 2019.
- [29] K. L. Smarr y A. L. Keefer, «Measures of Depression and Depressive Symptoms», *Arthritis Care Res. (Hoboken).*, vol. 63, n.º 11, pp. 454-466, 2011.
- [30] D. Celik y E. K. Mutlu, «Clinical implication of latent myofascial trigger point topical collection on myofascial pain», *Curr. Pain Headache Rep.*, vol. 17, n.º 8, 2013.
- [31] G. P. Jacobson, N. M. Ramadan, L. Norris, y C. W. Newman, «Headache Disability Inventory (HDI): Short-term Test-Retest Reliability and Spouse Perceptions», *Headache J. Head Face Pain*, vol. 35, n.º 9, pp. 534-539, 1995.
- [32] M. Rodríguez Vidal, M. Merino Escobar, y M. Castro Salas, «Valoración psicométrica de los componentes físicos (csf) y mentales (CSM) del SF-36 en pacientes insuficientes renales crónicos en tratamiento con hemodiálisis», *Cienc. y Enferm.*, vol. 15, n.º 1, pp. 75-88, 2009.
- [33] A. Guillén-Riquelme y G. Buena-Casal, «Actualización psicométrica y funcionamiento diferencial de los ítems en el State Trait Anxiety Inventory (STAI)», *Psicothema*, vol. 23, n.º 3, pp. 510-515, 2011.
- [34] S. Węglarczyk, «Kernel density estimation and its application», en *XLVIII Seminar of Applied Mathematics*, 2018, vol. 23, pp. 1-8.

- [35] S. Khalid, T. Khalil, y S. Nasreen, «A survey of feature selection and feature extraction techniques in machine learning», *Sci. Inf. Conf.*, n.º August 2014, pp. 372-378, 2014.
- [36] M. M. Mukaka, «Statistics corner: A guide to appropriate use of correlation coefficient in medical research», *Malawi Med. J.*, vol. 24, n.º 3, pp. 69-71, 2012.
- [37] M. L. Mchugh, «The Chi-square test of independence», *Biochem. Medica*, vol. 23, n.º 2, pp. 143-149, 2013.
- [38] J. M. Jerez, I. Molina, P. J. García-Laencina, E. Alba, N. Ribelles, L. Franco, y M. Martín, «Missing data imputation using statistical and machine learning methods in a real breast cancer problem», *Artif. Intell. Med.*, vol. 50, pp. 105-115, 2010.
- [39] J. G. Dy y C. E. Brodley, «Feature Selection for Unsupervised Learning», *J. Mach. Learn. Res.*, vol. 5, pp. 845-889, 2004.
- [40] M. M. Rahman y D. N. Davis, «Machine Learning-Based Missing Value Imputation Method for Clinical Datasets», en *IAENG Transactions on Engineering Technologies. Lecture Notes in Electrical Engineering*, vol. 229, Y. GC., S. Ao, y L. Gelman, Eds. Springer, 2013, pp. 245-257.
- [41] G. E. Batista y M. C. Monard, «A study of k-nearest neighbour as an imputation method», *Front. Artif. Intell. Appl.*, vol. 87, pp. 251-260, 2002.
- [42] D. R. Wilson y T. R. Martinez, «Improved heterogeneous distance functions», *J. Artif. Intell. Res.*, vol. 6, pp. 1-34, 1997.
- [43] L. Ladha y T. Deepa, «Feature Selection Methods And Algorithms», *Int. J. Comput. Sci. Eng.*, vol. 3, n.º 5, pp. 1787-1797, 2011.
- [44] J. A. Hartigan, «Statistical theory in clustering.», *J. Classif.*, vol. 2, pp. 63-76, 1985.
- [45] C. M. Schaffer y P. E. Green, «An Empirical Comparison of Variable Standardization Methods in Cluster Analysis», *Multivariate Behav. Res.*, vol. 31, n.º 2, pp. 149-167, 1996.
- [46] F. Boutin y M. Hascoët, «Cluster Validity Indices for Graph Partitioning», *Proc. Eighth Int. Conf. Inf. Vis.*, vol. 4, pp. 1-6, 2004.
- [47] J. H. Ward, «Hierarchical Grouping to Optimize an Objective Function», *J. Am. Stat. Assoc.*, vol. 58, n.º 301, pp. 236-244, 1963.
- [48] L. Rokach y O. Maimon, «Clustering Methods», en *Data Mining and Knowledge Discovery Handbook*, L. Rokach y O. Maimon, Eds. Springer, 2005, pp. 321-351.
- [49] A. Y. Ng, M. I. Jordan, y Y. Weiss, «On Spectral Clustering : Analysis and an algorithm», en *NIPS'01: Proceedings of the 14th International Conference on Neural Information Processing Systems: Natural and Synthetic*, 2001, pp. 849-856.
- [50] B. J. Frey y D. Dueck, «Clustering by Passing Messages Between Data Points», *Science*, vol. 315, pp. 972-976, 2007.
- [51] D. Comaniciu y P. Meer, «Mean Shift : A Robust Approach toward Feature Space Analysis», *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 24, n.º 5, pp. 603-619, 2002.
- [52] T. Kohonen, «Self-Organized Formation of Topologically Correct Feature Maps», *Biol. Cybern.*, vol. 43, pp. 59-69, 1982.
- [53] J. Lampinen y E. Oja, «Clustering Properties of Hierarchical Self-Organizing Maps», *J. Math. Imaging Vis.*, vol. 2, pp. 261-272, 1992.
- [54] M. Halkidi, Y. Batistakis, y M. Vazirgiannis, «On clustering validation techniques», *J. Intell. Inf.*

- Syst.*, vol. 17, n.º 2-3, pp. 107-145, 2001.
- [55] J. C. Dunn, «Well-Separated Clusters and Optimal Fuzzy Partitions», *J. Cybern.*, vol. 4, n.º 1, pp. 95-104, 1974.
- [56] D. L. Davies y D. W. Bouldin, «A Cluster Separation Measure», *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. PAMI-1, n.º 2, pp. 224-227, 1979.
- [57] T. Caliński y J. Harabasz, «A dendrite method for cluster analysis», *Commun. Stat. - Theory Methods*, vol. 3, n.º 1, pp. 1-27, 1974.
- [58] P. J. Rousseeuw, «Silhouettes: A graphical aid to the interpretation and validation of cluster analysis», *J. Comput. Appl. Math.*, vol. 20, pp. 53-65, 1987.
- [59] U. Von Luxburg, «A tutorial on spectral clustering», *Stat. Comput.*, vol. 17, n.º 4, pp. 395-416, 2007.



UNIVERSITAT
POLITÈCNICA
DE VALÈNCIA



ESCUELA TÉCNICA
SUPERIOR INGENIERÍA
INDUSTRIAL VALENCIA

DOCUMENTO II

PRESUPUESTO

DESARROLLO DE PERFILES DE PACIENTES AFECTADOS
POR SÍNDROME DE TÚNEL CARPIANO Y CEFALEA
TENSIONAL MEDIANTE EL USO DE TÉCNICAS DE
APRENDIZAJE AUTOMÁTICO

AUTOR: DANIEL MAYOR TOMILLO

TUTOR: JOSÉ DAVID MARTÍN GUERRERO

2019 - 2020

DESARROLLO DE PERFILES DE PACIENTES AFECTADOS POR SÍNDROME DE TÚNEL CARPIANO Y
CEFALEA TENSIONAL MEDIANTE EL USO DE TÉCNICAS DE APRENDIZAJE AUTOMÁTICO

ÍNDICE DE CONTENIDO DEL PRESUPUESTO

1. OBJETIVO	4
2. PRESUPUESTOS PARCIALES.....	5
2.1. COSTE DE PERSONAL	5
2.2. COSTE DE LOS MATERIALES.....	6
2.3. COSTE DE HARDWARE Y SOFTWARE.....	6
3. PRESUPUESTO TOTAL	8

1. OBJETIVO

El principal objetivo del presupuesto económico del trabajo fin de máster es calcular el coste que ha supuesto su desarrollo. Se pretenden estimar los costes derivados del personal involucrado en la realización del trabajo, de los materiales empleados y de los elementos utilizados tanto software como hardware.

En el apartado de los presupuestos parciales se expondrán los costes desglosados de cada uno de los ámbitos considerados a presupuestar.

En segundo lugar, se expone el presupuesto total del proyecto que será la suma de los presupuestos parciales definidos en el capítulo anterior. Además, al resultado final es necesario añadirle dos porcentajes establecidos: el de gastos generales (13%), el asociado al beneficio industrial (6%) y el IVA del 21% . De esta forma, se obtiene el presupuesto total que supondría la realización de este trabajo fin de máster por contrata.

2. PRESUPUESTOS PARCIALES

En esta sección se detallan los diferentes componentes que forman los presupuestos parciales necesarios para la realización del proyecto: *Desarrollo de perfiles de pacientes afectados por síndrome de túnel carpiano y cefalea tensional mediante el uso de técnicas de aprendizaje automático.*

El informe de presupuestos parciales se desglosa en tres cuadros de precios: coste de mano de obra, coste de materiales y coste de elementos hardware y software.

2.1. COSTE DE PERSONAL

En este apartado, se describen los recursos humanos necesarios para el desarrollo del presente proyecto. La remuneración de cada uno de los participantes se ha definido teniendo en cuenta lo expuesto en las retribuciones del profesorado universitario de la *Universitat de València*.

Las horas de trabajo para cada participante se establecen según lo indicado en el plan de estudios del Máster de Ingeniería Biomédica que define los créditos del trabajo fin de máster (20 CTS) y el tiempo estimado de dedicación por parte del tutor y del equipo de fisioterapeutas y psicólogos que participaron en la recolección de los datos.

Concretamente, se considera la contribución de:

- **Autor del trabajo fin de máster.** D. Daniel Mayor Tomillo, Ing. Tec. Especif. De Telecomunicación.
- **Tutor del trabajo fin de máster.** Cat. José David Martín Guerrero.
- **Equipo de fisioterapeutas y psicólogos que recopilaron los datos.** Catedrático de la *Universitat de València*, Profesora titular de *Universitat de València* y Becaria de doctorado en *Universitat de València*.

Tabla 1. Presupuesto para el coste del personal

Designación	Coste Unitario (€/h)	Tiempo total (h)	Coste Total (€)
Director del TFM (Catedrático)	42,00	8	320,00
Autor del TFM (Alumno)	15,00	600	9.000,00
Catedrático UV	42,00	20	840,00
Profesora titular UV	33,00	20	660,00
Becaria de doctorado UV	15,00	71,67	1075,05
Total			11.895,05

2.2. COSTE DE LOS MATERIALES

Para llevar a cabo el presupuesto de materiales se han tenido en cuenta los recursos materiales necesarios, en los que se incluye el coste derivado de la obtención de los datos de los pacientes, tanto de Cefalea Tensional como del Síndrome de Túnel Carpiano.

Los datos han sido recopilados por un equipo de fisioterapeutas y psicólogos del que forma parte la profesora Esperanza Navarro, perteneciente a la *Facultad de Psicología de la Universitat de València*. La cantidad corresponde al número de pacientes de los cuales se han obtenido los datos.

Tabla 2. Presupuesto de los materiales

Designación	Coste Unitario (€/paciente)	Cantidad (pacientes)	Coste Total (€)
Abono a pacientes con Cefalea Tensional	10,00	208	2.800,00
Abono a pacientes con Síndrome de Túnel Carpiano	10,00	222	2.200,00
Total			4.300,00

2.3. COSTE DE HARDWARE Y SOFTWARE

Este presupuesto tiene en cuenta el coste de las distintas herramientas informáticas (hardware y software) utilizadas en la realización del proyecto.

Debido a que las herramientas que se han empleado no se han empleado únicamente para la elaboración del trabajo, es necesario tener en cuenta el período de amortización para cada una de ellas. La amortización está relacionada con la vida útil del material y el intervalo de tiempo amortizado para cada elemento.

Cabe destacar que el coste real de las herramientas software empleadas ha sido nulo, ya que la licencia de Microsoft Office y de Matlab son proporcionadas por la *Universitat Politècnica de València*. El resto de software utilizado es gratuito y de código abierto o se ha empleado una versión gratuita del mismo en período de prueba, como es el caso del *SPSS Statistics*.

Tabla 3. Presupuesto de las herramientas hardware y software

Designación	Precio unitario (€/unidad)	Cantidad (unidades)	Período de amortización (meses)	Tiempo amortizado (meses)	Coste Total (€)
SOFTWARE					
Licencia de Office 365 Personal	69,00	1	12	6	34,50
Licencia de <i>Matlab Student</i> (Incluye <i>Statistics and Machine Learning Toolbox</i>)	69,00	1	12	6	34,50

DESARROLLO DE PERFILES DE PACIENTES AFECTADOS POR SÍNDROME DE TÚNEL CARIANO Y
CEFALEA TENSIONAL MEDIANTE EL USO DE TÉCNICAS DE APRENDIZAJE AUTOMÁTICO

Designación	Precio unitario (€/unidad)	Cantidad (unidades)	Período de amortización (meses)	Tiempo amortizado (meses)	Coste Total (€)
SPSS Statistics	99,00	1	1	1	99,00
Licencia <i>Python Software Foundation</i>	0	1	-	-	0,00
Librerías matplotlib, pandas, scipy, sklearn, seaborn, entre otras.	0	1	-	-	0,00
<i>PyCharm Community Edition</i> (IDE)	0	1	-	-	0,00
HARDWARE					
MSI Modern 14 A10RB-663XES Intel Core i7-10510U/16GB/512GB SSD/MX250	999,00	1	48	6	124,88
Disco Duro Externo - Toshiba Canvio (2 TB)	90,41	1	120	6	4,52
Total					297,40

3. PRESUPUESTO TOTAL

Para cálculo del presupuesto total del proyecto es necesario tener en cuenta la suma de los presupuestos parciales definidos en el capítulo anterior.

El presupuesto de ejecución del proyecto por contrata se obtiene añadiendo el porcentaje de gastos generales (13%), en el que se engloban los gastos necesarios para no cesar la actividad, pero que no están directamente relacionados con los productos o servicios que se ofrecen; y el asociado al beneficio industrial que se fija en un 6%. Además, se añadirá al precio total bruto el impuesto del IVA (21%), obteniendo como resultado el presupuesto total que supondría la realización del presente TFM.

Tabla 4. Presupuesto total de la realización del proyecto.

PRESUPUESTOS PARCIALES	Importe (€)
1. Presupuesto de coste de personal	11.895,05
2. Presupuesto de material	4.300,00
3. Presupuesto de HW y SW	297,40
PRESUPUESTO DE EJECUCIÓN DE MATERIAL	16.492,45
13% gastos generales	2.144,02
6% beneficio industrial	989,55
PRESUPUESTO DE EJECUCIÓN POR CONTRATA	19.626,02
21% IVA.	4.121,46
PRESUPUESTO TOTAL	23.747,48

El presupuesto para la realización del proyecto asciende a la cantidad de veintitrés mil setecientos cuarenta y siete con cuarenta y ocho céntimos (23.747,48 €).