


# Desarrollo de un algoritmo automatizado basado en técnicas de *machine learning* para analizar polisomnografías

José David Morales Dieguez





UNIVERSIDAD DEL VALLE DE GUATEMALA  
Facultad de Ingeniería




Desarrollo de un algoritmo automatizado basado en técnicas de *machine learning* para analizar polisomnografías

Trabajo de graduación en modalidad de proyecto presentado por José David Morales Dieguez para optar al grado académico de Licenciado en Ingeniería Biomédica


Guatemala,

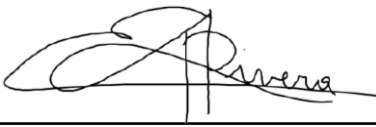
2024

Vo.Bo.:

(f)   
M. Sc. Carlos Esquit

Tribunal Examinador:

(f)   
M.Sc. Carlos Esquit

(f)   
Dr. Luis Alberto Rivera Estrada

(f) \_\_\_\_\_  
Ing. Kurt Emmanuel Kellner

Fecha de aprobación: Guatemala, 13 de febrero de 2025.

La elaboración del presente trabajo de graduación surge del deseo de querer dar visibilidad sobre la importancia del estudio del sueño así como concientizar sobre los trastornos del sueño que afectan a gran parte de la población en su día a día y como las tecnologías actuales, especialmente el uso de *machine learning*, pueden ser aplicados directamente a campos como el de la ingeniería biomédica presentando alternativas que simplifiquen el trabajo realizado por técnicos del sueño y cuyo potencial a largo plazo pueda mejorar los métodos de análisis y diagnóstico en esta área.

Agradezco profundamente a Dios, a mis padres, hermanas y demás familia por su apoyo incondicional durante estos cinco años, brindándome aliento en los momentos que más lo necesité y siendo pilares fundamentales en cada aspecto de mi vida; su ayuda ha sido esencial para cumplir este sueño. También quiero agradecer a los solecitos Paula, Esther y Ayleen, por su amistad.

Quiero expresar agradecimiento a mi asesor M.Sc. José Andrés Leal Ordóñez, por su apoyo durante el desarrollo de este trabajo de graduación y por ser una inspiración del potencial que la biomédica tiene al momento de ayudar a las personas, al igual que agradecerle a Luis Rivera por haberme apoyado durante varias sesiones y compartido su conocimiento en el campo del *machine learning* y agradecerle a Andrés Monterroso, técnico del sueño certificado en Guatemala, por su respaldo en este proyecto. Todos ellos fueron fundamentales para la culminación de este trabajo, y siempre tendré presente su valiosa participación.

Por último, agradezco profundamente al departamento de Ingeniería Biomédica y a la Universidad Del Valle de Guatemala por haberme permitido ser parte de esta prestigiosa casa de estudios, conocer amigos que siempre llevaré en mi corazón y culminar una carrera profesional de la cual me siento completamente orgulloso. Y a mí mismo, gracias por nunca dejar de creer en mi potencial, porque hoy puedo ver los frutos de mi esfuerzo.

# Índice

Prefacio	III
Lista de figuras	VII
Resumen	VIII
Abstract	IX
1 Introducción	1
2 Antecedentes	3
3 Justificación	5
4 Objetivos	8
5 Alcance	9
6 Marco teórico	10
7 Metodología	35
7.1 Análisis de las necesidades	35
7.2 Base de datos PhysioNet	36
7.3 Procesamiento de datos MATLAB	37
7.3.1 Extracción de archivos	37
7.3.2 Separación de la base de datos por datos individuales	38
7.3.3 Agrupamiento de datos y cálculo de estadísticas para modelos de <i>Machine Learning</i>	38
7.4 Uso de <i>Classification Learner</i> para entrenamiento de modelos de clasificación	40
8 Resultados	43
8.1 Entrevistas	43
8.2 Preprocesamiento y transformación de las señales	44
8.3 Resultados de clasificación	45
8.3.1 Resultados del Modelo <i>KNN</i>	45
8.3.2 Resultados del Modelo <i>SVM</i>	46
8.3.3 Resultados del Modelo <i>Fine tree</i>	48
8.3.4 Resultados del Modelo <i>Wide Neural Network</i>	50

8.3.5	Resultados del Modelo <i>Bagged Tress</i>	51
9	Discusión de resultados	54
10	Conclusiones	56
11	Recomendaciones	58
12	Referencias	60
13	Anexos	69
13.1	Anexo 1. Estadificación del sueño procesada mediante MATLAB de la base de datos PhysioNet	69
13.2	Anexo 2. Estadificación del sueño con estadísticas agregadas	71

# Lista de figuras

Figura 1. Cantidad de sueño recomendado por grupo de edad. . . . .	12
Figura 2. Huso del sueño y complejo K. . . . .	14
Figura 3. Ciclo de sueño típico durante un periodo de descanso. . . . .	15
Figura 4. Registro polisomnográfico. . . . .	17
Figura 5. Electrodo EEG y actividad según la etapa del sueño. . . . .	19
Figura 6. Posicionamiento de electrodos para EOG. . . . .	20
Figura 7. Posicionamiento de electrodos para EMG. . . . .	20
Figura 8. Posicionamiento de electrodos para ECG. . . . .	21
Figura 9. Posicionamiento de sensores para oximetría y bandas de esfuerzo. . . . .	22
Figura 10. Evaluación de un polisomnograma por un técnico del sueño. . . . .	25
Figura 11. Tipos principales de aprendizaje automático. . . . .	27
Figura 12. Ejemplo del método de clasificación KNN. . . . .	28
Figura 13. Funcionamiento de una red neuronal. . . . .	29
Figura 14. Aprendizaje en conjunto con árboles de decisión. . . . .	30
Figura 15. Separación de clases mediante SVM. . . . .	31
Figura 16. Ejemplo de matriz de confusión. . . . .	32
Figura 17. Curva AUC - ROC. . . . .	33
Figura 18. Archivos Hypnogram y PSG por paciente. . . . .	37
Figura 19. Flujo de trabajo. . . . .	39
Figura 20. Herramienta <i>Classification Learner</i> en MATLAB. . . . .	40
Figura 21. Selección de variables y modelos de clasificación. . . . .	41
Figura 22. Señales originales y características extraídas. . . . .	44
Figura 23. Resultados del modelo <i>KNN</i> . . . . .	46
Figura 24. Resultados del modelo <i>SVM (Fine Gaussian)</i> . . . . .	48
Figura 25. Resultados del modelo <i>Fine Tree</i> . . . . .	49
Figura 26. Resultados del modelo <i>Wide Neural Network</i> . . . . .	51

Figura 27. Resultados del modelo <i>Bagged Trees</i> . . . . .	53
Anexo 28. Estadío del sueño N1. . . . .	69
Anexo 29. Estadío del sueño N2. . . . .	70
Anexo 30. Estadío del sueño N3. . . . .	70
Anexo 31. Estadío del sueño N4. . . . .	71
Anexo 32. Estadío del sueño REM. . . . .	71
Anexo 33. Estadío W procesado. . . . .	72
Anexo 34. Estadío N1 procesado. . . . .	72
Anexo 35. Estadío N2 procesado. . . . .	73
Anexo 36. Estadío N4 procesado. . . . .	73
Anexo 37. Estadío REM procesado. . . . .	74

Los trastornos del sueño son uno de los problemas clínicos más frecuentes en la actualidad. Estudios han demostrado que el sueño inadecuado o no reparador puede interferir con el funcionamiento normal en aspectos físicos, mentales, sociales y emocionales. Aunque algunas de las preguntas más básicas en la investigación del sueño, como: ¿por qué dormimos?, siguen sin respuesta, los desarrollos recientes destacan la importancia de la salud del sueño. Las personas que duermen menos de seis horas por noche tienen un 12% más de probabilidades de morir prematuramente en comparación con quienes duermen las 6-8 horas recomendadas, lo que hace que un diagnóstico temprano relacionado con trastornos del sueño sea fundamental para un tratamiento exitoso. La polisomnografía es el estándar de oro para evaluar la fisiología del sueño; sin embargo, su costo y la carga de trabajo que implica pueden ser barreras significativas para muchas personas.

El objetivo de este proyecto fue desarrollar un software automatizado basado en técnicas de *machine learning* utilizando la plataforma MATLAB, para analizar de manera eficiente una base de datos de polisomnografías obtenida del repositorio en línea de PhysioNet. Este software fue diseñado específicamente para clasificar los estadios del sueño de los individuos de forma rápida, con el propósito de explorar el potencial de estas tecnologías para reducir costos y la carga de trabajo de los especialistas en polisomnografías. Los resultados y el desempeño del software se compararon con la estadificación realizada por técnicos capacitados según el manual de Rechtschaffen y Kales de 1968, cuyos resultados estaban adjuntos en la base de datos.

Finalmente, los resultados fueron compartidos con técnicos del sueño certificados en Guatemala, quienes proporcionaron retroalimentación sobre la utilidad y precisión del software, además de sugerencias de mejora y ajustes para su futura aplicación práctica.

Palabras clave: *machine learning*, polisomnografía, estudio del sueño.

Sleep disorders are among the most common clinical issues today. Studies have shown that inadequate or non-restorative sleep can interfere with normal physical, mental, social, and emotional functioning. Although some of the most basic questions in sleep research, such as “Why do we sleep?” remain unanswered, recent findings underscore the importance of sleep health. People who sleep less than six hours per night have a 12% higher likelihood of dying prematurely compared to those who sleep the recommended 6-8 hours, making early diagnosis of sleep disorders critical for successful treatment. Polysomnography is the gold standard for assessing sleep physiology; however, its cost and workload can pose significant barriers for many people.

The objective of this project was to develop an automated software based on *machine learning* techniques using MATLAB, to efficiently analyze a polysomnography database obtained from the PhysioNet online repository. This software was specifically designed to quickly classify sleep stages in individuals, aiming to explore the potential of these technologies to reduce costs and the workload of polysomnography specialists. The software’s results and performance were compared to scoring conducted by trained technicians according to the Rechtschaffen and Kales 1968 manual, which was included in the database.

Finally, the results were shared with certified sleep technicians in Guatemala, who provided feedback on the software’s utility and accuracy, as well as suggestions for improvement and adjustments for its future practical application.

Keywords: *machine learning*, polysomnography, sleep study.

El presente trabajo se enfoca en el desarrollo de un algoritmo automatizado basado en técnicas de machine learning para analizar polisomnografías y detectar estadios del sueño, así como artefactos asociados. Los trastornos del sueño son comunes y afectan significativamente la calidad de vida de muchas personas. Sin embargo, los métodos actuales para el diagnóstico, como la polisomnografía, pueden ser costosos y demandantes en términos de tiempo y recursos. Este trabajo tiene como objetivo presentar una posible alternativa que permita simplificar y optimizar el proceso de diagnóstico mediante la implementación de herramientas tecnológicas avanzadas.

La solución propuesta consiste en el desarrollo de un algoritmo automatizado de *machine learning* en MATLAB, que clasifique automáticamente los estadios del sueño y detecte artefactos asociados, utilizando una base de datos de polisomnografías obtenida de la base de datos PhysioNet. Para ello, se entrenan modelos de clasificación mediante algoritmos como KNN, SVM, redes neuronales y árboles de decisión, los cuales fueron implementados y entrenados en el entorno de MATLAB. Además, se aplica un proceso de preprocesamiento de datos, el cual incluye la limpieza y agrupamiento de la información, con el fin de garantizar la calidad y consistencia de los datos utilizados para entrenar los modelos.

A lo largo de los siguientes capítulos, se presenta un análisis detallado del marco teórico que respalda el uso de machine learning en el análisis de polisomnografías, junto con una revisión de las alternativas actuales en el mercado para la estadificación del sueño (capítulos 2 y 6). En la justificación (capítulo 3), se exponen las motivaciones que impulsaron el desarrollo de este trabajo, destacando la relevancia de la salud del sueño y la importancia de contar con diagnósticos precisos para los trastornos del sueño. A continuación, (capítulos 4 y 5), se establecen los objetivos a alcanzar y las limitaciones del trabajo de graduación realizado.

El capítulo 6 proporciona las bases teóricas que sustentan el proyecto, apoyadas por artículos científicos clave que guían el desarrollo de la investigación. En el capítulo 7, se describe detalladamente la metodología empleada para alcanzar los objetivos planteados, incluyendo el desarrollo y entrenamiento de los modelos de machine learning utilizados. Los capítulos 8, 9 y 10 están dedicados a la presentación y discusión de los resultados obtenidos,

seguidos de las conclusiones finales del proyecto y las recomendaciones sobre las posibles mejoras a implementar en el futuro, con especial énfasis en las tecnologías emergentes en el ámbito de la salud.

Las tecnologías de electroencefalografía (EEG) y magnetoencefalografía (MEG) de alta densidad ofrecen una herramienta efectiva para estudiar la dinámica del cerebro con gran detalle [1]. Al emplear técnicas de análisis de señales eléctricas en las actividades neuronales de áreas específicas de la cabeza, se puede reconstruir digitalmente estas señales con alta resolución en un período breve. Esto facilita la obtención de mediciones en tiempo real que revelan la dinámica temporal de las redes neuronales en todo el cerebro [2].

Las mediciones adquiridas a través del EEG no solo se emplean en la investigación de neurociencia cognitiva y clínica, sino que también han encontrado aplicaciones significativas en campos como la neurología y las polisomnografías (PSG), entre otros. Aunque persiste un debate sobre la exactitud y precisión en la localización de la actividad neuronal mediante métodos no invasivos, la polisomnografía sigue siendo una herramienta diagnóstica fundamental en la evaluación de trastornos del sueño. La PSG permite registrar de manera simultánea la estadificación del sueño, los movimientos oculares, la actividad electromiográfica, los parámetros respiratorios y el electrocardiograma [3]. Las pruebas de PSG estándar incluyen mediciones de neurofisiología como EEG, EOG, EMG, y generalmente también involucran ECG, flujo de aire, oximetría de pulso y canales de posición corporal, junto con monitoreo de video [4].

Las PSG se ha utilizado tanto en entornos clínicos como de investigación y sigue siendo la prueba de diagnóstico clínico estándar de oro para la sospecha de apnea obstructiva del sueño o apnea central del sueño [5]. Sin embargo, debido al costo y a las limitaciones en el acceso a la atención, se han desarrollado e implementado más pruebas, incluida la prueba de apnea del sueño en el hogar al igual que la reciente evolución de los “wearable devices” ha sido una tendencia creciente en la medicina del sueño; sin embargo, pocos han recibido la validación adecuada [6].

Hasta hace poco, el registro de las PSG se solía imprimir en papel para ser posteriormente evaluado por el especialista, lo que complicaba el proceso de llevar registros. Sin embargo, gracias al desarrollo de la tecnología informática, en la actualidad las grabaciones se almacenan en formato digital. Esto facilita su procesamiento y archivo posteriores, lo que

a su vez permite una búsqueda, envío y análisis más rápidos y precisos de las grabaciones y diagnósticos. A pesar de estas ventajas, todavía persisten problemas relacionados con la evaluación visual de estas grabaciones. Un médico experimentado requiere aproximadamente de 90 a 120 minutos para analizar las grabaciones de toda la noche. Por consiguiente, las soluciones de software para trabajar con datos digitales se están desarrollando constantemente [7].

Un software que permite la evaluación automatizada es el toolbox para MATLAB PSGLab, este funciona con registros biomédicos y facilita la interpretación adecuada de datos clínicos. Incluye métodos de preprocesamiento y representación de datos, clasificación, visualización y permite el procesamiento multicanal de diversas señales biomédicas. PSGLab utiliza un formato de archivo predefinido para almacenar datos en todas las etapas del proceso (señales de entrada, clasificación experta, bordes de segmentos, resultados de clasificación, imágenes, gráficos y otros resultados intermedios) [8].

Por su parte, el uso de tecnología de radar sin contacto tienen un gran potencial para la evaluación del sueño en el hogar debido a su naturaleza completamente no intrusiva. Recientemente, se desarrolló un radar IR-UWB con el fin de evaluar el sueño [9]. En un estudio piloto de validación en comparación con la PSG, el radar IR-UWB cuantificó el sueño y la vigilia a través de un algoritmo de machine learning que integraba los movimientos de todas las partes del cuerpo. Los resultados mostraron una pequeña discrepancia general con las estimaciones de la PSG para el tiempo total de sueño a las reportadas en estudios actigráficos [10].

Desde entonces, la tecnología de radar usada y los algoritmos de machine learning para el seguimiento del sueño han continuado mejorando. Estos avances han llevado al desarrollo del asistente de sueño comercialmente disponible Somnofy. Somnofy emplea datos de respiración y movimiento obtenidos a través de tecnología de radar para clasificar las etapas del sueño mediante machine learning. Además de la clasificación de las etapas del sueño, Somnofy está equipado con sensores que recopilan datos del entorno del sueño, incluyendo intensidad de la luz, nivel de ruido audible, temperatura ambiente, calidad del aire, presión del aire y humedad [11].

El sueño es esencial para la función cerebral y física de diversas maneras. A corto plazo, la falta de sueño conduce a problemas de memoria y atención; a largo plazo, puede provocar disfunción neurológica severa o incluso la muerte [12]. Estudios clínicos han revelado que las personas que duermen menos de seis horas cada noche tienen hasta un 12% más de probabilidades de morir prematuramente que aquellas que reciben las 6-8 horas recomendadas [13].

El sueño puede definirse como un estado reversible y recurrente de desconexión perceptiva, conciencia reducida e inmovilidad relativa [14]. Cada noche nos acostamos, cerramos los ojos y perdemos el conocimiento durante varias horas; no solo somos inactivos sino también vulnerables. El sueño es un estado biológico no negociable y esencial para el mantenimiento de la vida humana; nuestra necesidad de dormir es tan crucial como la de respirar, comer y beber agua [15]. La salud del sueño se evalúa mediante varios indicadores, como la regularidad, la satisfacción, el estado de alerta, el tiempo, la eficiencia y la duración del sueño. Estos indicadores, solos y en combinación, interactúan con muchos aspectos de nuestra salud general, incluida la salud cardiovascular, metabólica e inmunológica [16].

Una mala salud del sueño puede dar lugar a trastornos del sueño, los cuales abarcan un conjunto de afecciones que alteran los patrones normales del descanso y son uno de los problemas clínicos más frecuentes. El sueño inadecuado o no reparador puede interferir con el funcionamiento normal en aspectos físicos, mentales, sociales y emocionales, teniendo un impacto crucial en la salud general y la calidad de vida de las personas [17]. Existen diversos tipos de trastornos del sueño, para los cuales la Clasificación Internacional de Trastornos del Sueño (ICSD, por sus siglas en inglés) proporciona una clasificación y definiciones estandarizadas. La ICSD abarca las siguientes categorías de trastornos del sueño: insomnio, trastornos respiratorios del sueño, trastornos centrales de la hipersomnolencia, trastornos del ritmo circadiano, sueño-vigilia, parasomnias y trastornos del movimiento relacionados con el sueño [18].

Los tratamientos para los trastornos del sueño varían según el tipo específico de trastorno. En términos generales, el tratamiento del insomnio se clasifica en tratamientos

no farmacológicos y farmacológicos. Para el tratamiento de la apnea obstructiva del sueño (AOS), se emplean principalmente terapias mecánicas positivas de las vías respiratorias, junto con cambios en el estilo de vida y opciones como aparatos bucales o procedimientos quirúrgicos en ciertos pacientes. El manejo adecuado de los trastornos del sueño requiere la colaboración de un equipo de atención interprofesional que incluya médicos, especialistas y, en algunos casos, una clínica del sueño [18]. El estudio de estos trastornos tradicionalmente se realiza mediante polisomnografía (PSG) y/o cuestionarios. Si bien la PSG es el estándar de oro para evaluar la fisiología del sueño, su costo y carga pueden llegar a ser un factor en contra relevante para la población. La validez ecológica de los resultados del sueño basados en PSG también es deficiente debido a la necesidad de conectar una variedad de sensores al participante y la necesidad de que el participante duerma en un entorno de laboratorio supervisado. Debido a estas limitaciones, algunos estudios del sueño utilizan diarios y cuestionarios sobre el sueño, pero se sabe que tales calificaciones del sueño sufren sesgos subjetivos [19].

Por lo tanto, la actigrafía o acelerometría portátil ha proporcionado un enfoque objetivo, de baja carga y ecológicamente válido para evaluar los patrones circadianos y del sueño del mundo real, contribuyendo con datos valiosos a la información epidemiológica y clínica sobre el sueño y los trastornos del sueño. Los dispositivos acelerómetros que se usan en la muñeca ofrecen una solución atractiva para evaluaciones objetivas del sueño durante varias noches en el entorno natural del hogar. Dichos dispositivos tienen una baja carga para el paciente y pueden recopilar datos de alta resolución de forma continua durante varias semanas sin recargarlos, minimizando así la carga para los participantes. Para derivar los resultados del sueño, se utilizan algoritmos de puntuación automatizados para clasificar el sueño y la vigilia en función de la aceleración de la muñeca. El primer algoritmo de este tipo se desarrolló utilizando regresión lineal simple y se validó contra PSG en 1987 y los coeficientes de la ecuación de regresión lineal se actualizaron en 1992. Este último, denominado Cole-Kripke, se ha convertido en uno de los algoritmos de sueño más utilizados hasta la fecha [19][20].

El aprendizaje automático (*machine learning*) es una subdisciplina de la inteligencia artificial que se centra en cómo las computadoras o programas pueden adquirir la habilidad de identificar patrones, aprender de ejemplos y hacer predicciones basadas en datos históricos sin ser programadas explícitamente para esas tareas [21]. Aplicaciones de inteligencia artificial se utilizan ampliamente en el ámbito de la salud, por ejemplo, en el procesamiento de datos de salud e imágenes de salud o como herramientas de apoyo a la decisión diagnóstica [22]. Esto ha permitido tener un progreso muy rápido en la medicina moderna y exhibe un tremendo potencial en el campo de la salud del sueño, puesto que se analizan distintos canales de datos de manera simultánea, resultando en que a un médico experimentado le tome aproximadamente de 90 a 120 minutos para analizar las grabaciones de toda la noche [20]. Por consiguiente, continuar innovando en estas tecnologías emergentes, como el *machine learning*, ofrecerá soluciones en un futuro cercano.

El objetivo principal de este estudio es desarrollar un algoritmo automatizado utilizando técnicas de *machine learning* para analizar polisomnografías, distinguiendo eficazmente entre los diferentes estadios del sueño y los artefactos que se puedan presentar durante un estudio. Cabe destacar que se encontró una escasa cantidad de artículos enfocados específicamente en el uso de *machine learning* para detectar el riesgo o la presencia de apnea del sueño u otros trastornos del sueño recurrentes en la sociedad. Esto subraya la urgente necesidad de

realizar más investigaciones en esta área para evaluar diversos modelos de machine learning y determinar la mejor estrategia en cuanto a la selección de características y técnicas para lograr los mejores resultados.

### 4.1 Objetivo general

Desarrollar un algoritmo automatizado basado en técnicas de *machine learning* para analizar polisomnografías y detectar estadios del sueño y artefactos.

### 4.2 Objetivos específicos

- Definir un proceso estructurado para la adquisición, limpieza y filtrado de datos de polisomnografía, incluyendo la eliminación de ruidos y artefactos indeseados, mediante el procesamiento de datos en MATLAB.
- Validar los algoritmos desarrollados utilizando datos reales obtenidos de estudios de polisomnografía evaluando los modelos en términos de precisión, así como su capacidad para identificar eventos de interés relacionados con trastornos del sueño con menos de 5% de error en comparación a la evaluación de un técnico del sueño.
- Obtener retroalimentación sobre la utilidad y precisión de los algoritmos desarrollados, por medio de entrevistas y demostraciones a especialistas en trastornos del sueño.

El presente trabajo se limita al desarrollo de un algoritmo automatizado basado en técnicas de *machine learning* para la clasificación de estadios del sueño y la detección de artefactos en estudios de polisomnografía. El enfoque se centra en la implementación y validación del modelo a partir de datos previamente registrados en bases de datos públicas, sin incluir la recolección de nuevas señales fisiológicas.

El procesamiento de señales se lleva a cabo en MATLAB, utilizando registros de polisomnografía en formato EDF provenientes del repositorio de PhysioNet. Se establecen criterios específicos para la limpieza y estructuración de los datos, asegurando la correcta asociación entre las señales fisiológicas y la estadiación realizada por técnicos del sueño. No se contempla la aplicación de técnicas avanzadas de preprocesamiento, como la eliminación de artefactos mediante algoritmos de corrección de señal, más allá de los filtros preexistentes en los registros utilizados.

El entrenamiento del modelo de *machine learning* se basa exclusivamente en los datos segmentados según los estándares de estadiación de sueño. No se incluyen optimizaciones personalizadas para condiciones clínicas específicas ni el uso de datos adicionales fuera de los disponibles en la base de datos y la validación del modelo se realiza mediante métricas de rendimiento establecidas en literatura, comparando los resultados obtenidos con la clasificación realizada por los técnicos del sueño.

Finalmente, la evaluación cualitativa del desempeño del modelo se limita a la retroalimentación proporcionada por técnicos del sueño certificados en Guatemala, sin incluir pruebas extensivas en pacientes ni estudios clínicos adicionales. Es importante aclarar que este modelo no sustituye la evaluación manual realizada por un técnico del sueño, sino que está diseñado como una herramienta de apoyo para facilitar el análisis de grandes volúmenes de datos. Las pruebas y evaluaciones realizadas hasta el momento muestran que el modelo es capaz de realizar clasificaciones precisas bajo condiciones controladas, pero su implementación en un entorno clínico requerirá ajustes adicionales para asegurar su viabilidad en aplicaciones prácticas.

## 6.1 El sueño

El sueño y por qué dormimos sigue siendo uno de los misterios biológicos pendientes de resolver [23] que, aunque el sueño es esencial para el correcto funcionamiento de las personas y animales, aún falta determinar su verdadero propósito evolutivo [24]. A pesar de que todas las especies animales y muchas plantas duermen a diario, todavía no se ha encontrado una respuesta satisfactoria a una de las preguntas fundamentales de la biología: ¿Por qué dormimos? [24]-[26]

Existe gran cantidad de información sobre la fisiología del sueño, lo que nos sucede fisiológicamente durante el sueño y lo que sucede cuando nos privamos de él [23] [27]. El sueño puede entenderse como el cumplimiento de muchas funciones diferentes, pero la intuición sugiere que hay una función esencial [24]. Las teorías restaurativas o recuperativas plantean la hipótesis de que el sueño cumple una o más de las siguientes funciones: descansar y reparar [28]; consolidar lo que hemos aprendido mientras estábamos despiertos [29]; potenciar la respuesta inmunitaria [30]; evitar los graves efectos perjudiciales de la privación de sueño [31]; y desintoxicar [32]. El sueño está influenciado por los ciclos circadianos, los cuales experimentan cambios a medida que envejecemos. Con el paso de los años, los patrones de sueño se modifican, estos cambios incluyen un adelanto en el horario de sueño, una disminución en la duración del sueño nocturno, un aumento en la frecuencia de las siestas diarias, más despertares nocturnos, tiempo de vigilia durante la noche, entre otros factores externos [33].

### 6.1.1 Ritmo circadianos

Dos mecanismos biológicos internos, el ritmo circadiano y la homeostasis, trabajan juntos para regular cuándo está despierto y dormido [34]. La vida en este planeta está adaptada al día solar de 24 horas. A lo largo del tiempo evolutivo, los ciclos diarios predecibles de luz y

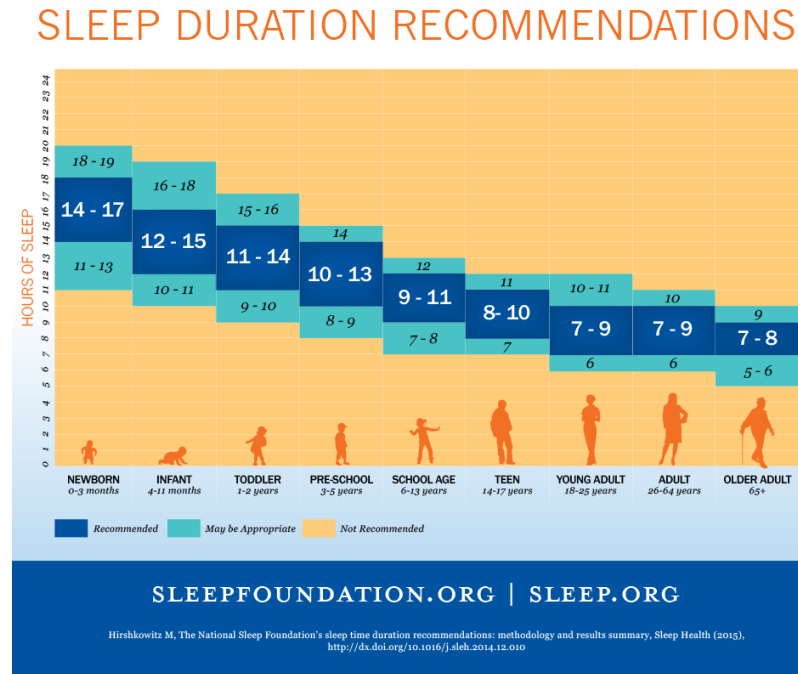
oscuridad se han internalizado en forma de ritmos circadianos [35]. Los ritmos circadianos permiten la sincronización de los procesos biológicos y conductuales con el entorno temporal externo [36]. La luz y la oscuridad son los principales factores que influyen en los ritmos circadianos, aunque la ingesta de alimentos, el estrés, la actividad física, el entorno social y la temperatura también desempeñan un papel importante. La mayoría de los seres vivos, incluyendo animales, plantas y microorganismos, poseen ritmos circadianos. En los humanos, casi todos los tejidos y órganos tienen su propio ritmo circadiano, sincronizándose colectivamente con el ciclo diario de día y noche. Estos ritmos circadianos afectan funciones corporales clave, como los patrones de sueño, la liberación de hormonas, el apetito, la digestión y la temperatura [37] [35].

Los ritmos circadianos se sincronizan con las señales ambientales (luz, temperatura) sobre la hora real del día, pero continúan incluso en ausencia visible de estas señales ambientales [38]. Por su parte, la homeostasis sueño-vigilia realiza un seguimiento de la necesidad de dormir, indicándole al cuerpo cuando es necesario dormir, aunque esto rompa los ritmos circadianos establecidos por parámetros ambientales. El impulso homeostático del sueño le recuerda al cuerpo que duerma después de cierto tiempo y regula la intensidad del sueño. Este impulso del sueño se fortalece cada hora que está despierto y hace que duerma más tiempo y más profundamente después de un período de privación del sueño. Los factores que influyen en sus necesidades de sueño y vigilia incluyen afecciones médicas, medicamentos, estrés, ambiente para dormir y la dieta. Quizás la mayor influencia es la exposición a la luz, ya que las células especializadas en las retinas de los ojos procesan la luz y le dicen al cerebro si es de día o de noche y pueden avanzar o retrasar nuestro ciclo de sueño-vigilia [34].

### **6.1.2 El sueño a lo largo de la edad**

La necesidad de dormir y los patrones de sueño cambian a medida que se envejece, pero estas necesidades varían significativamente de igual manera entre personas de la misma edad (Figura 1). No existe una cantidad exacta de horas de reposo o sueño que funcione para todas las personas de la misma manera. Los bebés duermen inicialmente entre 16 y 18 horas al día, lo que puede estimular el crecimiento y el desarrollo, pero los niños y adolescentes en edad escolar en promedio necesitan alrededor de 9.5 horas de sueño por noche. La mayoría de los adultos necesitan dormir de 7 a 9 horas por noche, pero después de los 60 años, el sueño nocturno tiende a ser más corto, ligero e interrumpido por múltiples despertares [34].

**Figura 1.** Cantidad de sueño recomendado por grupo de edad.



*Nota: Recomendaciones de sueño diario expresadas en horas para distintos grupos de edad. [39]*

Millones de personas están usando aplicaciones para teléfonos inteligentes, monitores junto a la cama y artículos portátiles (incluidos brazaletes, relojes inteligentes y cintas para la cabeza) para recopilar y analizar informalmente datos sobre su sueño. La tecnología inteligente puede grabar sonidos y movimientos durante el sueño, registrar las horas dormidas y controlar los latidos cardíacos y la respiración. Con una aplicación complementaria, los datos de algunos dispositivos se pueden sincronizar con un teléfono inteligente o tableta, o cargarlos en una PC. Otras aplicaciones y dispositivos hacen ruido blanco, producen luz que estimula la producción de melatonina y usan vibraciones suaves para ayudarnos a dormir y despertarnos [34].

## 6.2 Estadios del sueño

Existen dos tipos principales de sueño, el sueño con movimientos oculares rápidos (REM) y el sueño no REM, que se divide en tres etapas distintas: N1, N2 y N3 (también conocido como N4) [40]. Cada tipo de sueño está vinculado a patrones específicos de ondas cerebrales y actividad neuronal. Durante una noche típica, pasamos repetidamente por todas las etapas del sueño REM y no REM, con períodos de sueño REM que se vuelven más largos y profundos a medida que avanza la noche [40]. Aproximadamente el 75 % del sueño se dedica a las etapas no REM, con la mayor parte de este tiempo transcurriendo en la etapa N2 [41]. Una noche típica de sueño consta de 4 a 5 ciclos de sueño, con la progresión de las etapas del sueño

en personas sanas siguiendo el siguiente orden: N1, N2, N3, N2 y REM. Cada uno de estos ciclos completos que se transcurren durante la noche dura aproximadamente de 90 a 110 minutos [42].

### **6.2.1 Etapa de vigilia y etapa N1**

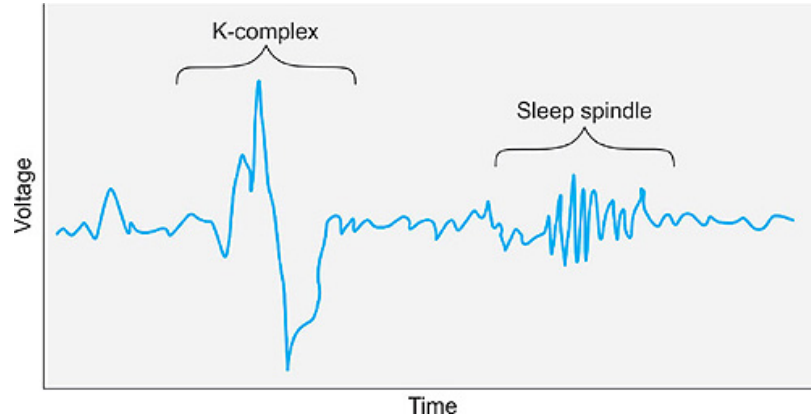
La primera etapa es la etapa de vigilia (W), que depende además de si los ojos están abiertos o cerrados. Durante la vigilia, con los ojos abiertos, predominan las ondas beta las cuales oscilan entre 12 a 35 Hz [43]. Las ondas alfa se convierten en el patrón predominante a medida que las personas se adormecen y cierran los ojos [44].

La etapa 1 del sueño no REM (N1) es el cambio de la vigilia al sueño. Durante este corto período (que dura varios minutos) de sueño relativamente ligero, los latidos del corazón, la respiración y los movimientos oculares disminuyen, y los músculos se relajan con contracciones ocasionales. Las ondas del cerebro comienzan a disminuir a partir de los patrones de vigilia diurna. Esta es la etapa más liviana del sueño y comienza cuando más del 50% de las ondas alfa, las cuales están en el rango de 8 a 12 Hz, se reemplazan con actividad de frecuencia mixta de baja amplitud. El tono muscular está presente en el músculo esquelético y la respiración ocurre regularmente. Esta etapa dura alrededor de 1 a 5 minutos y comprende el 5% del tiempo total de sueño [40].

### **6.2.2 Etapa N2**

El sueño no REM de la etapa 2 (N2) es un período de sueño ligero antes de entrar en un sueño más profundo. Los latidos del corazón y la respiración disminuyen, y los músculos se relajan aún más. La temperatura del cuerpo desciende y los movimientos oculares se detienen. La actividad de las ondas cerebrales disminuye, pero se caracteriza por breves ráfagas de actividad eléctrica. La mayor parte del tiempo de los ciclos repetidos de sueño se mantienen en esta etapa 2 del sueño en comparación a otras etapas del sueño. Esta etapa representa un sueño más profundo a medida que disminuyen la frecuencia cardíaca y la temperatura corporal. La presencia de husos del sueño, complejos K o ambos lo caracteriza [40]. Los husos del sueño son breves y poderosas ráfagas de activación neuronal en las circunvoluciones temporales superiores, el cíngulo anterior, las cortezas insulares y el tálamo, que inducen la entrada de calcio en las células piramidales corticales. Se cree que este mecanismo es integral a la plasticidad sináptica. Numerosos estudios sugieren que los husos del sueño son esenciales en la consolidación de la memoria, específicamente la memoria procesal y declarativa [45]. Por su parte, los complejos K son ondas bifásicas agudas, bien delineadas, de alto voltaje, que duran más de 0,5 segundos [46]. En el EEG, fue descrito por Laurino et al. como tener un pico de voltaje positivo corto, que generalmente es de 200 milisegundos, seguido de un complejo negativo grande de alrededor de 550 milisegundos y, finalmente, un pico positivo de larga duración de 900 milisegundos (Figura 2) [47]. El sueño en la etapa 2 dura alrededor de 25 minutos en el primer ciclo y se alarga con cada ciclo sucesivo, llegando a comprender aproximadamente el 45% del sueño total [40].

**Figura 2.** Huso del sueño y complejo K.



*Nota: Onda aguda negativa de alta amplitud seguida de ondas lentas positivas, característica de los estadios N2 del sueño. [48]*

### 6.2.3 Etapa N3


El sueño no REM en la etapa 3 (N3) es el período de sueño profundo que necesita para sentirse renovado al despertar. Ocurre en períodos más largos durante la primera mitad de la noche. Los latidos del corazón y la respiración disminuyen a sus niveles más bajos durante el sueño. Los músculos del cuerpo están relajados y las ondas cerebrales se vuelven aún más lentas. El N3 también se conoce como sueño de ondas lentas (SWS, por sus siglas en inglés) [40]. Esta se considera la etapa más profunda del sueño y se caracteriza por señales con frecuencias más bajas y amplitudes más altas, conocidas como ondas delta. En esta etapa es más difícil despertar debido a la profundidad del sueño y a medida que las personas envejecen, pasan menos tiempo en este sueño lento de ondas delta y más tiempo en el sueño de la etapa N2. Esta es la etapa en la que el cuerpo repara y regenera tejidos, desarrolla huesos y músculos y fortalece el sistema inmunológico. Esta es también la etapa en la que ocurren el sonambulismo, los terrores nocturnos y la enuresis nocturna [40].

### 6.2.4 Etapa REM

Por su parte, el sueño REM ocurre por primera vez unos 90 minutos después de quedarse dormido. Sus ojos se mueven rápidamente de un lado a otro detrás de los párpados cerrados. La actividad de las ondas cerebrales de frecuencia mixta se acerca a la observada en la vigilia, la respiración se vuelve más rápida e irregular, y la frecuencia cardíaca y presión arterial aumentan hasta niveles cercanos a la vigilia. El REM se asocia con los sueños y no se considera una etapa de sueño reparador. Si bien el EEG es similar a un individuo despierto, los músculos esqueléticos son atónicos y sin movimiento, excepto los ojos y los músculos diafragmáticos, que permanecen activos. Sin embargo, la frecuencia respiratoria es más errática e irregular. Esta etapa generalmente comienza 90 minutos después del estado de sueño, y cada ciclo REM aumenta a lo largo de la noche. El primer ciclo generalmente dura 10 minutos, y el ciclo final dura hasta 1 hora [49]. La etapa REM también es asociada con

la pérdida del tono motor, aumento de la oxigenación en el cerebro, aumento y variación del pulso y la presión arterial, ya que las ondas demuestran que el cerebro está muy activo durante el sueño REM, lo que aumenta el metabolismo cerebral hasta en un 20 % [50]. Después de quedarse dormido, un individuo comienza con el sueño REM y luego progresa a través de la Etapa 1, la Etapa 2 y la Etapa 3 del sueño NREM. Luego vuelven progresivamente al sueño REM. A medida que avanza la noche, una persona pasa menos tiempo en sueño profundo y más tiempo en sueño REM. (Figura 3)

**Figura 3.** *Ciclo de sueño típico durante un periodo de descanso.*



*Nota: En cada ciclo se modifica la proporción de tiempo dedicada a las distintas etapas del sueño. [51]*

## 6.3 Polisomnografía

La polisomnografía (PSG) se define como el monitoreo continuo y el registro simultáneo de la actividad fisiológica durante el sueño [52]. Es considerada como el estándar de oro para el diagnóstico de trastornos relacionados con el sueño e implica la medición de biopotenciales empleando múltiples canales de parámetros fisiológicos que incluyen: electroencefalografía (EEG), electrooculografía (EOG), electromiografía (EMG), electrocardiografía (ECG), esfuerzo respiratorio, flujo de aire y saturación de oxígeno. Los canales adicionales pueden incluir un dispositivo de monitorización de ronquidos, electrodos tibiales anteriores, sensores de luz, múltiples micrófonos en el espacio de estudio y cámaras de video [53].

### 6.3.1 Estandarización de la polisomnografía

En general, una PSG estándar requiere al menos cuatro canales de neurofisiología: EEG, EOG en ambos ojos y EMG [54]. Esto con el fin de generar un registro simultáneo

de la actividad eléctrica del cerebro, los movimientos oculares, el tono electromiográfico y variaciones del ritmo cardiaco al dormir lo cual en conjunto permite una correcta estadificación del sueño al igual que la evaluación de trastornos del sueño y su manejo [3]. Debido a la importancia de los diagnósticos mediante polisomnografías, la Academia Estadounidense de Medicina del Sueño (AASM) desarrolló el *Manual de Puntuación del Sueño y los Eventos Asociados* (versión 2.6), con el fin de establecer criterios universalmente aceptados para la técnica de registro estándar y las pautas de puntuación aplicadas en estos estudios por especialistas del sueño[55]. Durante el análisis de una PSG, el sueño se organiza en épocas de 30 segundos, con criterios y definiciones específicas para la vigilia y cada una de las etapas del sueño.

El EEG se registra en las regiones frontal, central y occipital para definir las diferentes etapas del sueño[54]. El electrooculograma (EOG) y la electromiografía del mentón (EMG) ayudan particularmente a identificar el sueño REM, caracterizado por movimientos oculares rápidos. Para detectar trastornos respiratorios, los sensores de presión nasal registran el flujo de aire y permiten identificar limitaciones parciales, útiles para el diagnóstico de hipoapneas, mientras que los sensores de flujo térmico oronasal detectan obstrucciones completas del flujo de aire, fundamentales para el diagnóstico de apneas. Las apneas se clasifican como obstructivas, mixtas o centrales mediante el uso de sensores torácicos y abdominales que evalúan el esfuerzo respiratorio[56]. Adicionalmente, la oximetría de pulso permite medir la saturación de oxígeno arterial, y el ECG registra la frecuencia y el ritmo cardíaco. Los electrodos de EMG en la tibia anterior detectan movimientos periódicos de las extremidades durante el sueño, y la medición de CO<sub>2</sub> ayuda a identificar casos de hipoventilación (Figura 4) [56].

**Figura 4.** Registro polisomnográfico.



*Nota: Señales electrofisiológicas registradas durante un estudio de sueño. [54]*

La electroencefalografía es una técnica no invasiva en la que se registra la actividad eléctrica del cerebro desde el cuero cabelludo mediante el uso de electrodos superficiales y generalmente con gel conductor para mejorar la calidad de las señales eléctricas de las poblaciones de neuronas [57]. Mediante esta técnica, se registran y amplifican las diferencias de voltaje entre los electrodos colocados en diferentes regiones del cuero cabelludo y tiene bastas aplicaciones en las que encontramos el diagnóstico de trastornos del sueño [55]. Por su parte, los músculos oculares producen una diferencia de potencial eléctrico con origen entre el epitelio pigmentario corneal y la retina [58]. Este diferencial se puede adquirir mediante el uso de la técnica no invasiva de la electrooculografía (EOG). El EOG se obtiene mediante electrodos superficiales colocados en la cara a los alrededores de las zonas oculares, registrando el canal horizontal (movimientos izquierda-derecha) y el canal vertical (movimientos arriba y abajo) de los ojos [45].

De manera similar, la electromiografía (EMG) mide los biopotenciales del sistema nervioso cuando esta se manifiesta durante la contracción de los músculos esqueléticos. Los movimientos voluntarios o por reflejos, que se originan en el cerebro, darán como repuesta la activación de los músculos esqueléticos [59]. Por lo que este proceso bioquímico por el cual

un músculo se contrae producen un campo eléctrico que se puede medir haciendo uso de la electromiografía por vía intramuscular o en nuestro caso, desde la superficie de la piel con el uso de electrodos superficiales que se colocan en la piel.

La Asociación Estadounidense de Trastornos del Sueño ha clasificado la monitorización portátil en cuatro tipos. Tipo I: Polisomnografía asistida; Tipo II: Polisomnografía no asistida; Tipo III: Prueba de apnea del sueño portátil modificada (mínimo 4 canales); Tipo IV: Registro continuo de uno o dos bioparámetros [60]. Una sola noche de PSG puede no detectar casos leves de apnea obstructiva del sueño (AOS), movimientos periódicos de las piernas (PLMS), parasomnias, crisis nocturnas u otros eventos episódicos. Además, los datos de PSG pueden no coincidir con el historial clínico del paciente; el estudio puede verse afectado por factores externos relacionados con la habitación en la que se realiza el estudio y la PSG estándar no mide la presión arterial parcial de dióxido de carbono, por lo que podría pasar por alto casos de hipoventilación.


### 6.3.2 Registros de EEG durante PSG

Para las mediciones de electroencefalografía, el sistema 10-20 de la federación internacional es un método reconocido internacionalmente que utiliza puntos de referencia anatómicos para estandarizar la colocación de electrodos (EEG) y registrar la actividad eléctrica del cerebro de manera correcta [61]. El sistema se basa en la relación entre la ubicación de los electrodos y el área subyacente de la corteza cerebral, al tiempo que garantiza que todas las regiones cerebrales estén cubiertas. Los números “10” y “20” se refieren a las distancias entre electrodos adyacentes, que son el 10 % o el 20 % de la distancia total (de adelante hacia atrás o de derecha a izquierda) del cráneo. El EEG es la variable principal para documentar las etapas de vigilia, excitación y sueño durante el estudio del sueño. Un único canal central referenciado a un sitio mastoideo del oído (C4-M1), un único canal frontal referenciado a un sitio mastoideo del oído (F4-M1) y un único canal occipital referenciado a un sitio mastoideo del oído (O2-M1) es suficiente para evaluar las formas de onda [55]. El mastoides se encuentra posterior a cada oreja. Sin embargo, se recomiendan canales adicionales (C3-M2, F3-M2, O1-M2) para proporcionar redundancia en caso se produzca algún mal funcionamiento de los electrodos anteriores, el posicionamiento de todos estos electrodos acorde al sistema 10-20 (Figura 5.)

Para el registro de electroencefalografía se deben usar electrodos de copa de oro y plata, de igual manera es importante limpiar la piel donde se colocarán los electrodos. Esto se realiza para disminuir la resistencia entre la piel y los electrodos, al igual que se usan cremas especializadas o geles que aumenten la conductividad de los electrodos y asegurarse de que los electrodos permanezcan en su lugar durante toda la noche [54]. Durante la vigilia (estado W), el electroencefalograma refleja una corteza cerebral activa involucrada en la percepción y las funciones cognitivas que muestra un voltaje bajo y alta frecuencia, la cual se relaciona con la actividad neuronal que desempeñamos al estar despiertos por lo que los canales del EEG registra la predominancia de ondas beta [43]. Cuando los ojos se cierran al empezar a dormir, múltiples neuronas muestran descargas sincrónicas a una frecuencia de 12 por segundo, constituyendo ondas alfa. Por su parte, si los ojos se abren después, la actividad del cerebro aumenta nuevamente, pero la sincronidad de las señales disminuye, lo que conduce a la cancelación de las ondas cerebrales. Como resultado de esto, aparecen

ondas débiles con patrones irregulares y de frecuencia más alta, que se denominan ondas beta, lo que indica el paso del estado de vigilia a comienzos del sueño (estado N1) [55]. La etapa 2 (N2) se caracteriza por la presencia de actividad theta bilateralmente sincrónica acompañada de husos del sueño o complejos K, los husos del sueño se definen como ondas distintas de 12 a 14 Hz que pueden llegar a tener frecuencias de 11 a 16 Hz con una duración mayor a 0.5 segundos [62]. La etapa 3 (N3) se caracteriza por una amplitud notablemente mayor a las demás etapas y notable desaceleración delta en el intervalo de 0.5 a 4 Hz con amplitudes iguales a  $75 \mu\text{V}$ . La etapa de REM (R) se caracteriza por la presencia de movimientos oculares rápidos y los registros de EEG son notablemente similares a las del estado despierto con una amplitud ligeramente menor [62].

**Figura 5.** *Electrodos EEG y actividad según la etapa del sueño.*




*Nota: a) Sistema internacional 10-20 para la colocación de electrodos EEG [63]. b) Cambios en la actividad del electroencefalograma según la etapa del sueño [59].*

### 6.3.3 Registros de EOG durante PSG

El objetivo de tener grabaciones de electrooculografía durante la polisomnografía es identificar los movimientos oculares. El registro de EOG ayuda a identificar varias etapas del sueño. Por ejemplo, los movimientos oculares lentos y giratorios se observan típicamente durante el sueño en la etapa N1 y los movimientos oculares rápidos ocurren durante el sueño en la etapa R (REM) [55]. Este registro es, de hecho, el registro de la diferencia de voltaje entre la córnea y la retina, la cual se produce dependiendo del movimiento de los ojos. Para esta medición, se recomiendan al menos dos canales de EOG. Cada canal de EOG registra desde un electrodo colocado 1 cm lateral y por encima (E2) o 1 cm lateral y por debajo (E1) del canto externo del ojo. Un desplazamiento igual de los electrodos asegura la misma amplitud de los movimientos oculares conjugados.

**Figura 6.** *Posicionamiento de electrodos para EOG.*




*Nota: Ubicación de los electrodos E1 y E2 para el registro de los movimientos oculares mediante electrooculografía (EOG). Elaboración propia.*

#### **6.3.4 Registros EMG durante PSG**

El registro de la actividad EMG en el área del mentón se usa para determinar el nivel de tono muscular, que disminuye gradualmente a medida que uno progresa a través de las etapas más profundas del sueño, por lo que es importante para detectar el estadio de sueño REM. Se deben colocar tres electrodos para registrar la EMG del mentón de la siguiente manera: uno colocado en la línea media 1 cm por encima del borde inferior de la mandíbula, uno 2 cm por debajo del borde inferior y 2 cm a la izquierda de la línea media, y uno colocado 2 cm por debajo del borde inferior y 2 cm a la derecha de la línea media [55].

**Figura 7.** *Posicionamiento de electrodos para EMG.*

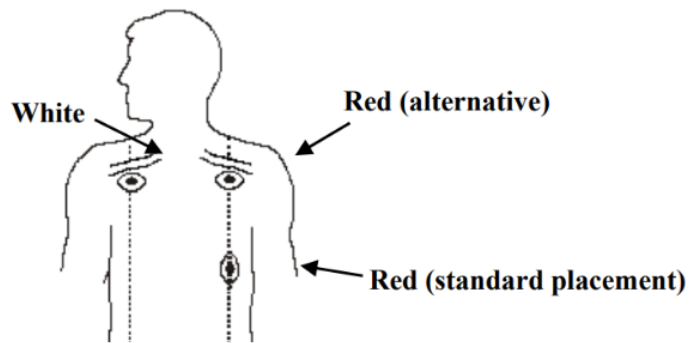


*Nota: Disposición de los electrodos CHz, CH1 y CH2 para el registro de actividad muscular mediante electromiografía (EMG) submentoniana. Elaboración propia.*

### 6.3.5 Registros ECG durante PSG

El ECG controla el ritmo cardíaco y sus cambios mientras se duerme, por lo que un solo canal de ECG es suficiente para la monitorización PSG estándar. Los dos electrodos de ECG estándar se aplican en un formato de derivación II. Se coloca un electrodo debajo de la clavícula derecha en paralelo al hombro derecho y se coloca un segundo electrodo en el torso en el cuarto espacio intercostal en el lado izquierdo paralelo a la cadera izquierda, de igual manera es posible ubicar un tercer electrodo de referencia debajo de la clavícula izquierda en paralelo al hombro izquierdo para la recolección de datos [55].

**Figura 8.** *Posicionamiento de electrodos para ECG.*



*Nota: Ubicación típica de los electrodos utilizados para la adquisición de la señal electrocardiográfica (ECG) durante una polisomnografía. [64]*

### 6.3.6 Registros de SpO2 y respiración durante PSG

El diagnóstico de apnea obstructiva del sueño durante la página estándar requiere el monitoreo continuo y la visualización de los niveles de saturación de oxígeno en la sangre para proporcionar información crucial sobre la gravedad del trastorno respiratorio relacionado con el sueño [65]. La oximetría de pulso transmite dos longitudes de onda de luz a través de un lecho vascular pulsátil para medir la saturación arterial de oxígeno [66]. La oximetría de pulso es con frecuencia el método utilizado para controlar los niveles de oxígeno en sangre durante la PSG idealmente empleando un sensor SpO2 para dedo [55]. Los canales de flujo de aire y esfuerzo respiratorio se utilizan durante la PSG para monitorear la respiración y detectar la presencia de apneas, hipopneas, despertares relacionados con el esfuerzo respiratorio y otros eventos respiratorios relacionados con el sueño. Es importante registrar al menos tres parámetros respiratorios: flujo de aire nasal/oral, esfuerzo torácico y esfuerzo abdominal [55].

**Figura 9.** *Posicionamiento de sensores para oximetría y bandas de esfuerzo.*



*Nota: Sensor de oximetría colocado en el dedo y bandas elásticas torácica y abdominal para la medición del esfuerzo respiratorio. Elaboración propia.*

### **6.3.7 Registro de observación conductual durante PSG**

Para un diagnóstico adecuado, es necesario tener la capacidad de observar y escuchar al paciente durante el registro de la PSG, así como para la evaluación clínica y técnica. La recomendación es utilizar tanto el monitoreo de audio como la grabación de video digital que esté sincronizada con la grabación PSG, tales registros serán de gran utilidad para confirmar ronquidos, movimientos de piernas, despertares nocturnos, terrores nocturnos, entre otros [55].

### **6.3.8 Análisis y calificación de una PSG**

Los estándares de las grabaciones de polisomnografía varían ampliamente, al igual que su interpretación, lo cual hace fundamental contar con procedimientos operativos estandarizados. Para un manejo adecuado de los pacientes, es esencial que el técnico del sueño esté capacitado y familiarizado con el procedimiento, brindando así un apoyo continuo durante la prueba. (Figura 10) Los hallazgos normales esenciales en una PSG son las etapas del sueño, las cuales son fundamentales para su interpretación. La puntuación de las etapas del sueño se basa en criterios de EEG, EOG y EMG submentoniano. Inicialmente, este sistema de puntuación fue detallado por Rechtschaffen y Kales (R&K), pero actualmente ha sido reemplazado por el manual de puntuación de la AASM el cual mantiene una consistencia considerable con el manual original y se actualiza regularmente [67].

El sueño se clasifica en secciones de 30 segundos, conocidas como épocas, y se asigna únicamente una etapa de sueño a cada época. Si dos o más etapas coexisten durante una única época, se asignará la etapa que ocupe la mayor parte de la época. Tanto el

neurólogo como el técnico del sueño son responsables de garantizar un registro de alta calidad, priorizando siempre la seguridad y el bienestar del paciente. Deben estar capacitados para detectar y corregir artefactos, registrar todos los eventos anormales y estar atentos ante posibles intentos del paciente de levantarse de la cama. Asimismo, deben ser capaces de identificar y manejar emergencias médicas, y contar con un conocimiento sólido sobre el funcionamiento de dispositivos ventilatorios como CPAP, BiPAP y otros [60].

Para identificar la etapa del sueño en una época, el EEG es fundamental, ya que muestra varios patrones de ondas reconocibles visualmente desde la vigilia hasta las diferentes etapas del sueño. Estos patrones se describen principalmente en términos de frecuencia, amplitud y morfología:

- Alfa: 8 a 13 Hz
- Beta:  $> 13$  Hz
- Theta: 4 a 7.99 Hz
- Delta:  $< 4$  Hz

La amplitud mide el voltaje de las ondas de EEG y varía según la etapa del sueño. La morfología general de las ondas también aporta información sobre la etapa de sueño. Por ejemplo, los complejos K y los husos de sueño característicos únicamente de la etapa N2. Las ondas en dientes de sierra, de 2-6 Hz y con apariencia serrada y amplitud máxima en las derivaciones centrales, pueden observarse durante o antes de la etapa R (REM) [68].

La puntuación del estadio de vigilia (W) en un PSG depende de si el paciente tiene los ojos abiertos o cerrados. Con los ojos abiertos, el EEG muestra ondas de baja amplitud y frecuencia mixta (LAMF), predominantemente en el rango de 4-7 Hz. El EOG evidencia parpadeo, movimientos oculares de lectura, o movimientos oculares rápidos, bruscos y conjugados. El EMG del mentón presenta un tono alto. Se califica como estadio W cuando más del 50% de una época muestra actividad alfa y patrones consistentes con estas características [69].

La etapa N1 representa la transición de la vigilia al sueño. En el EEG, predominan las ondas LAMF theta. El EOG muestra movimientos oculares lentos y rodados, mientras que el tono EMG del mentón es más bajo que en vigilia, pero superior al observado en el sueño REM. Una época se clasifica como N1 cuando más del 50% cumple con estas características en ausencia de evidencia de otra etapa del sueño [69].

La etapa N2 se caracteriza por la presencia de complejos K y husos de sueño, sobre un fondo de actividad EEG de baja amplitud y frecuencia mixta. En el EOG generalmente no hay movimientos oculares, y el tono EMG del mentón suele ser más bajo que durante la vigilia. La puntuación de N2 se asigna cuando se observa un complejo K sin una activación asociada o un huso de sueño en la primera mitad de la época actual o la última mitad de la época anterior, con menos del 20% de actividad de ondas lentas. Esta etapa persiste hasta una transición hacia N3, REM, un despertar, o un movimiento corporal significativo seguido de movimientos oculares lentos [69].

La etapa N3, el sueño más profundo, se caracteriza por ondas lentas y de alta amplitud. Predominan las ondas delta, con una frecuencia entre 0.5 y 2 Hz y amplitudes superiores a

75 microvoltios. El EOG generalmente no muestra movimientos oculares, y el tono del EMG es variable, aunque suele ser más bajo que en N2. Esta etapa se clasifica cuando más del 20% de una época (6 segundos) cumple con estos criterios de frecuencia y amplitud [69].

La etapa REM, o sueño de movimientos oculares rápidos, se identifica por movimientos oculares rápidos visibles en el EOG, similares a los de la vigilia. En el EEG, se observa una actividad LAMF sin complejos K ni husos del sueño. El tono del EMG en el mentón disminuye notablemente con respecto a las etapas anteriores. Las ondas en diente de sierra pueden estar presentes, aunque no siempre. Se clasifica como estadio REM cuando se cumplen los tres criterios de EOG, EMG y EEG [69].


Para la correcta interpretación de la polisomnografía, la sala de grabación en donde se realice la prueba debe ser insonorizada, cómoda, tener colores suaves y relajantes en la pared; debe haber una instalación para video con las luces apagadas y una cámara de video infrarroja. El técnico debe poder ver desde su estación el video del paciente y monitorearlo continuamente. Se requiere intervención si las señales fisiológicas se pierden debido a problemas con la instrumentación o sufre de fluctuaciones erróneas debido a artefactos. Se recomienda tener inodoro adjunto en la habitación para la comodidad de los pacientes con el fin de hacerlos sentir lo más cómodos posible. Se debe alentar al paciente a llevar consigo objetos asociados con el sueño y todas las medidas para ayudar a prevenir indeseados relacionados con dormir por primera vez en un lugar desconocido [60]. Los datos que se registrarán para el análisis posterior en el estudio son los que se indican a continuación.

- Datos de puntuación del sueño
  - Hora de apagado de luces en la habitación (h:min)
  - Hora de encendido de luces en la habitación (h:min)
  - Tiempo total de sueño (TST; min)
  - Tiempo total de grabación (de luces apagadas a luces encendidas en minutos)
  - Latencia del sueño (del tiempo de apagado de luces hasta el primer estadio de sueño observado)
  - Vigilia después del inicio del sueño (Total de minutos que una persona está despierta después de haberse quedado dormida inicialmente)
  - Porcentaje de eficiencia del sueño (TST / Tiempo total de grabación)
- Eventos de despertares
  - Número de despertares posteriores al inicio del sueño
- Eventos respiratorios
  - Número de apneas obstructivas
  - Número de apneas mixtas
  - Número de apneas centrales
  - Número de hipopneas
  - Número de apneas + hipopneas
  - Desaturaciones de oxígeno  $\geq 3\%$  o  $\geq 4\%$  - número total

- Saturación continua de oxígeno, valor medio
- Saturación mínima de oxígeno
- Aparición de hipoventilación
- Eventos cardíacos
  - Frecuencia cardíaca promedio
  - Frecuencia cardíaca máxima durante el sueño
  - Bradicardia
  - Taquicardia
- Eventos de movimiento
  - Número de movimientos periódicos de las piernas

Para la visualización de la PSG, se recomienda que la resolución de la pantalla sea de al menos  $1600 \times 1200$ , permitiendo así el análisis detallado de los datos brutos de PSG. La visualización debe incluir un histograma que muestre las etapas de sueño, eventos respiratorios, movimientos de las piernas, saturación de O<sub>2</sub> y despertares. Además, la escala de visualización debe permitir observar tanto el registro completo de toda la noche como ventanas más pequeñas, de hasta 5 segundos [60].

**Figura 10.** *Evaluación de un polisomnograma por un técnico del sueño.*



*Nota: Visualización e interpretación de señales polisomnográficas por parte de un técnico del sueño. [54]*

## 6.4 *Machine learning*

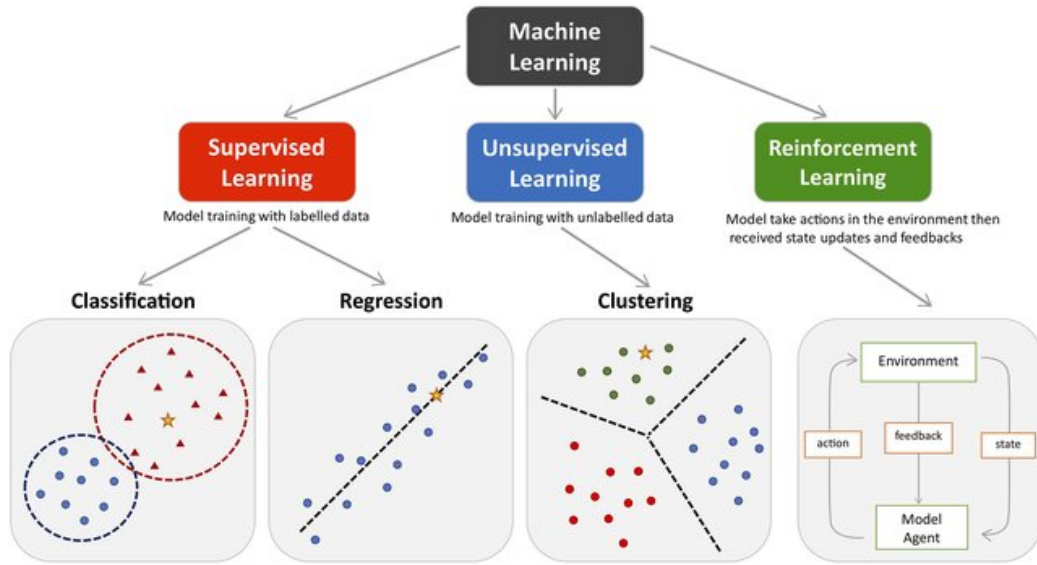
El aprendizaje automático, también conocido como *Machine Learning* (ML) por sus siglas en inglés, es un concepto amplio que abarca diversos algoritmos destinados a realizar predicciones inteligentes de conjuntos de datos nuevos basadas en conjuntos de datos existentes. Estos conjuntos de datos suelen ser muy grandes y aunque es una rama considerablemente nueva, los recientes avances en el aprendizaje automático han alcanzado un nivel de comprensión semántica y extracción de información similar al humano, y en

algunos casos, superan a los expertos humanos en la detección de patrones abstractos [70]. El *machine learning* es una rama de la inteligencia artificial que facilita la automatización en la creación de modelos analíticos, permitiendo que las máquinas se adapten de manera autónoma a nuevos escenarios. Esto posibilita que el software anticipe y responda eficazmente a situaciones futuras basándose en resultados anteriores [71]. Los algoritmos de aprendizaje se dividen principalmente en cuatro categorías: aprendizaje supervisado, aprendizaje no supervisado, aprendizaje semisupervisado y aprendizaje reforzado [72].

#### 6.4.1 Tipos de *machine learning*

El aprendizaje supervisado es la rama del ML que consiste en aprender una función que asigna una entrada a una salida nueva en función de pares de entradas y salidas conocidas de set de datos [73]. Este método utiliza datos de entrenamiento etiquetados y una colección de ejemplos de entrenamiento para determinar un algoritmo funcional en datos nuevos. El aprendizaje supervisado se aplica cuando se identifican ciertos objetivos que deben lograrse a partir de un conjunto específico de muestras [74]. El aprendizaje no supervisado analiza conjuntos de datos sin ninguna referencia en específico y, sin la necesidad de interferencia humana, es decir, un proceso impulsado puramente por datos [73]. Esto se usa ampliamente para extraer características propias de los datos, identificar tendencias en datos, agrupaciones en resultados y realizar exploraciones en grupos con gran cantidad de datos. Las tareas de aprendizaje no supervisadas más comunes son aprendizaje de características, reducción de dimensionalidad, búsqueda de reglas de asociación, detección de anomalías, entre otras [75]. Por su parte, el aprendizaje semisupervisado puede definirse como la mezcla de los métodos supervisados y no supervisados mencionados anteriormente, ya que opera tanto con datos etiquetados como sin etiquetar [73]. Algunas áreas de aplicación en las que se utiliza el aprendizaje semisupervisado incluyen la clasificación automática de textos, traducción automática, detección de fraudes, entre otros [75]. El aprendizaje por refuerzo es un tipo de algoritmo de aprendizaje automático que permite a los agentes y máquinas de software evaluar automáticamente el comportamiento óptimo en un contexto o entorno particular para mejorar su eficiencia (Figura 11) [76].

Figura 11. Tipos principales de aprendizaje automático.



Nota: Clasificación, regresión y agrupamiento como ejemplos de aprendizaje supervisado y no supervisado. En el aprendizaje por refuerzo, el modelo mejora su desempeño al interactuar con el entorno. Los puntos y triángulos representan datos de entrenamiento; las estrellas amarillas, predicciones del modelo. [77]

#### 6.4.2 Tipos de aprendizaje supervisado


El algoritmo de k-vecinos más cercanos (*KNN*, por sus siglas en inglés) es un algoritmo de aprendizaje automático supervisado que se utiliza predominantemente para fines de clasificación y ha sido ampliamente utilizado en la predicción de enfermedades [78]. El *KNN*, siendo un algoritmo supervisado, predice la clasificación de datos no etiquetados considerando las características y las etiquetas de los datos de entrenamiento. Generalmente, el algoritmo *KNN* es capaz de clasificar conjuntos de datos utilizando un modelo de entrenamiento, tomando en cuenta los *k* puntos de datos de entrenamiento más cercanos (vecinos) al dato que se busca predecir (Figura 12). Finalmente, el algoritmo realiza una regla de votación mayoritaria para determinar qué clasificación finalizar. Entre todos los algoritmos de aprendizaje automático, el *KNN* es una de las formas más simples y se usa ampliamente en tareas de clasificación debido a su diseño altamente adaptable y fácil de entender [79]. El algoritmo es reconocido por su uso en la resolución de desafíos de regresión y clasificación para datos de diferentes tamaños, cantidades de etiquetas, niveles de ruido, rangos y contextos [80].

El algoritmo clásico de *KNN* presenta diversas limitaciones que reducen su capacidad de clasificación, como la falta de sesgo hacia todos sus vecinos dependientes de la clasificación, la ausencia de características para el cálculo de distancias entre puntos de datos, y el hecho de considerar características innecesarias del conjunto de datos [81]. Sin embargo, dado que el *KNN* es adaptable a numerosas modificaciones, ha dado lugar a diferentes variantes del algoritmo. Las variantes del *KNN* difieren en varios aspectos algorítmicos, como la

optimización del parámetro  $k$ , la mejora en los cálculos de distancia, la asignación de pesos a diferentes puntos de datos y la reducción de los conjuntos de datos de entrenamiento para resolver los desafíos mencionados anteriormente [80].

El  $KNN$  con ajuste de peso ( $W-KNN$ ) se enfoca en la aplicación de ponderación de atributos. Este algoritmo asigna primero un peso a cada uno de los puntos de datos de entrenamiento utilizando una función conocida como la función núcleo. Esta asignación de peso tiene como objetivo otorgar mayor peso a los puntos cercanos, mientras que asigna menor peso a los puntos distantes. A medida que la distancia aumenta, se puede utilizar cualquier función que disminuya el valor, como función núcleo. La frecuencia de todos los vecinos más cercanos se utiliza luego para predecir la clase de salida de un punto de datos de prueba determinado. Esta variante de  $KNN$  considera la importancia de clasificación de diferentes atributos al definir la función núcleo para un conjunto de datos multiatributo [82].


**Figura 12.** Ejemplo del método de clasificación  $KNN$ .



*Nota: Representación gráfica del algoritmo  $K$ -Nearest Neighbors, que clasifica una nueva muestra en función de la mayoría de sus vecinos más cercanos. [83]*

Una red neuronal es un conjunto de algoritmos diseñados para reconocer patrones subyacentes en conjuntos de datos, emulando el funcionamiento del cerebro humano. Estas redes pueden adaptarse a entradas cambiantes, generando resultados óptimos sin necesidad de rediseñar los criterios de salida [79]. En el contexto de la inteligencia artificial, las redes neuronales artificiales se componen de tres capas principales. La capa de entrada que recibe los datos iniciales, la capa oculta encargada de procesar la información recibida y la capa de salida que proporciona el resultado calculado. Cada capa está formada por nodos o “neuronas” artificiales que realizan cálculos específicos. Las conexiones entre estas neuronas tienen pesos que determinan la influencia de una neurona sobre otra (Figura 13). Durante el proceso de entrenamiento, estos pesos se ajustan para minimizar el error en las predicciones de la red. Las redes neuronales son fundamentales en el aprendizaje profundo y se aplican en diversas áreas, como el reconocimiento de voz, la visión por computadora y la predicción de series temporales [84].

**Figura 13.** *Funcionamiento de una red neuronal.*




*Nota: Esquema de una red neuronal artificial, donde cada nodo representa una neurona artificial que procesa la información mediante pesos sinápticos, funciones de activación y capas ocultas. [85]*

El aprendizaje en conjunto (*Ensemble method* en inglés) es el proceso mediante el cual se generan y combinan estratégicamente múltiples modelos, como clasificadores o expertos, para resolver un problema específico de inteligencia computacional. Se utiliza principalmente para mejorar el rendimiento de un modelo o reducir la probabilidad de seleccionar un modelo deficiente. Otras aplicaciones del aprendizaje en conjunto incluyen la asignación de una medida de confianza a la decisión tomada por el modelo, la selección de características óptimas, la fusión de datos, el aprendizaje incremental, el aprendizaje no estacionario y la corrección de errores [79].

Un árbol de decisión individual es un modelo débil, pero al combinar varios árboles de decisión se obtiene un modelo más robusto, lo que mejora significativamente el rendimiento [79]. Aunque el aprendizaje en conjunto, como el *bagging* (*Bootstrap Aggregating*), puede ser costoso en tiempo, mejora la precisión y estabilidad del modelo. Esta técnica reduce la varianza y el sobreajuste mediante la agregación de las predicciones de múltiples árboles de decisión. El *bagging* se basa en crear múltiples muestras aleatorias (bolsas) del conjunto de entrenamiento, con aproximadamente el 60% de los datos en cada bolsa. Cada árbol se entrena con una bolsa diferente y las predicciones se combinan usando el modo para clasificación y la media para regresión. Entre las técnicas populares que utilizan *bagging* se encuentran los Bosques Aleatorios (*Random Forests*), que submuestran tanto observaciones como características, y los Árboles Extra (*Extra Trees*), que solo submuestran observaciones (Figura 14). Los Bosques Aleatorios son especialmente confiables debido a su aprendizaje diverso a partir de combinaciones variadas de datos [86].


**Figura 14.** *Aprendizaje en conjunto con árboles de decisión.*



*Nota: Esquema del funcionamiento de un modelo de aprendizaje en conjunto (ensemble), en el cual múltiples árboles de decisión se entrenan en subconjuntos de datos y sus predicciones se combinan para mejorar la precisión del clasificador. [87]*

Por último, otra técnica de aprendizaje automático muy utilizada y de vanguardia es la Máquina de Vectores de Soporte (*SVM*). En el aprendizaje automático, las máquinas de soporte vectorial son modelos de aprendizaje supervisado con algoritmos asociados que analizan datos utilizados para clasificación y análisis de regresión. Además de realizar clasificación lineal, las *SVM* pueden llevar a cabo de manera eficiente una clasificación no lineal mediante lo que se conoce como el truco del kernel, que mapea implícitamente sus entradas en espacios de características de alta dimensión [79]. Básicamente, dibuja márgenes entre las clases y los márgenes se trazan de tal manera que la distancia entre el margen y las clases es máxima, minimizando así el error de clasificación por lo que el objetivo principal del algoritmo SVM es encontrar un hiperplano que separe de manera óptima dos clases diferentes de puntos de datos (Figura 15). Sin embargo, el algoritmo solo puede encontrar este hiperplano en problemas que permiten separación lineal. En la mayoría de los problemas reales, el algoritmo maximiza un margen flexible, permitiendo una pequeña cantidad de clasificaciones erróneas para mejorar la generalización del modelo [88].

**Figura 15.** Separación de clases mediante SVM.

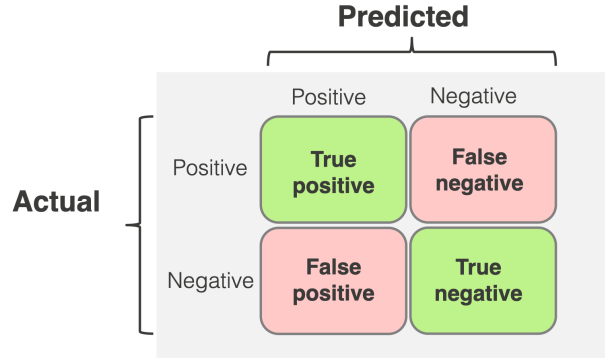


*Nota: Representación de la definición del margen óptimo entre clases, criterio fundamental que los algoritmos de máquinas de vectores de soporte (SVM) buscan maximizar para lograr una separación eficaz de los datos. [88]*

### 6.4.3 Evaluación y parámetros para modelos de clasificación

Las matrices de confusión son herramientas gráficas utilizadas en el aprendizaje automático para demostrar la eficacia de los modelos. A menudo, se presentan en forma de figuras coloridas que adornan los informes científicos y documentos técnicos. Estas matrices guían a los lectores a través de la interpretación de los modelos mediante sus características particulares, como las líneas diagonales que atraen la vista de una esquina a otra. De esta manera, las matrices de confusión actúan como argumentos gráficos [89]. En su forma más simple, una matriz de confusión muestra el rendimiento de un clasificador binario en una tabla con dos filas y dos columnas, y representa los porcentajes de los cuatro posibles resultados de clasificación: Verdaderos Positivos (TP), Falsos Positivos (FP), Verdaderos Negativos (TN) y Falsos Negativos (FN) (Figura 16) [90]. Este principio se extiende fácilmente a la visualización de los resultados obtenidos por un modelo de clasificación multiclase, donde cada objeto del conjunto de datos puede pertenecer a una de varias clases distintas en cualquier momento. Por ejemplo, si un objeto de tipo A suele clasificarse erróneamente como tipo B, la matriz de confusión lo mostrará claramente, lo que sugiere al investigador que podría mejorar el modelo de clasificación buscando características adicionales que ayuden a diferenciar mejor las clases A y B [91].

**Figura 16.** Ejemplo de matriz de confusión.



*Nota: Herramienta utilizada para evaluar el desempeño de un modelo de clasificación. Se observan mediante una matriz las predicciones correctas e incorrectas en función de las clases verdaderas y las predichas. [92]*

La evaluación basada en etiquetas considera cada etiqueta por separado, lo que convierte al clasificador multietiqueta en un clasificador binario para una etiqueta particular, con cuatro posibles resultados de predicción: Verdadero Positivo ( $TP$ ), Falso Positivo ( $FP$ ), Verdadero Negativo ( $TN$ ) y Falso Negativo ( $FN$ ). La exactitud ( $Accuracy$ ), precisión ( $Precision$ ) y recuperación ( $Recall$ ) se definen de la siguiente manera:

$$\text{Exactitud} = \frac{TP + TN}{N}$$

$$\text{Precisión} = \frac{TP}{TP + FP}$$

$$\text{Recuperación} = \frac{TP}{TP + FN}$$


Otra de las herramientas más utilizadas para evaluar el desempeño de los modelos de clasificación es la curva AUC-ROC (Área Bajo la Curva - Características Operativas del Receptor). Esta curva se emplea comúnmente en problemas de clasificación multiclase para analizar y visualizar el rendimiento del modelo. La AUC-ROC es una de las métricas de evaluación más importantes para medir la efectividad de cualquier modelo de clasificación y también se le conoce como AUROC (Área Bajo las Características Operativas del Receptor) [93].

La ROC (*Receiver Operating Characteristic*) es una curva de probabilidad, mientras que AUC (Área Bajo la Curva) representa el grado de separabilidad del modelo, es decir, su capacidad para distinguir entre las distintas clases. Cuanto mayor sea el AUC, mejor será el modelo para clasificar correctamente los valores verdaderos y falsos, lo que implica una

mayor precisión en la predicción. En otras palabras, un AUC más alto refleja un mejor rendimiento del modelo al clasificar las observaciones de manera correcta [93].

La curva ROC se traza colocando la Tasa de Verdaderos Positivos (TPR) en el eje y y la Tasa de Falsos Positivos (FPR) en el eje x (Figura 17).

**Figura 17.** Curva AUC - ROC.



*Nota: Gráfica utilizada para evaluar el rendimiento de un modelo de clasificación binaria. La curva muestra la relación entre la tasa de verdaderos positivos (TPR) y la tasa de falsos positivos (FPR). [93]*

#### 6.4.4 Aplicaciones de *machine learning* a la polisomnografía

En el ámbito de la salud, los enfoques de aprendizaje automático han mostrado avances significativos, impulsados por la disponibilidad de grandes volúmenes de datos y la reducción en los costos de procesamiento. Sin embargo, estos avances también exigen el desarrollo de almacenes de datos inteligentes y seguros que integren aprendizaje automático y mecanismos avanzados de seguridad [94]. Por ejemplo, algunos estudios han utilizado algoritmos de aprendizaje automático supervisado para clasificar las etapas del sueño a partir de espectrogramas de EEG, un proceso que en la práctica requiere tiempo y experiencia debido a la variabilidad de las señales cerebrales y los posibles artefactos generados por el uso de electrodos superficiales. Algunos de estos estudios reportan precisiones de clasificación superiores al 80 %, logrando hasta un 94 % en algunos conjuntos de datos, lo cual muestra el potencial de los modelos de aprendizaje profundo con múltiples capas ocultas, como las redes LSTM, para identificar secuencias en las etapas de sueño de manera automatizada y efectiva [95] [96].

Otro ejemplo de aplicación es el uso de algoritmos de aprendizaje automático para predecir la gravedad del síndrome de apnea obstructiva del sueño (AOS) a partir de grandes conjuntos de datos clínicos de pacientes. En este caso, se han aplicado tanto técnicas de aprendizaje supervisado como no supervisado, alcanzando precisiones de hasta el 91 %. Aunque estos modelos presentan desafíos, como la variabilidad de los datos entre centros de

salud o la presencia de valores faltantes, los resultados destacan el potencial del aprendizaje automático para facilitar el diagnóstico de la AOS y otros trastornos relacionados [97].

## 7.1. Análisis de las necesidades

Para desarrollar un algoritmo automatizado basado en técnicas de machine learning que sea eficiente y se adapte a las necesidades actuales de los técnicos del sueño certificados en Guatemala, se realizan una serie de entrevistas con estos profesionales. El objetivo es entender su perspectiva respecto a la necesidad de un algoritmo que permita calificar los estudios del sueño de manera más rápida y precisa.

Las preguntas a realizar durante la entrevista fueron las siguientes:

1. Nombre
2. En su experiencia, ¿qué es lo más complicado del análisis de la PSG al momento de su calificación posterior a terminar la prueba?
3. ¿Conoce de alguna herramienta que exista y que le pueda facilitar este proceso de calificación posterior a la prueba?
4. De conocer herramientas de software que le puedan facilitar el proceso de calificación, ¿suele utilizarlas, o hay algún motivo por el que no las utilice?
5. Generalmente, ¿qué es lo que más tiempo toma en el análisis?
6. En promedio, ¿cuántas PSG califica semanales/quincenales?
7. En su conocimiento de técnico del sueño, ¿en dónde ve las mayores posibilidades de mejora o los puntos de dolor que más podría ayudar el software?
8. ¿Qué parámetros les gustaría que un algoritmo automatizado pudiera identificar automáticamente?

9. ¿Cuál sería el error aceptable para un software con la finalidad de no afectar de manera drástica el diagnóstico de un paciente?
10. ¿Cuáles son los diagnósticos de trastornos del sueño más recurrentes en su clínica?
11. ¿Cuáles son los trastornos esenciales que deben de ser reconocidos por el software?
12. En márgenes de dinero, ¿qué impacto cree que este software podría tener en su clínica?
13. Comentarios

## 7.2. Base de datos PhysioNet

PhysioNet ofrece acceso gratuito a través de la web a grandes colecciones de señales fisiológicas grabadas y software de código abierto relacionado. El sitio web de PhysioNet es un servicio público del Recurso de Investigación PhysioNet para Señales Fisiológicas Complejas, financiado por el Instituto Nacional de Ciencias Médicas Generales (NIGMS) y el Instituto Nacional de Imágenes Biomédicas y Bioingeniería (NIBIB) [98].

La base de datos empleada para el desarrollo del software es obtenida de PhysioNet: “Sleep-EDF Database Expanded”. La base de datos Sleep-EDF se ha ampliado para contener 197 grabaciones polisomnográficas de sueño durante toda la noche, que contienen EEG, EOG, chin EMG y marcadores de eventos. Algunos registros también contienen respiración y temperatura corporal [99]. Los hipnogramas correspondientes (patrones de sueño) son calificados manualmente por técnicos capacitados de acuerdo con el manual Rechtschaffen y Kales, y también están disponibles dentro de la base de datos. La base de datos tiene un tamaño total sin comprimir de 8.1 GB. Los archivos pueden descargarse directamente desde el sitio web de PhysioNet.

Los datos provienen de dos estudios, descritos brevemente a continuación. Los archivos EDF son grabaciones polisomnográficas de sueño durante toda la noche que contienen EEG (de ubicaciones de electrodos Fpz-Cz y Pz-Oz), EOG (horizontal), EMG de mentón submentoniano y un marcador de evento. Los hipnogramas contienen anotaciones de los patrones de sueño que corresponden a los PSG. Estos patrones consisten en etapas de sueño “W”, “R”, “1”, “2”, “3”, “4”, “M” (Tiempo de movimiento) y “?” (no puntuado).

Todos los campos de encabezado EDF también cumplen con las especificaciones EDF+, y las señales no grabadas son eliminadas de la base de datos. Los archivos PSD están formateados en EDF mientras que los hipnogramas están en EDF+. Cada archivo EDF y EDF+ tiene un encabezado que especifica el paciente (en estos archivos anonimizados solo para sexo y edad), detalles de la grabación (en particular, el período de tiempo grabado) y características de las señales, incluida su calibración de amplitud. Las señales de EOG y EEG son muestreadas cada una a 100 Hz. La señal EMG submental se filtra electrónicamente con paso alto, se rectifica y se filtra con paso bajo, después de lo cual se muestrea la envolvente EMG resultante expresada en  $\mu\text{V}$  rms (raíz cuadrada meda) a 1 Hz. También se muestrean el flujo de aire oronasal, la temperatura corporal rectal y el marcador de evento a 1 Hz [99].

## 7.3. Procesamiento de datos MATLAB

Para la extracción y procesamiento de datos, se utiliza la versión 2024b de MATLAB (*MathWorks, MA, USA*). La función `edfread` permite acceder a los archivos en formato EDF de la base de datos *Sleep-EDF*. Los archivos contienen señales de EEG (Fpz-Cz y Pz-Oz), EOG (horizontal) y EMG (submentoniano).

### 7.3.1. Extracción de archivos

Se filtran los archivos en el directorio de trabajo para identificar aquellos correspondientes a los estudios de polisomnografía (PSG.edf) y sus hipnogramas asociados (Hypnogram.edf). Cada paciente dispone de dos archivos en formato .edf, uno para el PSG y otro para el hipnograma. Estos archivos se organizan en una celda de MATLAB, utilizando el nombre del paciente como identificador único para su procesamiento posterior (Figura 18).

**Figura 18.** Archivos *Hypnogram* y *PSG* por paciente.

Nombre	Fecha de modificación	Tipo	Tamaño
ST7011-Hypnogram.edf	28/02/2024 09:21 a. m.	Archivo EDF	7 KB
ST7011-PSG.edf	28/02/2024 09:21 a. m.	Archivo EDF	28,750 KB
ST701210-Hypnogram.edf	28/02/2024 09:21 a. m.	Archivo EDF	5 KB
ST701210-PSG.edf	28/02/2024 09:21 a. m.	Archivo EDF	25,082 KB
ST702110-Hypnogram.edf	28/02/2024 09:21 a. m.	Archivo EDF	4 KB
ST702110-PSG.edf	28/02/2024 09:21 a. m.	Archivo EDF	24,506 KB
ST702210-Hypnogram.edf	28/02/2024 09:21 a. m.	Archivo EDF	5 KB
ST702210-PSG.edf	28/02/2024 09:21 a. m.	Archivo EDF	24,634 KB
ST704110-Hypnogram.edf	28/02/2024 09:21 a. m.	Archivo EDF	5 KB
ST704110-PSG.edf	28/02/2024 09:21 a. m.	Archivo EDF	24,954 KB
ST704210-Hypnogram.edf	28/02/2024 09:21 a. m.	Archivo EDF	4 KB
ST704210-PSG.edf	28/02/2024 09:21 a. m.	Archivo EDF	27,797 KB
ST705110-Hypnogram.edf	28/02/2024 09:21 a. m.	Archivo EDF	6 KB
ST705110-PSG.edf	28/02/2024 09:21 a. m.	Archivo EDF	25,787 KB
ST705210-Hypnogram.edf	28/02/2024 09:21 a. m.	Archivo EDF	4 KB
ST705210-PSG.edf	28/02/2024 09:21 a. m.	Archivo EDF	26,292 KB
ST706110-Hypnogram.edf	28/02/2024 09:21 a. m.	Archivo EDF	3 KB
ST706110-PSG.edf	28/02/2024 09:21 a. m.	Archivo EDF	26,083 KB

*Nota: Ejemplo de los dos tipos de archivos principales disponibles por paciente en la base de datos: el archivo de polisomnografía (PSG), que contiene las señales fisiológicas, y el archivo Hypnogram, que contiene las anotaciones manuales de las etapas del sueño.*

Cada archivo de PSG es procesado para importar las señales de EEG, EOG y EMG, que se convierten en matrices. A partir del hipnograma, se extraen las anotaciones de las etapas del sueño, incluyendo la información de inicio y duración de cada etapa. Con esta información, las señales se segmentan y reorganizan en bloques conforme a las duraciones definidas en el hipnograma. Estos bloques se almacenan en una estructura organizada que incluye las señales fisiológicas, la duración y la etapa de sueño, además del identificador del paciente para facilitar el acceso y la organización de los datos.

### 7.3.2. Separación de la base de datos por datos individuales

Una vez agrupados los datos por paciente, estos se reorganizan en una tabla unificada en la que cada fila corresponde a un segmento individual de datos. Se mantiene el índice identificador del paciente y el estadio de sueño asociado a cada segmento, asegurando un formato adecuado para el posterior entrenamiento de modelos de *machine learning*.

Se comienza con inicializar una tabla vacía para almacenar los datos de todos los pacientes agrupados, con el fin de eliminar el formato cell extraído del .edf y tener una tabla que contenga el conjunto total de datos, para lograr esto, se recorre la *cell* que contiene los datos organizados por paciente. Para cada paciente se itera sobre las columnas de los datos, seleccionando las señales fisiológicas, que son las que se utilizarán en las matrices cuadradas con el fin de asegurar un formato adecuado para su almacenamiento y procesamiento.

Se crea una lista para almacenar los valores expandidos de las etapas del sueño. En este paso, se ajusta el estadio de sueño para cada fila, asegurándose de que el valor sea una cadena de caracteres y luego, se replica el estadio de sueño según el número de filas correspondiente para cada segmento de datos. Después, los datos de EEG, EOG y EMG se combinan en una tabla, y se añade una columna con el estadio de sueño expandido para cada segmento de datos. Finalmente, se incluye el identificador del paciente en la tabla, lo que permite agrupar y separar correctamente los datos de cada individuo en la base de datos final.

Una vez procesados los datos de todos los pacientes, se combinan en una tabla general que contiene los datos de todos los pacientes, con sus respectivas señales y etiquetas de etapas de sueño, lista para ser utilizada en el entrenamiento de modelos de *machine learning*.

### 7.3.3. Agrupamiento de datos y cálculo de estadísticas para modelos de *Machine Learning*

Se carga la tabla unificada que contiene todos los datos de los pacientes. A partir de esta tabla, se determina el número de períodos de 3000 filas, correspondientes a 30 segundos de datos, considerando que la frecuencia de muestreo para las señales fisiológicas indicada en PhysioNet es de 100 Hz. Se inicializa una tabla de resultados con preasignación para almacenar las estadísticas extraídas, que incluyen la potencia total y relativa de las señales de EEG, así como el cambio RMS en EOG, RMS en EMG y la etapa de sueño como marcador.

Se definen los parámetros necesarios para aplicar la transformada *wavelet* a las señales EEG y EOG:

- Frecuencia de muestreo: 100 Hz
- Longitud de cada segmento: 3000 muestras (30 segundos)
- Nombre del wavelet: 'dB4'
- Número de niveles de descomposición: 5, para capturar varias bandas de frecuencia.

Para cada período de 3000 datos, se extraen las señales correspondientes de EEG, EOG y EMG, y se realizan los siguientes pasos:

1. EEG (Columnas 1 y 2):

Se aplica la transformada wavelet (MODWT) a las señales de EEG de las columnas 1 y 2. Se calcula la potencia total de la señal en cada canal de EEG sumando la potencia en cada nivel de descomposición. Posteriormente, se calcula la potencia relativa de cada canal de EEG, dividiendo la potencia total por la potencia total de la señal original.

2. EOG (Columna 3):

Se calcula el cambio RMS de la derivada rectificada de la señal de EOG, se aplica la transformada wavelet a la señal de EOG y se calcula su potencia en las diferentes bandas de frecuencia, para representar la potencia total y relativa de la señal de EOG.

3. EMG (Columna 4):

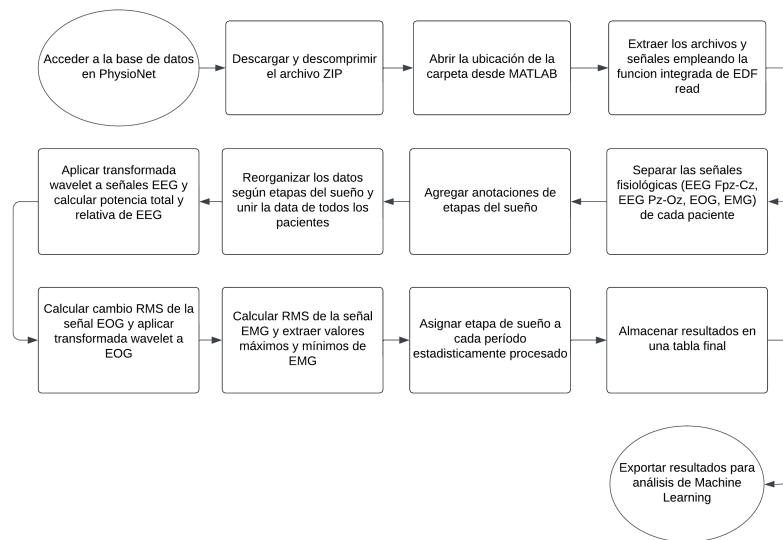
Se calcula el RMS de la señal de EMG y se obtienen los valores máximo y mínimo de la señal.

4. SleepStage (Columna categórica):

Se toma el primer valor de la columna SleepStage de cada período de 3000 muestras para asignarlo al resultado correspondiente.

A continuación, se presenta un resumen del flujo de trabajo empleado para procesar los datos fisiológicos y calcular las estadísticas relevantes. (Figura 19) Este diagrama de flujo ilustra de manera simplificada los pasos realizados hasta el momento.

**Figura 19.** Flujo de trabajo.

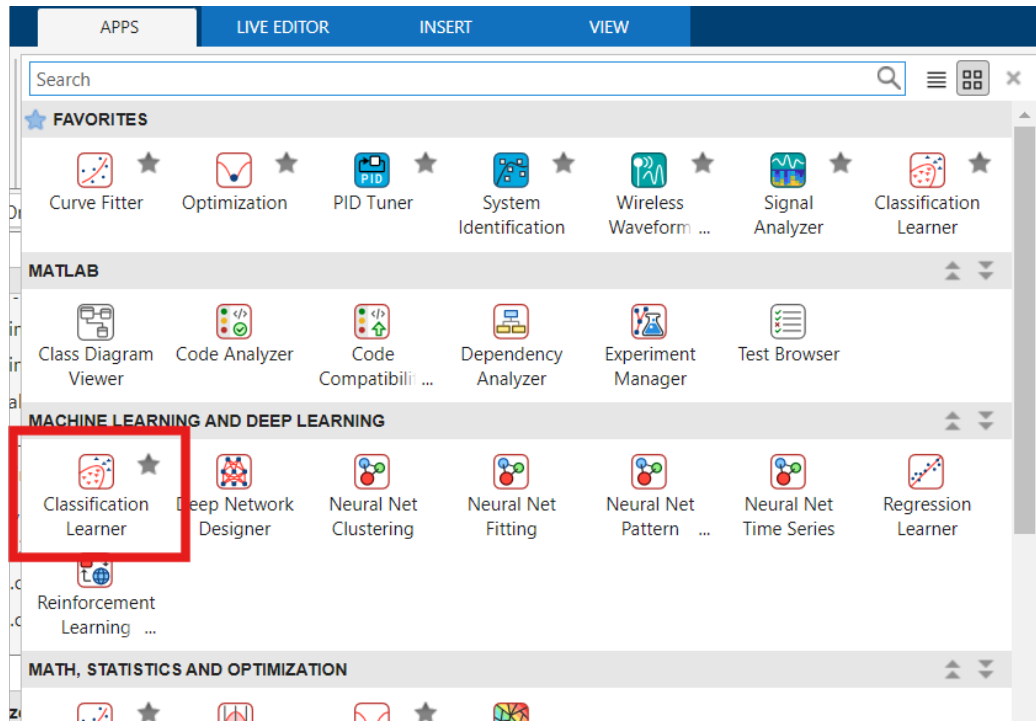


*Nota: Diagrama sobre el procesamiento de señales fisiológicas y entrenamiento de modelos de machine learning.*

## 7.4. Uso de *Classification Learner* para entrenamiento de modelos de clasificación

Se utilizó la aplicación *Classification Learner* de MATLAB para entrenar y evaluar modelos de clasificación supervisada (Figura 20). Esta herramienta permite explorar diferentes tipos de clasificadores, como árboles de decisión, análisis discriminante, regresión logística, vecinos más cercanos (kNN, por sus siglas en inglés de "*k-nearest neighbors*"), máquinas de soporte vectorial (*SVM*), modelo *Naïve Bayes*, redes neuronales, entre otros.

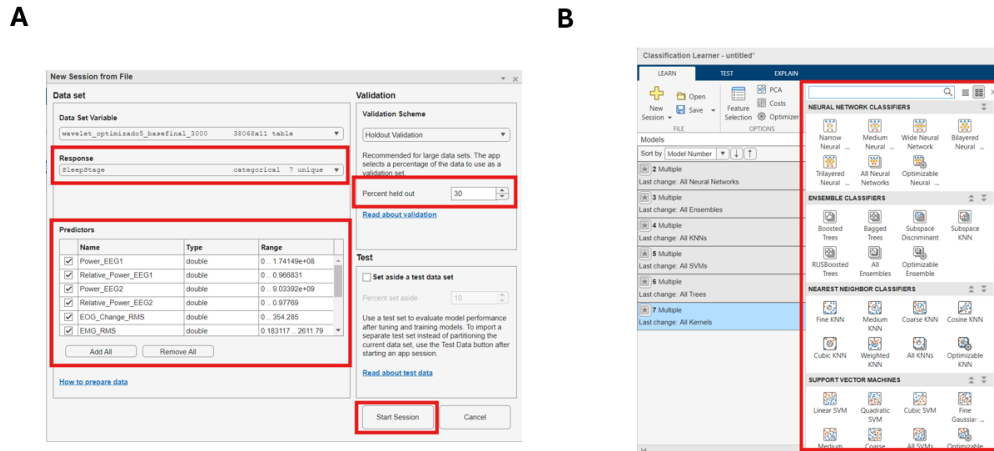
**Figura 20.** Herramienta *Classification Learner* en MATLAB.



*Nota:* Vista de la interfaz de la herramienta *Classification Learner* en MATLAB, utilizada para el entrenamiento y evaluación de modelos de clasificación.

Se importan los datos al *Classification Learner*, en los cuales se seleccionaron todas las características a usar para la creación del modelo de *machine learning* y se verifica el conjunto de datos seleccionados, el cual consta de 10 características (variables predictoras) y 1 respuesta (la variable de *Sleep Stage*). Se utiliza un esquema de validación de *holdout* del 30%, lo cual permite evitar el sobreajuste (*overfitting*) al separar el 30% de los datos para ser usados como conjunto de validación (Figura 21,a). Posteriormente, se entrenan y evalúan varios modelos de clasificación utilizando diferentes algoritmos. Se seleccionan todos los modelos básicos disponibles en la aplicación para observar cuáles obtienen mejores resultados en términos de precisión y rendimiento. Los clasificadores evaluados incluyen árboles de decisión, máquinas de soporte vectorial (*SVM*), vecinos más cercanos (*kNN*), clasificadores de ensamblaje (*ensemble classifiers*) y redes neuronales (Figura 21,b).

**Figura 21.** Selección de variables y modelos de clasificación.



*Nota:* a) Selección de base de datos, variables predictoras, respuesta y porcentaje de holdout. b) Selección de modelos de clasificación para la evaluación de su rendimiento.

El rendimiento de los modelos es evaluado utilizando el conjunto de datos de prueba seleccionado en el *holdout*. Para cada modelo, se analizan las métricas proporcionadas por la aplicación, tales como tablas de resultados y gráficos comparativos, con el fin de seleccionar el modelo con el mejor desempeño en la clasificación de las etapas del sueño. Se seleccionan los hiperparámetros por defecto proporcionados por MATLAB en la aplicación *Classification Learner* para la evaluación inicial de los modelos. A continuación, se presenta un cuadro que muestra los parámetros utilizados durante el entrenamiento de los modelos de clasificación. Este cuadro incluye detalles sobre la validación aplicada, las características seleccionadas, la respuesta utilizada, y los hiperparámetros por defecto correspondientes a cada clasificador (Cuadro 1). Los parámetros de cada modelo se ajustan según los valores predefinidos por la herramienta para facilitar la comparación entre los distintos clasificadores.

Se iteran los hiperparámetros de los modelos con los porcentajes de aciertos más altos observados en (Cuadro 1), tales como el número máximo de divisiones, el número de aprendices y la tasa de aprendizaje, entre otros. Estos hiperparámetros se ajustan en función del rendimiento obtenido en cada iteración. En cada caso, se evalúa la precisión de los modelos mediante las métricas correspondientes, y los hiperparámetros se modifican dependiendo de si los resultados mejoran o empeoran. Este proceso iterativo de ajuste permite optimizar los modelos con el objetivo de obtener los mejores resultados en la clasificación de las etapas del sueño.

**Cuadro 1.** *Hiperparámetros iniciales para clasificación de modelos.*

Modelo Empleado	Porcentaje de Acierto	Preset	Hiperparámetros
Red Neuronal	71.5674	Red Neuronal Estrecha	Número de capas completamente conectadas: 1; Tamaño de la primera capa: 10; Activación: ReLU; Límite de iteraciones: 1000; Intensidad de regularización (Lambda): 0; Estandarizar datos: Sí
Red Neuronal	73.6427	Red Neuronal Mediana	Número de capas completamente conectadas: 1; Tamaño de la primera capa: 25; Activación: ReLU; Límite de iteraciones: 1000; Intensidad de regularización (Lambda): 0; Estandarizar datos: Sí
Red Neuronal	73.9054	Red Neuronal Ancha	Número de capas completamente conectadas: 1; Tamaño de la primera capa: 100; Activación: ReLU; Límite de iteraciones: 1000; Intensidad de regularización (Lambda): 0; Estandarizar datos: Sí
Ensamble	69.317	Árboles Potenciados	Método de ensamble: AdaBoost; Tipo de aprendiz: Árbol de decisión; Número máximo de divisiones: 20; Número de aprendices: 30; Tasa de aprendizaje: 0.1; Número de predictores a muestrear: Seleccionar todos
Ensamble	76.0158	Árboles con Bolsas (Bagged Trees)	Método de ensamble: Bag; Tipo de aprendiz: Árbol de decisión; Número máximo de divisiones: 38067; Número de aprendices: 30; Número de predictores a muestrear: Seleccionar todos
KNN	68.8091	KNN Cúbico	Número de vecinos: 10; Métrica de distancia: Minkowski (cúbica); Peso de la distancia: Igual; Estandarizar datos: Sí
KNN	69.2557	KNN Ponderado	Número de vecinos: 10; Métrica de distancia: Euclidiana; Peso de la distancia: Inverso al cuadrado; Estandarizar datos: Sí
SVM	16.5937	SVM Cúbica	Función núcleo: Cúbica; Escala del núcleo: Automática; Nivel de restricción (box constraint): 1; Codificación multiclase: Uno contra uno; Estandarizar datos: Sí
SVM	72.7583	SVM Gaussiana Fina	Función núcleo: Gaussiana; Escala del núcleo: 0.79; Nivel de restricción (box constraint): 1; Codificación multiclase: Uno contra uno; Estandarizar datos: Sí
Árbol	70.4991	Árbol Fino	Número máximo de divisiones: 100; Criterio de división: Índice de diversidad de Gini; Divisiones de decisión sustitutas: Desactivado
Árbol	58.8967	Árbol Burdo	Número máximo de divisiones: 4; Criterio de división: Índice de diversidad de Gini; Divisiones de decisión sustitutas: Desactivado
Núcleo	67.1629	Núcleo SVM	Aprendiz: SVM; Número de dimensiones de expansión: Automático; Intensidad de regularización (Lambda): Automática; Escala del núcleo: Automática; Codificación multiclase: Uno contra uno; Estandarizar datos: Sí; Límite de iteraciones: 1000
Núcleo	65.3327	Núcleo de Regresión Logística	Aprendiz: Regresión Logística; Número de dimensiones de expansión: Automático; Intensidad de regularización (Lambda): Automática; Escala del núcleo: Automática; Codificación multiclase: Uno contra uno; Estandarizar datos: Sí; Límite de iteraciones: 1000

*Nota: Elaboración propia.*

## 8.1. Entrevistas

De las entrevistas realizadas, se observó que los aspectos más desafiantes durante la calificación de las polisomnografías (PSG) son la correcta segmentación de los estadios del sueño y la identificación de artefactos en las señales (pregunta 2). Estos problemas requieren una experiencia considerable y una correcta interpretación de los datos fisiológicos.

Se identificaron alternativas como *Sleep Diagnostic Solution* y *Somnolyzer 24x7* para la codificación del sueño; sin embargo, estas soluciones resultan ser costosas y poco funcionales para clínicas con el flujo de pacientes actual (preguntas 3 y 4). En clínicas con un promedio de 3 a 4 PSG por semana, se determinó que un algoritmo automatizado accesible podría ahorrar entre 6 y 9 horas de trabajo posterior a la prueba, lo que permitiría realizar múltiples consultas o avanzar con otras tareas, mejorando así la carga de trabajo (preguntas 6 y 11).

Además, se mencionó que sería de gran utilidad si el software pudiera incorporar un sistema de reconocimiento automatizado para eventos importantes, tales como apneas e hipoapneas (pregunta 7). Este avance podría mejorar significativamente la eficiencia del diagnóstico.

Por último, se determinó que un margen de error del 5% o menos sería ideal para el correcto funcionamiento del algoritmo, sin que esto interfiera con la precisión del diagnóstico para los pacientes (pregunta 9).

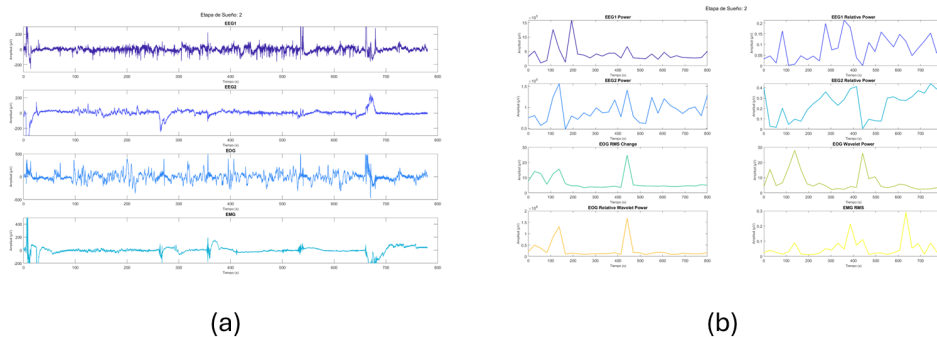
## 8.2. Preprocesamiento y transformación de las señales

Previo al ingreso de los datos al algoritmo de clasificación, las señales originales de EEG, EOG y EMG fueron sometidas a un proceso de transformación estadística con el objetivo de mejorar la identificación de patrones relevantes para la clasificación de las etapas del sueño. En (Figura 22, (a)) se presentan las señales en su estado original, mientras que en (Figura 22, (b)) se muestran las características extraídas mediante técnicas de análisis de potencia, energía y transformada wavelet.

Este proceso de estadificación de los datos permitió representar de manera más robusta las variaciones relevantes en la actividad cerebral y muscular, reduciendo el ruido y destacando las tendencias clave en cada canal. Al aplicar métricas como la potencia relativa en las señales de EEG y la potencia wavelet en las señales de EOG, se logró enfatizar los cambios característicos de cada etapa del sueño, lo que facilitó su reconocimiento por parte de los algoritmos de clasificación.

Además, la transformación de los datos en atributos estadísticos contribuyó a mejorar el rendimiento del modelo, ya que permitió reducir la dimensionalidad de las señales crudas sin perder información relevante. Esto se tradujo en un mejor ajuste del modelo y en una mayor capacidad para generalizar la clasificación en distintos sujetos y registros. En las secciones siguientes se presentan los resultados obtenidos con los distintos modelos evaluados, destacando el impacto de estas transformaciones en la precisión y sensibilidad de la clasificación.

**Figura 22.** *Señales originales y características extraídas.*



*Nota: a) Señales originales de EEG, EOG y EMG antes del preprocesamiento. b) Características extraídas de las señales mediante técnicas de análisis de potencia, energía y transformada wavelet.*

## 8.3. Resultados de clasificación

Para todos los modelos entrenados, se utilizó un esquema de validación *Holdout*, con un 30% de los datos reservados para pruebas. A continuación, se presentan los resultados obtenidos con el modelo *k-Nearest Neighbors (KNN)*, seguido por los resultados de los modelos *SVM (Fine Gaussian)*, entre otros.

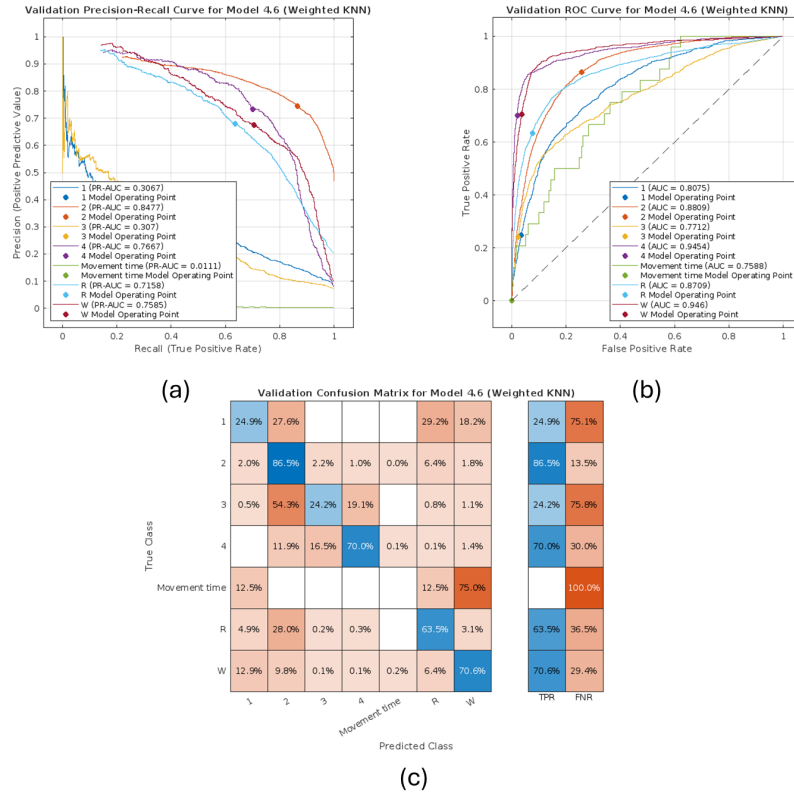
### 8.3.1. Resultados del Modelo *KNN*

Se entrenó un modelo de clasificación *k-Nearest Neighbors (KNN)* con los datos procesados utilizando la herramienta *Classification Learner* de MATLAB. Los hiperparámetros seleccionados para este modelo fueron los siguientes:

- Número de vecinos (k): 10
- Métrica de distancia: Euclidiana
- Peso de la distancia: Inversa cuadrada
- Normalización de los datos: Sí

La matriz de confusión del modelo KNN (Figura 23, (c)) muestra el rendimiento del modelo en la clasificación de las etapas de sueño. El modelo presentó un desempeño normal en la mayoría de las clases, con una tasa de aciertos general del 69.3%, especialmente en las etapas de sueño R y W, con tasa de aciertos por arriba del 60% y baja tasa de falsos negativos. Se destacó una precisión del 86.5% para la clasificación de N2, 70.0% para N4 y 70.6% para REM. Sin embargo, la clase Movimiento presentó un mayor porcentaje de falsos negativos, con una tasa de FNR de 100.0% lo que indica que todas las observaciones de esta clase fueron mal clasificadas, seguido por un FNR de 75.1% para la clase N1 y 75.8% para la clase N3. Las curvas ROC (*Receiver Operating Characteristic*) para cada clase (Figura 23, (b)) indican que el modelo presentó una AUC (*Área Bajo la Curva*) relativamente alta para la mayoría de las clases, especialmente para N4 (AUC = 0.9454) y W (AUC = 0.946), este valor indica un excelente rendimiento discriminativo, lo que sugiere que el modelo es muy eficaz para distinguir entre los eventos de la clase N4, W de otras clases. La clase Movimiento mostró un (AUC = 0.7588), lo que refleja el rendimiento más bajo entre todas las clases siendo moderado en la discriminación de la clase Movimiento. Aunque el modelo muestra una capacidad razonable para identificar los movimientos, no tiene el mismo nivel de precisión que en la clase N4, seguido por la clase N3 (AUC = 0.7712). Finalmente, las curvas de *precisión-recall* (Figura 23, (a)) muestran que el modelo obtuvo un PR-AUC (*Área Bajo la Curva de Precisión-Recall*) de 0.8477 para la clase N2 y de 0.7585 para la clase W, lo que indica un buen equilibrio entre precisión y recall en estas clases lo que sugiere que la mayoría de las predicciones positivas hechas por el modelo son correctas, y que el modelo es capaz de identificar bien los eventos de estas clases. Sin embargo, las clases N1 y N3 presentaron valores de PR-AUC de 0.3067 y 0.307, respectivamente, lo que sugiere un bajo rendimiento en cuanto al equilibrio entre precisión y recall para estas clases, que son también relevantes para la clasificación de las etapas del sueño e indican que hay espacio para mejorar la capacidad del modelo para identificar correctamente estos estados.

Figura 23. Resultados del modelo KNN.



Nota: Visualización de los principales resultados obtenidos por el modelo KNN. (a) Curvas de precisión-recall para cada clase, que reflejan el equilibrio entre precisión y sensibilidad. (b) Curvas ROC para cada clase, utilizadas para evaluar la capacidad discriminativa del modelo. (c) Matriz de confusión, que muestra el desempeño del modelo en términos de predicciones correctas e incorrectas por estadio del sueño.

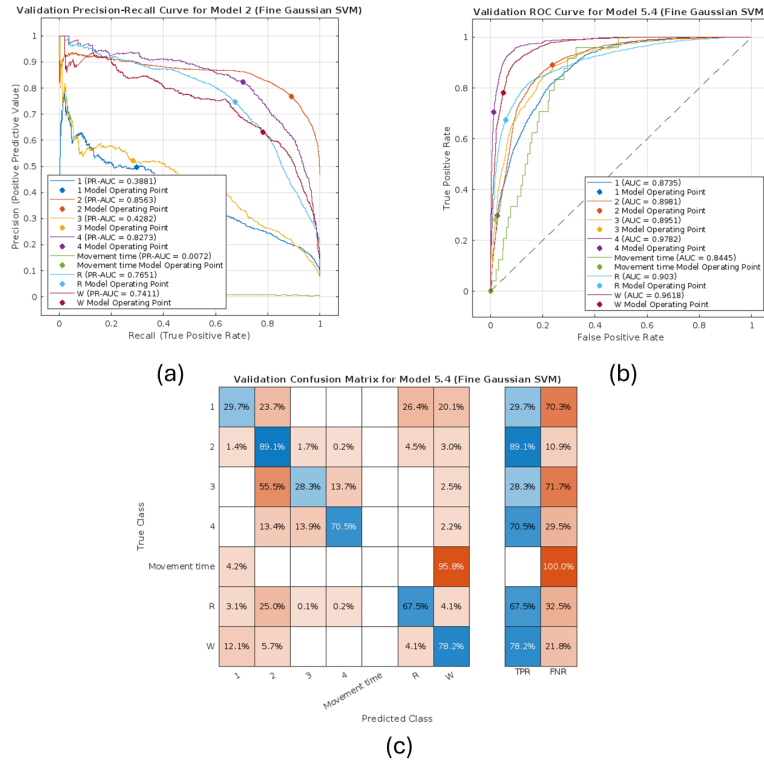
### 8.3.2. Resultados del Modelo SVM

Se entrenó un modelo *Support Vector Machine (SVM)* utilizando los datos procesados con la herramienta *Classification Learner* de MATLAB. Los hiperparámetros seleccionados para este modelo fueron:

- Función del kernel: Gaussiana
- Escala del kernel: 0.79
- Nivel de restricción del margen: 1
- Codificación multiclase: One-vs-One
- Normalización de los datos: Sí

La matriz de confusión del modelo SVM (Figura 24, (c)) reveló que el modelo presentó un rendimiento sólido con una tasa de aciertos general del 72.8%, especialmente en las clases 2 y W, con una alta tasa de aciertos y baja tasa de falsos negativos. La precisión para la clase 2 alcanzó el 89.1%, mientras que para W fue del 78.2%. Sin embargo, la clase Movimiento también mostró un porcentaje elevado de falsos negativos, con un FNR de 100.0% y las clases N1 y N3 presentaron un FNR de 70.3% y 71.7% respectivamente, indicando clasificaciones erróneas en su mayoría para estos dos estadios de sueño. Las curvas ROC (Figura 24, (b)) muestran que el modelo SVM alcanzó un desempeño notable en la clasificación de varias clases. En particular, la clase W obtuvo un AUC de 0.9618, mientras que la clase R alcanzó 0.903 y la clase N4 logró el valor más alto con 0.9782, lo que indica una excelente capacidad del modelo para distinguir estas clases de las demás. Por otro lado, la clase Movimiento presentó un AUC de 0.8445, reflejando un rendimiento moderado en su identificación, aunque superior en comparación con otros modelos. En cuanto a las curvas de precisión-recall (Figura 24, (a)), el modelo mostró un PR-AUC de 0.7651 para la clase R y 0.7411 para la clase W, lo que sugiere una buena capacidad de clasificación con un equilibrio adecuado entre precisión y *recall*. Además, se observó una mejora en la clasificación de las clases N2 y N4, con valores de PR-AUC de 0.8563 y 0.8273 respectivamente, indicando que el modelo mantiene un buen rendimiento en la detección de estas etapas del sueño.

**Figura 24.** Resultados del modelo SVM (*Fine Gaussian*).



Nota: Resultados gráficos obtenidos por el modelo SVM. (a) Curvas de precisión-recall por clase, que indican el equilibrio entre precisión y sensibilidad. (b) Curvas ROC que representan la capacidad del modelo para discriminar entre clases. (c) Matriz de confusión, que resume los aciertos y errores de clasificación por estadio del sueño.

### 8.3.3. Resultados del Modelo *Fine tree*

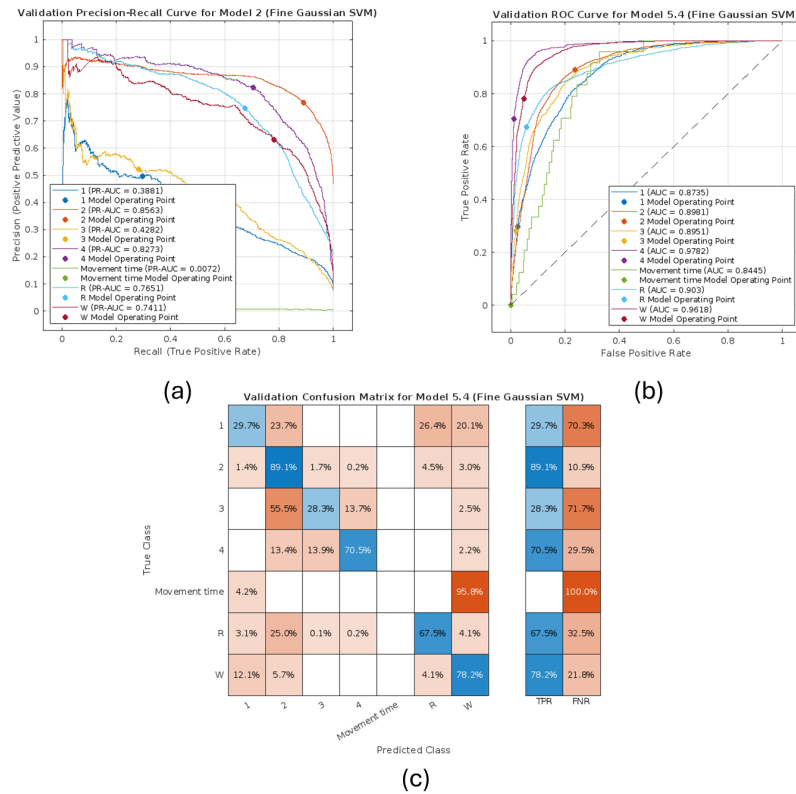
Se entrenó un modelo de clasificación *Fine Tree* utilizando los datos procesados con la herramienta *Classification Learner* de MATLAB. Los hiperparámetros seleccionados para este modelo fueron:

- Número máximo de divisiones: 100
- Criterio de división: Índice de diversidad de Gini
- Divisiones de decisiones sustitutas: Apagado

La matriz de confusión del modelo *Fine Tree* (Figura 25, (c)) refleja un rendimiento equilibrado en la clasificación de las etapas del sueño, con una tasa de aciertos general del 70.5%. Sin embargo, algunas clases presentaron dificultades notables. En particular, la clase movimiento tuvo un FNR del 100.0%, lo que indica que todas sus observaciones fueron

mal clasificadas. De manera similar, la clase N3 mostró un alto FNR de 89.4%, mientras que la clase N1 registró un 75.3%, lo que evidencia una menor capacidad del modelo para identificar correctamente estas etapas. En contraste, el modelo logró un mejor desempeño en las clases N2 y N4, con una precisión de 88.9% y 71.1% respectivamente, sugiriendo que estas clases fueron reconocidas con mayor fiabilidad. Las curvas ROC (Figura 25, (b)) muestran que el modelo alcanzó una AUC relativamente alta en las clases principales, con valores de 0.9245 para N4, 0.9354 para W y 0.8769 para N2, lo que indica una buena capacidad para discriminar estas etapas del sueño. Sin embargo, la clase movimiento obtuvo un AUC de 0.5944, reflejando un desempeño deficiente en la diferenciación de esta clase. Por otro lado, las curvas de *precisión-recall* (Figura 25, (a)) destacan que el modelo alcanzó un PR-AUC de 0.8585 para N2, 0.7108 para REM y 0.7261 para W, lo que sugiere un equilibrio adecuado entre precisión y recall en estas clases. No obstante, las clases N1 y N3 obtuvieron PR-AUC de 0.2907 y 0.2244 respectivamente, evidenciando dificultades para mantener una buena capacidad predictiva en estas categorías más complejas de clasificar.

**Figura 25.** Resultados del modelo *Fine Tree*.



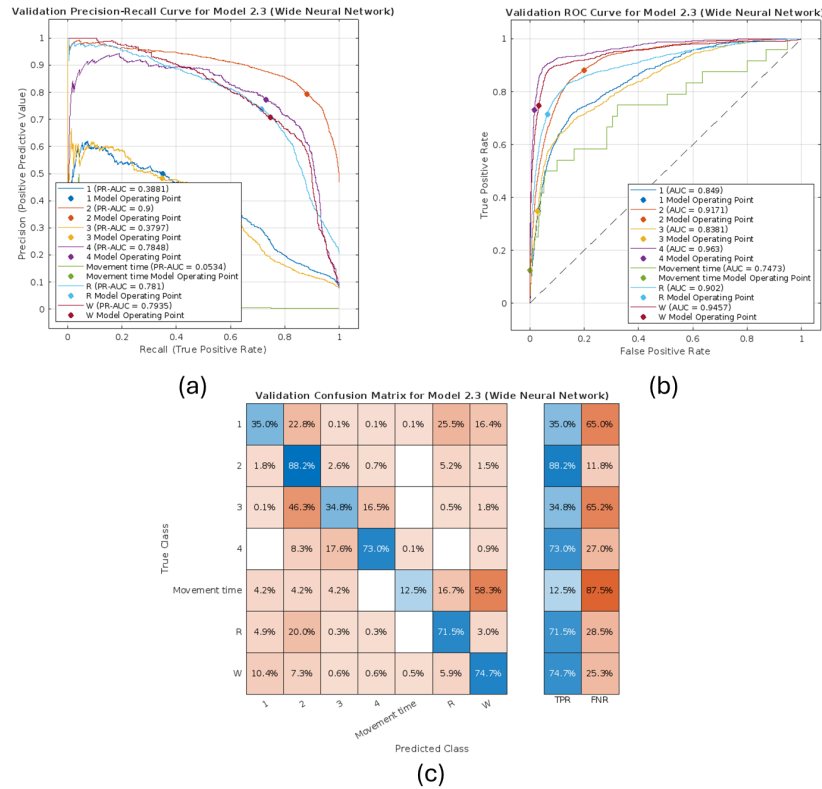
*Nota: Resultados gráficos generados por el modelo Fine Tree. (a) Curvas de precisión-recall por clase, que permiten evaluar el equilibrio entre precisión y sensibilidad. (b) Curvas ROC que representan la capacidad del modelo para discriminar entre clases. (c) Matriz de confusión, que muestra los aciertos y errores de clasificación de cada estadio del sueño.*

### 8.3.4. Resultados del Modelo *Wide Neural Network*

- Número de capas completamente conectadas: 1
- Tamaño de la primera capa: 100
- Activación: ReLU
- Límite de iteraciones: 1000
- Fuerza de regularización ( $\lambda$ ): 0
- Normalización de los datos: Sí

La matriz de confusión del modelo *Wide Neural Network* (Figura 26, (c)) reveló un rendimiento general bueno, alcanzando una precisión del 73.9%. El modelo mostró un buen desempeño en la clasificación de las clases N2, N4, REM y W, con una alta tasa de aciertos (más del 71%) y una baja tasa de falsos negativos. La precisión para la clase N2 alcanzó el 88.2%, mientras que para la clase W fue del 74.7%, seguidos por la clase N4 y REM con 73.0% y 71.5% respectivamente. Sin embargo, la clase movimiento aún presentó una alta tasa de falsos negativos (FNR = 87.5%), seguido por la clase N3 (FNR = 65.2%) y la clase N1 (FNR = 65.0%), lo que refleja la dificultad del modelo para clasificar correctamente estas clases. En cuanto a las curvas ROC (Figura 26, (b)), el modelo obtuvo un AUC alto para las clases W (AUC = 0.9457), REM (AUC = 0.902), N4 (AUC = 0.963) y N2 (AUC = 0.9171), lo que indica un buen rendimiento discriminativo en estas clases. Para la clase movimiento, el AUC fue de 0.7473, lo que indica un rendimiento moderado para esta clase en comparación con las demás. El AUC para la clase N2 fue de 0.9171, lo que también refleja un buen poder discriminativo para esta clase también, la cual es muy representativa en la estadificación del sueño. Finalmente, las curvas de *precisión-recall* (Figura 26, (a)) mostraron que el modelo obtuvo un PR-AUC de 0.9 para la clase N2, 0.781 para la clase REM y de 0.7935 para la clase W. Estas métricas indican un buen equilibrio entre precisión y recall en las clases más importantes para la clasificación del sueño. Sin embargo, las clases Movimiento, N1 y N3 mostraron valores de PR-AUC relativamente bajos (0.0534, 0.3881 y 0.3797 respectivamente), lo que sugiere que el modelo tiene dificultades para equilibrar precisión y recall en estas clases.

**Figura 26.** Resultados del modelo Wide Neural Network.



*Nota: Resultados gráficos generados por el modelo Wide Neural Network. (a) Curvas de precisión-recall por clase, que permiten evaluar el equilibrio entre precisión y sensibilidad. (b) Curvas ROC que representan la capacidad del modelo para discriminar entre clases. (c) Matriz de confusión, que muestra los aciertos y errores de clasificación de cada estadio del sueño.*

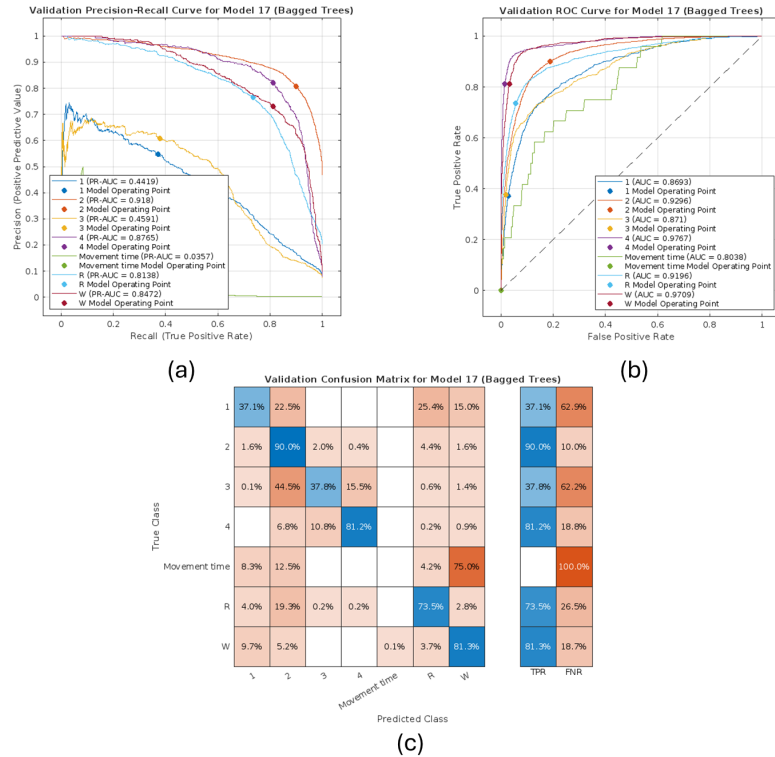
### 8.3.5. Resultados del Modelo Bagged Trees

El modelo *Bagged Trees* se entrenó utilizando los datos procesados con la herramienta *Classification Learner* de MATLAB. Los hiperparámetros seleccionados para este modelo fueron:

- Método del conjunto: Bagging
- Tipo de clasificador: Árbol de decisión
- Número máximo de divisiones: 50,000
- Número de clasificadores: 500
- Número de predictores para muestrear: Seleccionar todos

La matriz de confusión del modelo *Bagged Trees* (Figura 27, (c)) muestra un buen rendimiento general, con una precisión promedio del 76.8%. El modelo presentó un buen desempeño en las clases N2, N4, REM y W, alcanzando una precisión del 90.0% para la clase N2, del 81.2% para la clase N4, un 73.5% para la clase REM y un 81.3% para la clase W, con una tasa de falsos negativos (FNR) relativamente baja para las mismas. Sin embargo, las clases 1 y 3 tuvieron un mayor porcentaje de falsos negativos, con FNR de 62.9% para la clase 1 y 62.2% para la clase 3, indicando áreas de mejora en la clasificación de estas clases. Las curvas ROC (Figura 27, (b)) evidencian que el modelo tuvo un desempeño excelente en las clases N2, N4 y W, con AUC de 0.9296, 0.9767 y 0.9709 respectivamente, reflejando una alta capacidad para diferenciar estos estados del sueño. En contraste, la clase N1 obtuvo un AUC de 0.8693, mientras que la clase N3 registró un AUC de 0.871, lo que sugiere una capacidad moderada del modelo para distinguir estos estados. Finalmente, las curvas de precisión-recall (Figura 27, (a)) muestran que el modelo alcanzó un PR-AUC de 0.918 para la clase N2 y de 0.8472 para la clase W, lo que indica un buen equilibrio entre precisión y recall en estas etapas del sueño. Sin embargo, las clases N1 y N3 obtuvieron valores de PR-AUC más bajos, con 0.4419 y 0.4591 respectivamente, lo que señala la necesidad de mejorar la capacidad del modelo para identificar correctamente estas categorías más complejas.

Figura 27. Resultados del modelo Bagged Trees.



Nota: Resultados gráficos generados por el modelo Bagged Trees. (a) Curvas de precisión-recall por clase, que permiten evaluar el equilibrio entre precisión y sensibilidad. (b) Curvas ROC que representan la capacidad del modelo para discriminar entre clases. (c) Matriz de confusión, que muestra los aciertos y errores de clasificación de cada estadio del sueño.

---

## Discusión de resultados

---

El objetivo de este trabajo es desarrollar un algoritmo automatizado basado en técnicas de *machine learning* para analizar polisomnografías y detectar de manera precisa los estadios del sueño y los artefactos asociados. En este capítulo, se discutirán los resultados obtenidos a partir de los modelos de clasificación entrenados para este propósito.

En este estudio, se aplicaron diferentes metodologías de *machine learning* para predecir y clasificar las etapas del sueño y los artefactos presentes en los datos de polisomnografía. Al evaluar el rendimiento de cada modelo, se observó que algunos modelos, como SVM (*Fine Gaussian*) y *Bagged Trees*, lograron una mayor precisión en las clases más relevantes, como las etapas REM y N2, lo que indica una capacidad de discriminación más robusta para estas etapas. Sin embargo, otras clases, como Movimiento y N1, mostraron un mayor porcentaje de falsos negativos, lo que sugiere que el modelo aún no es capaz de identificar correctamente estos eventos en las polisomnografías. De manera similar, se encontró que el modelo *KNN*, aunque efectivo en la clasificación de ciertas etapas, mostró limitaciones en la detección de las clases más complejas. Estos hallazgos subrayan la necesidad de ajustes adicionales en los hiperparámetros y la incorporación de características adicionales que puedan mejorar la clasificación de las etapas de sueño menos representadas. En general, los resultados alcanzaron una precisión promedio que supera el 75 % en las clases más relevantes, lo que valida la aplicabilidad de los modelos en la clasificación automatizada de las etapas del sueño y artefactos.

A pesar de que los modelos entrenados han mostrado un desempeño satisfactorio en la clasificación de las etapas de sueño, no se logró alcanzar el objetivo de obtener un error menor al 5%, como se esperaba inicialmente. Aunque la precisión general de los modelos fue alta, ciertas estadificaciones específicas, como Movimiento y algunas etapas de transición, como N1 y N3, presentaron tasas de falsos negativos más altas de lo esperado. Estas clases menos representadas o más complejas resultaron más difíciles de clasificar de manera precisa. Dado que no se logró clasificar de manera ideal las etapas registradas de

Movimiento, no se cumplió el objetivo de detectar efectivamente los artefactos asociados al movimiento del paciente, lo cual es esencial para una correcta interpretación de los datos de polisomnografía. Los artefactos, causados usualmente por el movimiento de los pacientes durante el sueño, interfieren significativamente con el registro de las señales fisiológicas. La incapacidad de los modelos para identificar correctamente el Movimiento limita su efectividad en la detección de estos artefactos, lo que afecta la capacidad de clasificación general del modelo. A continuación, se discuten los resultados obtenidos para cada modelo, las razones detrás de estos y las posibles estrategias para mejorar su desempeño.

El modelo de k-Nearest Neighbors (KNN) mostró un buen rendimiento en las etapas de sueño N2 y W, sin embargo, presentó un alto porcentaje de falsos negativos en las clases de Movimiento y en las etapas N1 y N3, lo que sugiere dificultades para identificar correctamente los patrones de estas clases. Esto podría deberse a la falta de distinción adecuada entre las señales fisiológicas de las diferentes etapas del sueño, lo que lleva a una mayor confusión entre clases que comparten características similares. A pesar de los ajustes realizados en los hiperparámetros, como el número de vecinos y la métrica de distancia, es posible que se requiera una mayor iteración de estos parámetros o la inclusión de nuevas características para mejorar la precisión de las clases problemáticas [81][80].

El tamaño de la base de datos puede influir significativamente en el desempeño de los modelos, especialmente en el caso de algoritmos como KNN y SVM, que dependen de una buena distribución de los datos para aprender patrones precisos [81] [88]. De manera similar, la selección de características jugó un papel importante en el rendimiento de los modelos. La adición de características relacionadas con el movimiento o artefactos podría mejorar la capacidad de clasificación en esas clases problemáticas.

Los modelos *Ensemble (Bagged Trees)* y Red Neuronal demostraron un mejor manejo de la complejidad de los datos y fueron más robustos al clasificar las diferentes etapas del sueño. El uso de *bagging* permitió reducir la varianza y mejorar la precisión al combinar múltiples árboles de decisión, lo que resultó en una mayor estabilidad en la clasificación. [86]En cambio, los modelos basados en SVM mostraron una mayor capacidad para manejar datos no lineales, lo que permitió una clasificación precisa en clases como REM y W, pero aún presentaron dificultades con las clases menos representadas. Las redes neuronales, al ser modelos no lineales complejos, también mostraron un rendimiento sólido, aunque en algunos casos se beneficiaron de una mayor cantidad de datos de entrenamiento para afinar los parámetros internos y mejorar la capacidad de generalización [79].

A pesar del rendimiento apreciable en la predicción de los modelos, existen varias limitaciones en este estudio. Dado que los datos fueron recolectados de una sola base de datos, estos resultados son difíciles de generalizar a la población en general. Además, la falta de datos sobre movimientos y artefactos también representó un desafío, ya que la clasificación de la clase “Movimiento” presentó altas tasas de falsos negativos, lo que indica que el modelo tuvo dificultades para identificar correctamente los artefactos relacionados con el movimiento del paciente. Esta deficiencia en la detección de artefactos interfiere con la capacidad del modelo para proporcionar una clasificación precisa y completa de las etapas del sueño. Estas limitaciones destacan la importancia de contar con bases de datos más completas y representativas, así como la inclusión de características adicionales que puedan mejorar la capacidad del modelo para diferenciar de manera más efectiva entre las diversas etapas del sueño y los artefactos.

- El desarrollo del algoritmo automatizado basado en técnicas de machine learning para analizar polisomnografías y detectar estadios del sueño y artefactos se logró parcialmente. Los modelos entrenados fueron capaces de clasificar correctamente la mayoría de las etapas del sueño, logrando una precisión máxima de hasta el 76.8 % con el modelo de *Bagged Trees*. Sin embargo, algunas clases, especialmente movimiento, mostraron altas tasas de falsos negativos. Este resultado subraya la necesidad de mejorar la clasificación de artefactos de movimiento, realizar ajustes adicionales en los hiperparámetros, así como la inclusión de características adicionales que permitan una mejor diferenciación entre las etapas de sueño y los artefactos.
- Se logró establecer un proceso estructurado para la adquisición y limpieza de datos de polisomnografía, utilizando herramientas de MATLAB. El procesamiento de datos fue realizado de manera satisfactoria, logrando extraer todos los datos de la base de datos de PhysioNet, agruparlos de manera ideal y extraer las características necesarias para construir una base de datos procesable.
- El uso de un conjunto de datos de repositorios de polisomnografía permitió entrenar los modelos de machine learning, que fueron capaces de identificar y separar correctamente la mayoría de las etapas del sueño. Sin embargo, algunas clases menos representadas, como las etapas de transición N1 y N3, así como los artefactos de movimiento, presentaron dificultades en su clasificación. Esto resalta la necesidad de la ampliación y diversificación del conjunto de datos para mejorar la capacidad de generalización del modelo, junto con la inclusión de nuevas características.
- La validación de los algoritmos con datos reales no permitió alcanzar el objetivo de un error menor al 5 %. Aunque las clasificaciones fueron satisfactorias en la mayoría de los casos, las clases Movimiento y las etapas de transición mostraron un mayor porcentaje de falsos negativos. Para mejorar el rendimiento del modelo, se recomienda la implementación de técnicas de preprocesamiento más avanzadas y la optimización de los hiperparámetros, además de ampliar el conjunto de datos con ejemplos más representativos.

- Al presentar el algoritmo a especialistas en trastornos del sueño, estos consideraron que representa una herramienta útil para reducir su carga de trabajo. Destacaron que el enfoque está bien formulado y señalaron posibles mejoras en la clasificación de los estadios del sueño. Además, recalcaron la importancia de su implementación como una herramienta de apoyo en la calificación de estudios PSG, con el potencial de evolucionar hacia una automatización completa en el futuro.

- Incrementar el tamaño del conjunto de datos utilizado para entrenar los modelos. Esto podría incluir la recopilación de más datos de diversas fuentes o la ampliación de la base de datos de PhysioNet con más muestras representativas de las clases menos representadas, como Movimiento. Un conjunto de datos más grande y equilibrado podría ayudar a mejorar la precisión del modelo y reducir las tasas de falsos negativos.
- Realizar un análisis más exhaustivo de las características utilizadas para entrenar los modelos. Incluir características adicionales relacionadas con los artefactos de movimiento, o incluso características extraídas de la señal EMG, podría mejorar la capacidad del modelo para detectar estos artefactos de forma más precisa.
- Aunque se ajustaron algunos hiperparámetros durante el proceso, se recomienda continuar con la iteración y ajuste de estos parámetros para optimizar el rendimiento del modelo. En particular, la selección del número de vecinos en el KNN y los parámetros relacionados con la red neuronal pueden ser objeto de una búsqueda más exhaustiva.
- Explorar el uso de modelos más avanzados, como redes neuronales profundas (*Deep Learning*) o técnicas no supervisadas de aprendizaje automático, como el clustering. Estos modelos podrían ser capaces de captar patrones más complejos en los datos, especialmente en los artefactos de movimiento y las etapas de transición del sueño que presentaron dificultades de clasificación. La implementación de redes neuronales recurrentes (RNN) o modelos auto-codificadores podría ser beneficiosa para mejorar el rendimiento en la clasificación de artefactos y las transiciones de sueño.
- Siguiendo el propósito original de este trabajo de graduación, se fomenta continuar desarrollando tecnologías que contribuyan a mejorar la calidad de vida de las personas. En el caso particular de este estudio, una vez que los modelos sean optimizados y validados, se sugiere centrarse en la automatización del sistema para su implementación en entornos clínicos. Esto implicaría integrar los modelos en plataformas de análisis de polisomnografía ya existentes, de manera que los resultados

se generen automáticamente, permitiendo que los técnicos del sueño se enfoquen en tareas más críticas y que el proceso de análisis sea más eficiente.

- 
- [1] C. M. Michel, M. M. Murray, G. Lantz, S. Gonzalez, L. Spinelli y R. G. De Peralta, “EEG source imaging [Imágenes de fuente EEG],” *Clinical neurophysiology*, vol. 115, n.º 10, págs. 2195-2222, 2004.
  - [2] M. Seeber, L.-M. Cantonas, M. Hoevels, T. Sesia, V. Visser-Vandewalle y C. M. Michel, “Subcortical electrophysiological activity is detectable with high-density EEG source imaging [La actividad electrofisiológica subcortical es detectable con imágenes de fuente EEG de alta densidad.],” *Nature communications*, vol. 10, n.º 1, pág. 753, 2019.
  - [3] L. C. Markun y A. Sampat, “Clinician-focused overview and developments in polysomnography [Visión general y avances en la polisomnografía, centrados en el clínico],” *Current sleep medicine reports*, vol. 6, págs. 309-321, 2020.
  - [4] J. V. Rundo y R. Downey, “Chapter 25-Polysomnography,” *Handbook of Clinical Neurology*, págs. 381-392,
  - [5] V. K. Kapur, D. H. Auckley, S. Chowdhuri et al., “Clinical practice guideline for diagnostic testing for adult obstructive sleep apnea: an American Academy of Sleep Medicine clinical practice guideline [Guía de práctica clínica para las pruebas diagnósticas de la apnea obstructiva del sueño en adultos: una guía de práctica clínica de la Academia Estadounidense de Medicina del Sueño],” *Journal of clinical sleep medicine*, vol. 13, n.º 3, págs. 479-504, 2017.
  - [6] A. Manoni, F. Loreti, V. Radicioni et al., “A new wearable system for home sleep apnea testing, screening, and classification [Nuevo sistema portátil para la evaluación, detección y clasificación de la apnea del sueño en el hogar.],” *Sensors*, vol. 20, n.º 24, pág. 7014, 2020.
  - [7] N. Stanley, “The Future of Sleep Staging, Revisited [El futuro de la estadificación del sueño, revisado],” *Nature and Science of Sleep*, págs. 313-322, 2023.
  - [8] V. Gerla, V. Djordjevic, L. Lhotska y V. Krajca, “PSGLab Matlab toolbox for polysomnographic data processing: Development and practical application,” en *Proceedings of the 10th IEEE International Conference on Information Technology and Applications in Biomedicine*, IEEE, 2010, págs. 1-4.

- [9] S. Pallesen, J. Grønli, K. Myhre et al., “A pilot study of impulse radio ultra wideband radar technology as a new tool for sleep assessment [Un estudio piloto de la tecnología de radar de banda ultraancha de radio de impulsos como una nueva herramienta para la evaluación del sueño],” *Journal of Clinical Sleep Medicine*, vol. 14, n.º 7, págs. 1249-1254, 2018.
- [10] K. Nakazaki, S. Kitamura, Y. Motomura et al., “Validity of an algorithm for determining sleep/wake states using a new actigraph,” *Journal of physiological anthropology*, vol. 33, págs. 1-8, 2014.
- [11] S. Toften, S. Pallesen, M. Hrozanova, F. Moen y J. Grønli, “Validation of sleep stage classification using non-contact radar technology and machine learning (Somnofy®) [Validación de la clasificación de las fases del sueño mediante tecnología de radar sin contacto y aprendizaje automático (Somnofy®)],” *Sleep Medicine*, vol. 75, págs. 54-61, 2020.
- [12] G. Medic, M. Wille y M. E. Hemels, “Short-and long-term health consequences of sleep disruption [Consecuencias a corto y largo plazo de la interrupción del sueño para la salud],” *Nature and science of sleep*, págs. 151-161, 2017.
- [13] F. P. Cappuccio, L. D’Elia, P. Strazzullo y M. A. Miller, “Sleep duration and all-cause mortality: a systematic review and meta-analysis of prospective studies [Duración del sueño y mortalidad por todas las causas: una revisión sistemática y un metanálisis de estudios prospectivos],” *Sleep*, vol. 33, n.º 5, págs. 585-592, 2010.
- [14] W. J. Joiner, “The neurobiological basis of sleep and sleep disorders [La base neurobiológica del sueño y los trastornos del sueño],” *Physiology*, vol. 33, n.º 5, págs. 317-327, 2018.
- [15] M. A. Grandner y F.-X. Fernandez, “The translational neuroscience of sleep: a contextual framework [La neurociencia traslacional del sueño: una marco contextual],” *Science*, vol. 374, n.º 6567, págs. 568-573, 2021.
- [16] M. A. Grandner, “Sleep, health, and society [Sueño, salud y sociedad],” *Sleep medicine clinics*, vol. 17, n.º 2, págs. 117-139, 2022.
- [17] N. M. Dwi Satyawati, L. P. Lina Kamelia y N. N. Mestri Agustini, “Prevalensi Gangguan Neurologi pada Tenaga Kerja Pariwisata di Kawasan Wisata Pantai Lovina di Kabupaten Buleleng [Predominio Trastornos neurológicos en trabajadores del turismo en la zona turística de Lovina Beach en la regencia de Buleleng],” Tesis doct., Universitas Pendidikan Ganesha, 2024.
- [18] C. Gauld, R. Lopez, P. A. Geoffroy et al., “A systematic analysis of ICSD-3 diagnostic criteria and proposal for further structured iteration [Análisis sistemático de los criterios diagnósticos de la ICSD-3 y propuesta para una iteración estructurada adicional],” *Sleep Medicine Reviews*, vol. 58, pág. 101 439, 2021.
- [19] M. R. Patterson, A. A. Nunes, D. Gerstel et al., “40 years of actigraphy in sleep medicine and current state of the art algorithms [40 años de actigrafía en la medicina del sueño y algoritmos de vanguardia],” *NPJ Digital Medicine*, vol. 6, n.º 1, pág. 51, 2023.
- [20] R. J. Cole, D. F. Kripke, W. Gruen, D. J. Mullaney y J. C. Gillin, “Automatic sleep/wake identification from wrist activity [Identificación automática de sueño/vigilia a partir de la actividad de la muñeca],” *Sleep*, vol. 15, n.º 5, págs. 461-469, 1992.

- [21] J. F. Torres, D. Hadjout, A. Sebaa, F. Martínez-Álvarez y A. Troncoso, “Deep learning for time series forecasting: a survey [Aprendizaje profundo para la previsión de series temporales: una encuesta],” *Big Data*, vol. 9, n.º 1, págs. 3-21, 2021.
- [22] A. Troncoso-García, M. Martínez-Ballesteros, F. Martínez-Álvarez y A. Troncoso, “Explainable machine learning for sleep apnea prediction [Aprendizaje automático explicable para la predicción de la apnea del sueño],” *Procedia Computer Science*, vol. 207, págs. 2930-2939, 2022.
- [23] M. Walker, *Why we sleep: Unlocking the power of sleep and dreams [Por qué dormimos: Desbloqueando el poder del sueño y los sueños]*. Simon y Schuster, 2017.
- [24] A. S. Freiberg, “Why we sleep: a hypothesis for an ultimate or evolutionary origin for sleep and other physiological rhythms [Por qué dormimos: una hipótesis sobre un origen último o evolutivo del sueño y otros ritmos fisiológicos],” *Journal of circadian rhythms*, vol. 18, 2020.
- [25] R. G. Foster, “There is no mystery to sleep [No hay ningún misterio en dormir],” *PsyCh journal*, vol. 7, n.º 4, págs. 206-208, 2018.
- [26] C. Cirelli y G. Tononi, “Is sleep essential? [¿Es esencial el sueño?]” *PLoS biology*, vol. 6, n.º 8, e216, 2008.
- [27] C. B. Saper, T. E. Scammell y J. Lu, “Hypothalamic regulation of sleep and circadian rhythms [Regulación hipotalámica del sueño y los ritmos circadianos],” *Nature*, vol. 437, n.º 7063, págs. 1257-1263, 2005.
- [28] N. N. Aalling, M. Nedergaard y M. DiNuzzo, “Cerebral metabolic changes during sleep [Cambios metabólicos cerebrales durante el sueño],” *Current neurology and neuroscience reports*, vol. 18, págs. 1-17, 2018.
- [29] J. A. Hobson, “Sleep is of the brain, by the brain and for the brain [El sueño es del cerebro, por el cerebro y para el cerebro],” *Nature*, vol. 437, n.º 7063, págs. 1254-1256, 2005.
- [30] B. T. Preston, I. Capellini, P. McNamara, R. A. Barton y C. L. Nunn, “Parasite resistance and the adaptive significance of sleep [La resistencia a los parásitos y la importancia adaptativa del sueño],” *BMC evolutionary biology*, vol. 9, págs. 1-9, 2009.
- [31] B. A. Klein, A. Klein, M. K. Wray, U. G. Mueller y T. D. Seeley, “Sleep deprivation impairs precision of waggle dance signaling in honey bees [La falta de sueño afecta la precisión de la señalización del baile de meneo en las abejas melíferas],” *Proceedings of the National Academy of Sciences*, vol. 107, n.º 52, págs. 22 705-22 709, 2010.
- [32] L. Xie, H. Kang, Q. Xu et al., “Sleep drives metabolite clearance from the adult brain [El sueño impulsa la eliminación de metabolitos del cerebro adulto],” *science*, vol. 342, n.º 6156, págs. 373-377, 2013.
- [33] J. Li, M. V. Vitiello y N. S. Gooneratne, “Sleep in normal aging [El sueño en el envejecimiento normal],” *Sleep medicine clinics*, vol. 17, n.º 2, págs. 161-171, 2022.
- [34] National Institute of Neurological Disorders and Stroke, *Brain Basics: Understanding Sleep [Conceptos básicos del cerebro: comprender el sueño]*, 2024. dirección: <https://www.ninds.nih.gov/health-information/public-education/brain-basics/brain-basics-understanding-sleep>.

- [35] W. H. Walker, J. C. Walton, A. C. DeVries y R. J. Nelson, “Circadian rhythm disruption and mental health [Alteración del ritmo circadiano y salud mental],” *Translational psychiatry*, vol. 10, n.º 1, págs. 1-13, 2020.
- [36] D. M. Dominoni, J. C. Borniger y R. J. Nelson, “Light at night, clocks and health: from humans to wild organisms [Light at night, clocks and health: from humans to wild organisms],” *Biology letters*, vol. 12, n.º 2, pág. 2016015, 2016.
- [37] National Institute of General Medical Sciences, *Circadian Rhythms [Ritmos circadianos]*, 2023. dirección: <https://www.nigms.nih.gov/education/fact-sheets/Pages/circadian-rhythms.aspx>.
- [38] U. Ortega Pozas, *Alteraciones fisiológicas derivadas de cambios en el ritmo sueño-vigilia*, 2017. dirección: <https://repositorio.unican.es/xmlui/bitstream/handle/10902/11693/Ortega%20Pozas%20Unai.pdf?sequence=4&isAllowed=y#:~:text=Los%20ritmos%20circadianos%20son%20ritmos,hasta%20plantas%20superiores%20y%20mam%C3%ADferos..>
- [39] D. Kirsch, R. Benca y A. Eichler, “Stages and architecture of normal sleep [Etapas y arquitectura del sueño normal],” *UpToDate. Retrieved, March*, vol. 19, pág. 2020, 2015.
- [40] A. Patel, V. Reddy, K. Shumway et al., *Physiology, Sleep Stages [Fisiología, Etapas del sueño]* (StatPearls [Internet]), 2024 Jan-. Treasure Island (FL): StatPearls Publishing, 2024, Updated 2024 Jan 26. dirección: <https://www.ncbi.nlm.nih.gov/books/NBK526132/>.
- [41] J. Malik, Y.-L. Lo y H.-t. Wu, “Sleep-wake classification via quantifying heart rate variability by convolutional neural network [Clasificación sueño-vigilia mediante la cuantificación de la variabilidad de la frecuencia cardíaca mediante una red neuronal convolucional],” *Physiological measurement*, vol. 39, n.º 8, pág. 085004, 2018.
- [42] I. Feinberg y T. Floyd, “Systematic trends across the night in human sleep cycles [Tendencias sistemáticas a lo largo de la noche en los ciclos de sueño humanos],” *Psychophysiology*, vol. 16, n.º 3, págs. 283-291, 1979.
- [43] E. R. Kandel, J. H. Schwartz, T. M. Jessell, S. Siegelbaum, A. J. Hudspeth, S. Mack et al., *Principles of neural science [Principios de la neurociencia]*. McGraw-hill New York, 2000, vol. 4.
- [44] B. Varga, A. Gergely, Á. Galambos y A. Kis, “Heart rate and heart rate variability during sleep in family dogs (*Canis familiaris*). Moderate effect of pre-sleep emotions [Frecuencia cardíaca y variabilidad de la frecuencia cardíaca durante el sueño en perros de familia (*Canis familiaris*). Efecto moderado de las emociones previas al sueño.],” *Animals*, vol. 8, n.º 7, pág. 107, 2018.
- [45] S. N. Hernández Pérez, F. D. Pérez Reynoso, C. A. G. Gutiérrez, M. D. I. Á. Cosío León y R. Ortega Palacios, “EOG signal classification with wavelet and supervised learning algorithms KNN, SVM and DT [Clasificación de señales EOG con wavelets y algoritmos de aprendizaje supervisado KNN, SVM y DT],” *Sensors*, vol. 23, n.º 9, pág. 4553, 2023.
- [46] S. S. Cash, E. Halgren, N. Dehghani et al., “The human K-complex represents an isolated cortical down-state [El complejo K humano representa un estado inactivo cortical aislado],” *Science*, vol. 324, n.º 5930, págs. 1084-1087, 2009.

- [47] R. Wennberg, "Intracranial cortical localization of the human K-complex [Localización cortical intracraneal del complejo K humano]," *Clinical neurophysiology*, vol. 121, n.º 8, págs. 1176-1186, 2010.
- [48] V. Sarbhai, N. P. Shah y P. Chatterjee, *Normal human sleep [Sueño humano normal]*, ene. de 1970. dirección: <https://www.jaypeedigital.com/eReader/chapter/9789351524205/ch1>.
- [49] P. Memar y F. Faradji, "A novel multi-class EEG-based sleep stage classification system [A novel multi-class EEG-based sleep stage classification system]," *IEEE Transactions on Neural Systems and Rehabilitation Engineering*, vol. 26, n.º 1, págs. 84-95, 2017.
- [50] J. Peever y P. M. Fuller, "The biology of REM sleep [La biología del sueño REM]," *Current biology*, vol. 27, n.º 22, R1237-R1248, 2017.
- [51] D. A. Singh, *Stages of sleep: What happens in a sleep cycle [Etapas del sueño: ¿Qué sucede en un ciclo de sueño?]* Dic. de 2023. dirección: <https://www.sleepfoundation.org/stages-of-sleep#references-175856>.
- [52] M. Hirshkowitz, "Polysomnography challenges. [Desafíos de la polisomnografía.]," *Sleep medicine clinics*, vol. 11, n.º 4, págs. 403-411, 2016.
- [53] T. Bond, "Evaluation and diagnosis of sleep-disordered breathing [Evaluación y diagnóstico de los trastornos respiratorios del sueño]," *Oral and Maxillofacial Surgery Clinics of North America*, vol. 14, n.º 3, págs. 293-296, 2002, ISSN: 1042-3699. DOI: [https://doi.org/10.1016/S1042-3699\(02\)00030-4](https://doi.org/10.1016/S1042-3699(02)00030-4). dirección: <https://www.sciencedirect.com/science/article/pii/S1042369902000304>.
- [54] M. Kayabekir, "Sleep physiology and polysomnogram, physiopathology and symptomatology in sleep medicine [Fisiología del sueño y polisomnograma, fisiopatología y sintomatología en medicina del sueño]," *Updates in Sleep Neurology and Obstructive Sleep Apnea*, 2019.
- [55] R. B. Berry, R. Budhiraja, D. J. Gottlieb et al., "Rules for scoring respiratory events in sleep: update of the 2007 AASM manual for the scoring of sleep and associated events: deliberations of the sleep apnea definitions task force of the American Academy of Sleep Medicine [Reglas para la puntuación de eventos respiratorios durante el sueño: actualización del manual de la AASM de 2007 para la puntuación del sueño y eventos asociados: deliberaciones del grupo de trabajo de definiciones de apnea del sueño de la Academia Estadounidense de Medicina del Sueño]," *Journal of clinical sleep medicine*, vol. 8, n.º 5, págs. 597-619, 2012.
- [56] S. P. Patil, "What every clinician should know about polysomnography [Lo que todo médico debe saber sobre la polisomnografía]," *Respiratory care*, vol. 55, n.º 9, págs. 1179-1195, 2010.
- [57] M. J. Aminoff, "Electrophysiology [Electrofisiología]," en *Textbook of Clinical Neurology*, Elsevier, 2007, págs. 477-497.
- [58] F. D. Pérez-Reynoso, L. Rodríguez-Guerrero, J. C. Salgado-Ramírez y R. Ortega-Palacios, "Human-machine interface: multiclass classification by machine learning on 1D EOG Signals for the Control of an Omnidirectional Robot [Interfaz hombre-máquina: clasificación multiclase mediante aprendizaje automático en señales EOG 1D para el control de un robot omnidireccional]," *Sensors*, vol. 21, n.º 17, pág. 5882, 2021.

- [59] V. Hedges y E. Lansing, *Introduction to Neuroscience Open Edition [Introducción a la Neurociencia Edición Abierta]*, 2022. dirección: <https://openbooks.lib.msu.edu/introneuroscience1/>.
- [60] M. Tripathi, “Technical notes for digital polysomnography recording in sleep medicine practice [Notas técnicas para el registro de polisomnografía digital en la práctica de la medicina del sueño],” *Annals of Indian Academy of Neurology*, vol. 11, n.º 2, págs. 129-138, 2008.
- [61] Elsevier, *Clinical Neurophysiology [Neurofisiología clínica]*, 2024. dirección: <https://media.journals.elsevier.com/content/files/clinph-chapter11-14082757.pdf>.
- [62] C. S. Nayak y A. C. Anilkumar, “EEG Normal Sleep, StatPearls [EEG del sueño normal, StatPearls],” *Stat-Pearls Publishing*, 2021.
- [63] R. Shriram, M. Sundhararajan y N. Daimiwal, “EEG Based Cognitive Workload Assessment for Maximum Efficiency,” *IOSR Journal of Electronics and Communication Engineering (IOSR-JECE)*, ago. de 2012.
- [64] National Institute on Aging [Instituto Nacional sobre el Envejecimiento], *Polysomnography Hook-Up Protocol*, 2024. dirección: [https://agingresearchbiobank.nia.nih.gov/studies/mros/documents/download/Protocols/Sleep\\_V1/Sleep\\_PolysomnographyHookUp.pdf/](https://agingresearchbiobank.nia.nih.gov/studies/mros/documents/download/Protocols/Sleep_V1/Sleep_PolysomnographyHookUp.pdf/).
- [65] Neumosur, *Polisomnografía*, 2024. dirección: [https://www.neumosur.net/files/publicaciones/ebook/15-POLISOMNOGRAFIA-Neumologia-3\\_ed.pdf](https://www.neumosur.net/files/publicaciones/ebook/15-POLISOMNOGRAFIA-Neumologia-3_ed.pdf).
- [66] Elsevier, “Article on ScienceDirect [Artículo en ScienceDirect],” *ScienceDirect*, 2024. dirección: <https://www.sciencedirect.com/science/article/abs/pii/B9780323085007000060>.
- [67] D. Moser, P. Anderer, G. Gruber et al., “Sleep classification according to AASM and Rechtschaffen & Kales: effects on sleep scoring parameters [Clasificación del sueño según AASM y Rechtschaffen Kales: efectos sobre los parámetros de puntuación del sueño],” *Sleep*, vol. 32, n.º 2, págs. 139-149, 2009.
- [68] B. Gerstenslager y J. M. Slowik, “Sleep study [Estudio del sueño],” *Sleep*, 2020. dirección: <https://www.ncbi.nlm.nih.gov/books/NBK563147/>.
- [69] M. M. Grigg-Damberger, “The AASM scoring manual: a critical appraisal [El manual de puntuación de la AASM: una evaluación crítica],” *Current opinion in pulmonary medicine*, vol. 15, n.º 6, págs. 540-549, 2009.
- [70] J. A. Nichols, H. W. Herbert Chan y M. A. Baker, “Machine learning: applications of artificial intelligence to imaging and diagnosis [Aprendizaje automático: aplicaciones de la inteligencia artificial a la imagen y el diagnóstico],” *Biophysical reviews*, vol. 11, págs. 111-118, 2019.
- [71] R. P. França, A. C. Borges Monteiro, R. Arthur e Y. Iano, “Chapter 3 - An overview of deep learning in big data, image, and signal processing in the modern digital age [Capítulo 3 - Una descripción general del aprendizaje profundo en big data, imágenes y procesamiento de señales en la era digital moderna],” en *Trends in Deep Learning Methodologies*, ép. Hybrid Computational Intelligence for Pattern Analysis, V. Piuri, S. Raj, A. Genovese y R. Srivastava, eds., Academic Press, 2021, págs. 63-87, ISBN: 978-0-12-822226-3. DOI: <https://doi.org/10.1016/B978-0-12-822226-3.00003-9>. dirección: <https://www.sciencedirect.com/science/article/pii/B9780128222263000039>.

- [72] M. Mohammed, M. B. Khan y E. B. M. Bashier, *Machine Learning: Algorithms and Applications [Aprendizaje automático: algoritmos y aplicaciones]*. CRC Press, 2016. dirección: <https://www.taylorfrancis.com/books/mono/10.1201/9781315371658/machine-learning-mohssen-mohammed-muhammad-badruddin-khan-eihab-bashier-mohammed-bashier>.
- [73] J. Han, J. Pei y H. Tong, *Data mining: concepts and techniques [Minería de datos: conceptos y técnicas]*. Morgan kaufmann, 2022.
- [74] I. H. Sarker, A. Kayes, S. Badsha, H. Alqahtani, P. Watters y A. Ng, “Cybersecurity data science: an overview from machine learning perspective [Ciencia de datos de ciberseguridad: una visión general desde la perspectiva del aprendizaje automático],” *Journal of Big data*, vol. 7, págs. 1-29, 2020.
- [75] I. H. Sarker, “Machine learning: Algorithms, real-world applications and research directions [Aprendizaje automático: algoritmos, aplicaciones reales y direcciones de investigación],” *SN computer science*, vol. 2, n.º 3, pág. 160, 2021.
- [76] L. P. Kaelbling, M. L. Littman y A. W. Moore, “Reinforcement learning: A survey [Aprendizaje por refuerzo: una encuesta],” *Journal of artificial intelligence research*, vol. 4, págs. 237-285, 1996.
- [77] J. Peng, E. C. Jury, P. Dönnnes y C. Ciurtin, “Machine learning techniques for personalised medicine approaches in immune-mediated chronic inflammatory diseases: applications and challenges [Técnicas de aprendizaje automático para enfoques de medicina personalizada en enfermedades inflamatorias crónicas inmunomediadas: aplicaciones y desafíos],” *Frontiers in pharmacology*, vol. 12, pág. 720694, 2021.
- [78] S. Uddin, A. Khan, M. E. Hossain y M. A. Moni, “Comparing different supervised machine learning algorithms for disease prediction [Comparación de diferentes algoritmos de aprendizaje automático supervisado para la predicción de enfermedades],” *BMC medical informatics and decision making*, vol. 19, n.º 1, págs. 1-16, 2019.
- [79] B. Mahesh, “Machine learning algorithms-a review [Algoritmos de aprendizaje automático: una revisión],” *International Journal of Science and Research (IJSR).[Internet]*, vol. 9, n.º 1, págs. 381-386, 2020.
- [80] S. Uddin, I. Haque, H. Lu, M. A. Moni y E. Gide, “Comparative performance analysis of K-nearest neighbour (KNN) algorithm and its different variants for disease prediction [Análisis comparativo del rendimiento del algoritmo K-vecino más cercano (KNN) y sus diferentes variantes para la predicción de enfermedades],” *Scientific Reports*, vol. 12, n.º 1, pág. 6256, 2022.
- [81] N. Bhatia et al., “Survey of nearest neighbor techniques [Estudio de técnicas de vecino más cercano],” *arXiv preprint arXiv:1007.0085*, 2010.
- [82] E.-H. Han, G. Karypis y V. Kumar, “Text categorization using weight adjusted k-nearest neighbor classification [Categorización de texto mediante la clasificación de k vecinos más cercanos ajustada por peso],” en *Advances in Knowledge Discovery and Data Mining: 5th Pacific-Asia Conference, PAKDD 2001 Hong Kong, China, April 16–18, 2001 Proceedings 5*, Springer, 2001, págs. 53-65.


- [83] P. Inuera, *A simple introduction to the K-nearest neighbour (knn) algorithm [Una introducción sencilla al algoritmo de los K vecinos más cercanos (knn)]*, ago. de 2023. dirección: <https://www.iunera.com/kraken/fabric/k-nearest-neighbour-knn-algorithm/>.
- [84] IBM. “¿Qué son las redes neuronales?” (2024), dirección: <https://www.ibm.com/es-es/topics/neural-networks> (visitado 15-11-2024).
- [85] A. Vidhya. “La evolución y los conceptos fundamentales de las redes neuronales y el aprendizaje profundo.” (2016), dirección: <https://www.analyticsvidhya.com/blog/2016/08/evolution-core-concepts-deep-learning-neural-networks/> (visitado 15-11-2024).
- [86] Z.-H. Zhou, *Ensemble methods: foundations and algorithms [Métodos de conjunto: fundamentos y algoritmos]*. CRC press, 2012.
- [87] A. Vidhya, “Ensemble Models: Bagging Boosting [Modelos de conjunto: Bagging y Boosting],” *Medium*, 2020. dirección: <https://medium.com/analytics-vidhya/ensemble-models-bagging-boosting-c33706db0b0b>.
- [88] MathWorks, *Support Vector Machine (SVM) [Máquina de vectores de soporte (SVM)]*, 2023. dirección: [https://la.mathworks.com/discovery/support-vector-machine.html#:~:text=Support%20vector%20machine%20\(SVM\)%20es,reconocimiento%20de%20im%C3%A1genes%20y%20voz..](https://la.mathworks.com/discovery/support-vector-machine.html#:~:text=Support%20vector%20machine%20(SVM)%20es,reconocimiento%20de%20im%C3%A1genes%20y%20voz..)
- [89] J. E. Dobson, “On the Confusion Matrix [En la Matriz de Confusión],” *Configurations*, vol. 32, n.º 4, págs. 331-350, 2024.
- [90] G. Canbek, S. Sagiroglu, T. T. Temizel y N. Baykal, “Binary classification performance measures/metrics: A comprehensive visualized roadmap to gain new insights [edidas/métricas de rendimiento de la clasificación binaria: una hoja de ruta visualizada y completa para obtener nuevos conocimientos],” en *2017 International Conference on Computer Science and Engineering (UBMK)*, IEEE, 2017, págs. 821-826.
- [91] D. Krstinić, M. Braović, L. Šerić y D. Božić-Štulić, “Multi-label classifier performance evaluation with confusion matrix [Evaluación del rendimiento del clasificador multietiqueta con matriz de confusión],” *Computer Science & Information Technology*, vol. 1, págs. 1-14, 2020.
- [92] E. AI Team, *How to interpret a confusion matrix for a machine learning model [Cómo interpretar una matriz de confusión para un modelo de aprendizaje automático]*. dirección: <https://www.evidentlyai.com/classification-metrics/confusion-matrix>.
- [93] S. Narkhede, “Understanding auc-roc curve [Comprensión de la curva auc-roc],” *Towards data science*, vol. 26, n.º 1, págs. 220-227, 2018.
- [94] R. D. Thantilage, N.-A. Le-Khac y M.-T. Kechadi, “Healthcare data security and privacy in Data Warehouse architectures [Seguridad y privacidad de los datos sanitarios en las arquitecturas de almacenamiento de datos],” *Informatics in Medicine Unlocked*, vol. 39, pág. 101 270, 2023, ISSN: 2352-9148. DOI: <https://doi.org/10.1016/j.imu.2023.101270>. dirección: <https://www.sciencedirect.com/science/article/pii/S2352914823001144>.

- [95] C. Li, Y. Qi, X. Ding, J. Zhao, T. Sang y M. Lee, “A deep learning method approach for sleep stage classification with EEG spectrogram [Un enfoque de aprendizaje profundo para la clasificación de las etapas del sueño con espectrograma EEG],” *International Journal of Environmental Research and Public Health*, vol. 19, n.º 10, pág. 6322, 2022.
- [96] T. S. Alshammari, “Applying Machine Learning Algorithms for the Classification of Sleep Disorders [Aplicación de algoritmos de aprendizaje automático para la clasificación de los trastornos del sueño],” *IEEE Access*, vol. 12, págs. 36 110-36 121, 2024. DOI: 10.1109/ACCESS.2024.3374408.
- [97] H. Han y J. Oh, “Application of various machine learning techniques to predict obstructive sleep apnea syndrome severity [Aplicación de diversas técnicas de aprendizaje automático para predecir la gravedad del síndrome de apnea obstructiva del sueño],” *Scientific Reports*, vol. 13, n.º 1, pág. 6379, 2023.
- [98] G. Moody, R. Mark y A. Goldberger, “PhysioNet: A research resource for studies of complex physiologic and biomedical signals [PhysioNet: Un recurso de investigación para estudios de señales fisiológicas y biomédicas complejas],” en *Computers in Cardiology 2000. Vol. 27 (Cat. 00CH37163)*, IEEE, 2000, págs. 179-182.
- [99] A. L. Goldberger, L. A. Amaral, L. Glass et al., “PhysioBank, PhysioToolkit, and PhysioNet: components of a new research resource for complex physiologic signals [PhysioBank, PhysioToolkit y PhysioNet: componentes de un nuevo recurso de investigación para señales fisiológicas complejas],” *circulation*, vol. 101, n.º 23, e215-e220, 2000.

### 13.1. Anexo 1. Estadificación del sueño procesada mediante MATLAB de la base de datos PhysioNet


En este anexo se presentan las figuras generadas tras el procesamiento de señales PSG de la base de datos Sleep-EDF de PhysioNet. Cada figura representa una ventana de 30 segundos correspondiente a un estadio específico del sueño.

**Anexo 28.** *Estadio del sueño N1.*

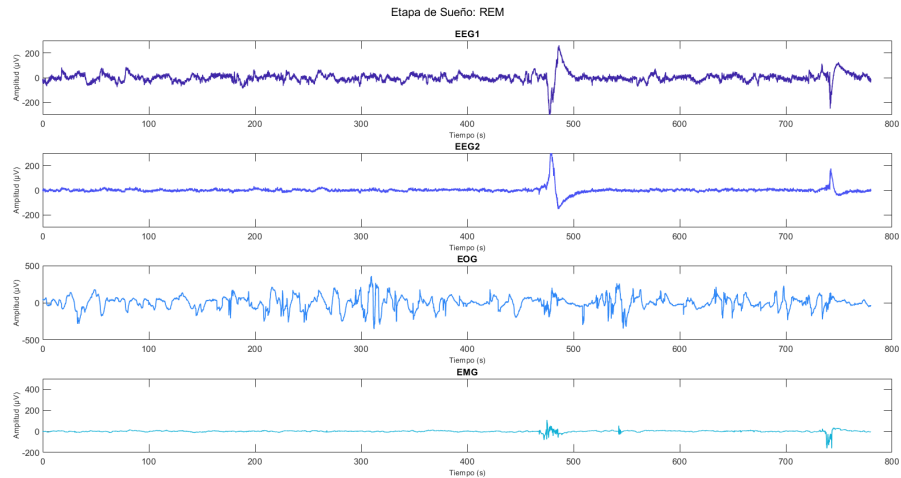




### Anexo 31. Estadío del sueño N4.



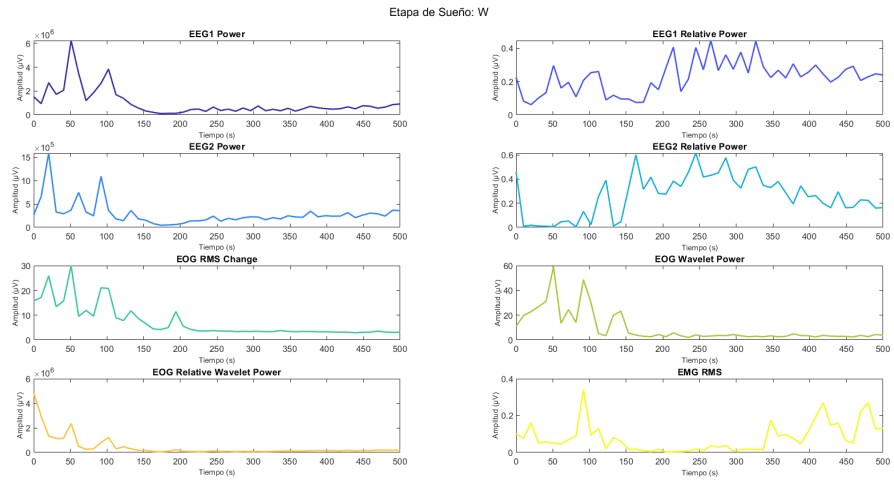
### Anexo 32. Estadío del sueño REM.



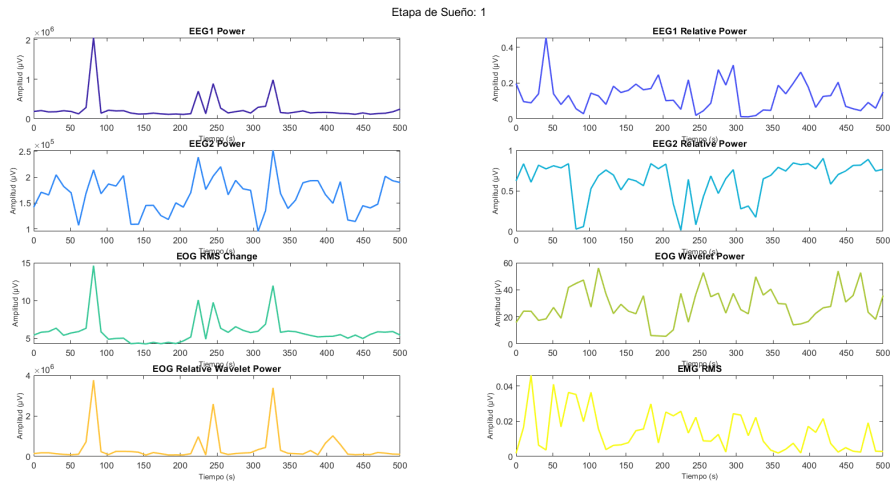
## 13.2. Anexo 2. Estadificación del sueño con estadísticas agregadas

Este anexo presenta visualizaciones del procesamiento estadístico aplicado a los diferentes estadios del sueño. Las imágenes muestran la representación gráfica de características extraídas mediante análisis de 300 muestras por ventana, lo cual permite observar patrones relevantes para la clasificación automática.

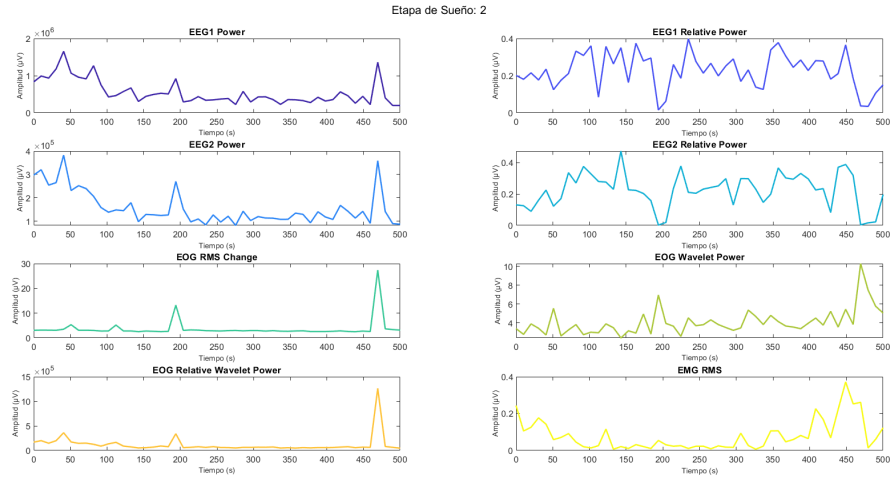
### Anexo 33. Estadío W procesado.



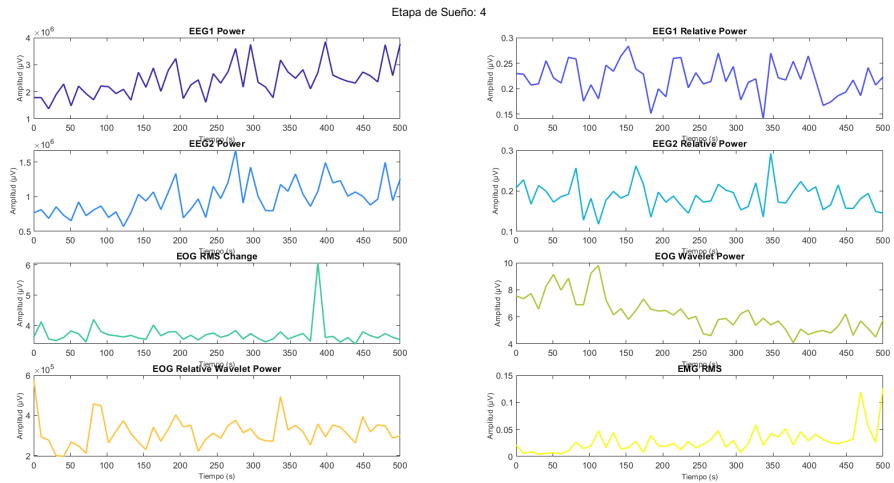
### Anexo 34. Estadío N1 procesado.



Anexo 35. Estadio N2 procesado.



Anexo 36. Estadio N4 procesado.



### Anexo 37. Estadío REM procesado.

