

Treball de Fi de Grau

Grau en Enginyeria en Tecnologies Industrials

**Clasificación de las fases del sueño utilizando
señales EEG**

MEMORIA

Autora: Carmina Saló Casajuana
Directoras: Carolina Migliorelli i Leidy Yanet Serna
Convocatoria: Enero 2019



Escola Tècnica Superior
d'Enginyeria Industrial de Barcelona



Resumen

La identificación eficaz de las fases del sueño es de gran ayuda para el tratamiento de problemas del sueño como la apnea obstructiva (OSA), insomnio o narcolepsia. De esta manera, se puede mejorar la calidad de vida de los pacientes.

La clasificación de estas fases pueden realizarla expertos del sueño de manera manual, basándose en señales PSG (Polisomnograma). No obstante, esto requiere mucho tiempo y para realizar una polisomnografía se necesitan muchas señales. Con un clasificador automático basado en señales EEG la detección sería más rápida y efectiva.

En este trabajo se ha realizado una investigación de estudios ya realizados de la detección automática de las fases del sueño y se ha experimentado con las señales EEG de 4 sujetos sanos: se han extraído un conjunto de características y se ha evaluado del rendimiento de diferentes clasificadores.

Con el clasificador KNN, 7 características y 8 canales EEG, se han clasificado las fases del sueño con un *F1 score* del 51,41%.

Como líneas de investigación futuras para mejorar los resultados se ha propuesto añadir características espectrales y reducir el número de canales, entre otras.

Índice

1. Glosario	5
2. Introducción	6
2.1. Objetivos	6
2.2. Estado del arte	6
2.2.1. Señales EEG	6
2.2.2. Clases a predecir.....	7
2.2.3. Ondas de la señal EEG	8
2.2.4. Características que se han extraído y clasificadores usados.....	9
2.2.5. Hipnograma.....	10
3. Metodología.....	12
3.1. Datos experimentales.....	12
3.2. Extracción de características	12
3.2.1. Características estadísticas	13
3.2.2. Características de potencia.....	14
3.2.3. Características no lineales	15
3.3. Representación de características	16
3.4. Mejora de las características	17
3.4.1. Interpolación de los datos	17
3.4.2. Media móvil.....	18
3.4.3. Normalización de las variables	19
3.5. Extracción del hipnograma para cada sujeto.....	20
3.6. Clasificación.....	21
3.6.1. Matriz de características	21
3.6.2. Aprendizaje automático	21
3.6.3. Métodos de clasificación	22
3.7. Validación de los resultados	23

3.7.1. Matriz de confusión.....	23
3.7.2. Estructura de validación de resultados.....	25
4. Resultados.....	27
4.1. Selección de canales.....	27
4.2. Selección de características.....	28
4.3. Predicción de las fases del sueño dejando un sujeto afuera.....	29
5. Discusión.....	31
6. Conclusiones y futuras líneas de investigación.....	33
7. Agradecimientos.....	34
8. Bibliografía.....	35
9. Anexos.....	37
Anexo 1. Código desarrollado para la extracción de características.....	37

1. Glosario

PSG = polisomnograma

EEG = electroencefalograma

TP = true positive (verdadero positivo)

TN = true negative (verdadero negativo)

FN = false negative (falso negativo)

ZC = *Zero Crossing*

SE = *Sample Entropy*

SWA = *Slow Wave Activity*

2. Introducción

Las personas pasan una tercera parte de su vida durmiendo (Aboalayon et al. 2016). No obstante, actualmente existe un número considerable de personas que sufren desórdenes en este aspecto como el insomnio o la Apnea Obstructiva (OSA) y estos pueden afectar a su salud física (Liang, Kuo, Hu, Pan, et al. 2012).

El sueño, en su desarrollo, va pasando por diferentes etapas, las cuales se han definido en diferentes estudios, revelando la profundidad del sueño y la fisiología. Según (Şen et al. 2014), la fase de sueño profunda y sana ayuda a acelerar la recuperación física. A la vez, una fase REM sana, ayuda a la memoria y la capacidad de aprendizaje. Es importante, por lo tanto, poder detectar las fases del sueño para poder solventar los problemas del dormir.

2.1. Objetivos

El objetivo principal del proyecto es desarrollar un detector de las diferentes fases del sueño usando diferentes configuraciones de electrodos EEG de superficie y diferentes características temporales y espectrales.

Los objetivos específicos son analizar la bibliografía existente sobre el tema, seleccionar y calcular aquellas características que permitan predecir las fases del sueño, probar diferentes configuraciones de canales, clasificar las fases con diversos algoritmos de aprendizaje automático, analizar los resultados obtenidos y proponer nuevas líneas de investigación.

2.2. Estado del arte

2.2.1. Señales EEG

El electroencefalograma fue desarrollado por el psiquiatra Hans Berger en 1929 y registra la actividad eléctrica del cerebro.

Según (Aboalayon et al. 2016), el cerebro humano se compone de un sistema dinámico y complejo que consiste en millones de neuronas interconectadas por axones y dendritas. Esta actividad eléctrica se puede captar mediante los electrodos de un electroencefalograma (EEG). Estos electrodos pasan a ser canales, los cuales se distribuyen a lo largo del cráneo de diferentes maneras. En la Figura 1, se muestra la representación de canales según el sistema 10-20 (Homan, Herman, and Purdy 1987, 376–82).

las siguientes tres clases: fases N1, N2 y N3, de menos a más profunda, respectivamente. Según las reglas que Rechtschaffen y Kales (R&K) propusieron en 1968 (Allan Hobson 1969; Anderer et al. 2007), la división de la fase NREM se puede hacer en las siguientes cuatro clases: N-REM fase 1, N-REM fase 2, N-REM fase 3 y N-REM fase 4, también de menos a más profundas, con épocas de 30 segundos. En el estudio actual, se han seguido las reglas de AASM, dividiendo el sueño en las siguientes cinco clases:

AW: despierto

REM

N1: estado de somnolencia	}	NREM
N2: sueño ligero		
N3: fase profunda		

A lo largo del sueño, se va pasando por varios ciclos: se empieza por la fase N1, que es la transición entre la vigilia y el sueño y constituye un 4-5% de todo el sueño. A continuación, tiene lugar la fase N2, que constituye un 45-55% del total de sueño. Esta va seguida de la fase N3, conocida también como SWS (*slow wave sleep*), la cual es más profunda y es la parte más restauradora del sueño. Esta comprende aproximadamente el 4-6% del sueño. Finalmente, se llega a la fase REM, que constituye el 20-25% del sueño y es en la que tienen lugar los sueños. Tiene un patrón muy similar a la fase N1 (Ebrahimi et al. 2008). A lo largo de la noche, pueden presentarse normalmente entre 4 y 6 ciclos de sueño REM (Carrillo, Ramírez, and Magaña 2013).

2.2.3. Ondas de la señal EEG

La señal EEG puede ser descompuesta en cinco bandas de frecuencia diferentes. Según la profundidad del sueño, unas bandas tendrán más peso en la señal que las otras. En la Tabla 1 se presentan las diferentes bandas y el rango de frecuencia y amplitud asociadas.

Banda	Frecuencia (Hz)	Amplitud (μ V)
Delta (δ)	0-4	20-100
Theta (θ)	4-8	10
Alfa (α)	8-13	2-100
Beta (β)	13-22	5-10

Tabla 1. Diferentes bandas de frecuencia de la señal EEG

Además de estas cinco bandas, en la señal EEG también pueden aparecer los fenómenos llamados *sleep spindles* (huso del sueño) y complejos-k. Los *spindles* son ráfagas cortas, con una duración entre 0.5 y 2 s, a una frecuencia en la banda sigma (entre 10 y 15 Hz). Aparecen en la fase N2 del sueño. Los complejos-k se definen como ondas de tiempo corto que empiezan con una desviación negativa seguida por un valor positivo (Ebrahimi et al. 2008). Tienen lugar también en la fase N2.

Estas ondas pueden ser útiles a la hora de clasificar la señal en las diferentes fases del sueño. Durante la fase REM pueden apreciarse las siguientes características: amplitud de la señal EEG baja, frecuencia de señal EEG mixta (principalmente ondas beta, según (Güneş, Polat, and Yosunkaya 2010), amplitud baja de señal EMG y nivel alto de señales EOG. Durante la fase N1, aparecen ondas alfa (Şen et al. 2014) y theta principalmente (Ebrahimi et al. 2008). Durante la fase N2, como ya se ha dicho, se pueden observar complejos-k y *sleep spindles*. Por último, en la fase N3, se observa una frecuencia de señal baja (<2Hz), así como también *sleep spindles* y complejos-k (Fraiwan et al. 2012). Las ondas alfa aparecen en la vigilia (fase AW) (Huang et al. 2014; Rokach and Maimon 2007).

2.2.4. Características que se han extraído y clasificadores usados

Existe mucha literatura en la que se han propuesto diferentes características extraídas de señales EEG, a partir de diferentes configuraciones de canales (de uno o más de un canal). Las características pueden ser en el dominio temporal, en el dominio temporal-frecuencial o en el dominio frecuencial. A continuación, se citarán los estudios en los que se basa el estudio para extraer las características.

En los estudios de (Aboalayon et al. 2016; Hassan, Bashar, and Bhuiyan 2015), se proponen las características estadísticas estándares, obteniendo, junto con características espectrales, una exactitud del 86,53% en el segundo artículo citado. Según (Koley and Dey 2012), la varianza es adecuada para discriminar la fase REM de las fases N2 y N3. (Rodríguez-Sotelo et al. 2014) compararon diferentes estimadores de entropía, entre otros. Obtuvieron un promedio del 80% de clases clasificadas correctamente. La característica *Zero Crossing* fue utilizada en los estudios de (Shuyuan et al. 2015), obteniendo una exactitud del 75%.

A parte de estas, muchas otras características se han extraído en otras investigaciones. Algunas de ellas se comentarán en el capítulo de 3.2.Extracción de características y en el capítulo 5.Discusión.

En cuanto a los clasificadores, se han aplicado muchos algoritmos diferentes en función de los datos y las características. Un clasificador comúnmente aplicado son los DT (árboles de decisión o *decision trees* inglés), aplicados por (Lan et al. 2015), obteniendo una exactitud alta (>84%) y por (Liang, Kuo, Hu, and Cheng 2012), obteniendo un acuerdo global (*overall agreement*) de 86.68%. Otro clasificador es el llamado K-vecinos más cercanos (KNN) usado en (Phan et al. 2013), obteniendo una exactitud de 94.49 % en la clasificación de 4 clases. Por último, hay que mencionar el clasificador SVM (Máquinas de Vector de Soporte), aplicado en (Radha et al. 2014), obteniendo una exactitud de un 98,01% distinguiendo la fases vigilia y somnolencia. Aparte de estos, existen otros algoritmos de clasificación, algunos más sofisticados. En el artículo de (Aboalayon et al. 2016) se ofrece una tabla resumen de muchos otros estudios y estos se separan según los diferentes clasificadores usados.

2.2.5. Hipnograma

El hipnograma es la representación de las diferentes fases del sueño en función del tiempo. Se puede obtener a partir de la clasificación manual de los expertos del sueño o de manera automática.

En el Gráfico 1 se muestra un ejemplo de un hipnograma para un sujeto que ha dormido 8 horas. En el eje de abscisas se representa el tiempo (8 horas de sueño) y el eje de ordenadas corresponde a las diferentes fases: AW, REM, N1, N2 y N3. Se puede observar cómo, a lo largo del tiempo, el sujeto (en este caso es el sujeto 1) va pasando por las diferentes etapas del sueño, realizando diferentes ciclos.




Gráfico 1. Hipnograma correspondiente al sujeto 1

En el estudio actual, la representación del hipnograma se obtendrá a partir de un código en MATLAB® que se explicará en el capítulo 3.5. Extracción del hipnograma de cada sujeto.

3. Metodología

3.1. Datos experimentales

Para llevar a cabo la investigación, se dispone de señales PSG de cuatro sujetos sanos, proporcionadas por el hospital Sant Pau (Barcelona), y de sus respectivos hipnogramas obtenidos de la clasificación manual de los expertos. Los pacientes han pasado dos noches en el hospital: la primera para adaptarse y la segunda para grabar las señales.

A cada sujeto le corresponden 21 señales diferentes correspondientes a 21 canales: 2 EOG y 19 EEG (en el anexo se detallan estos canales). La frecuencia de muestreo de cada señal es de 256 Hz. Mediante el lenguaje propio de MATLAB®, se ha desarrollado un código para procesar las señales y extraer las características. Las señales se han obtenido como una matriz de 7372800 filas y 19 columnas, donde las filas corresponden al tiempo que dura la señal (8 horas). Por lo tanto, el número de 7372800 muestras resulta del siguiente cálculo:

$$8h * 60min * 60s * 256muestras/s = 7372800 \text{ muestras}$$

Por otra parte, las columnas representan los 19 canales EEG, ya que las señales EOG no interesan en este estudio.

Para calcular las características de las señales de 8 horas de sueño, se han dividido las señales de todos los canales a estudiar en ventanas de 5 segundos. Con ello, la señal ha quedado dividida en 5760 segmentos, a los que se llamarán épocas. Para cada época, y para cada canal se han calculado las características seleccionadas. Debido a que la frecuencia de todas las señales es de 256 Hz, cada época contendrá 1280 muestras.

De cada sujeto se conocen las fases del sueño, clasificadas por expertos del hospital a partir de las señales PSG grabadas, con las cuales se genera el hipnograma. En este estudio se utilizará el hipnograma para validar los resultados obtenidos, aplicando algoritmos de aprendizaje supervisado.

3.2. Extracción de características

En numerosos estudios se han seleccionado características del dominio temporal, frecuencial o temporal-frecuencial. En este estudio se han aplicado características lineales y no lineales.

Las características calculadas en cada época son las siguientes:

- Características estadísticas: media aritmética, varianza, sesgo y curtosis
- Características de potencia: *Slow Wave Activity (SWA)* y Valor eficaz
- Características no lineales: *Sample Entropy (SE)* y *Zero Crossing (ZC)*

En el Anexo 1 se adjunta la parte del código principal para el cálculo de las características.

3.2.1. Características estadísticas

A partir del estudio de (Hassan, Bashar, and Bhuiyan 2015), se han añadido las siguientes características estadísticas: media aritmética, varianza, curtosis y sesgo como posibles predictores. Estas características permiten clasificar la señal según su amplitud y duración.

Media aritmética

La primera característica es la media, que informa sobre la tendencia general de la señal en cada muestra. Para calcular la media de N datos de una variable X, se puede aplicar la expresión de la Ecuación 1.

$$\bar{X} = \frac{\sum X_i}{N} \quad (1)$$

En MATLAB®, se ha calculado la media con el comando *mean()*.

Varianza

La varianza es una medida de dispersión que se calcula como el promedio de las distancias al cuadrado desde los valores en X hasta la media en una muestra de N sujetos. Se puede calcular mediante la Ecuación 2.

$$\sigma_n^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \bar{X})^2 \quad (2)$$

Donde n es el número de muestras y \bar{X} es la media aritmética.

En MATLAB®, se ha llamado a la función *var()* para calcular esta característica.

Sesgo

El sesgo es una medida de asimetría que indica el nivel en que los datos se reparten por encima y por debajo de la tendencia central. Si el sesgo es negativo, los datos se encuentran a la izquierda de la media. Si es positivo, la forma de la gráfica se reparte hacia la parte derecha de la media. En MATLAB® se ha calculado llamando la función *skewness()*. El sesgo (s) se calcula con la Ecuación 3.

$$s = \frac{E(x - \mu)^3}{\sigma^3} \quad (3)$$

donde μ es la media de x , σ es la desviación típica y $E(t)$ es el valor esperado de la cantidad t .

Curtosis

La curtosis es una medida del grado de apuntamiento de una distribución en un conjunto de datos. Del mismo modo que el sesgo, la curtosis (k) describe la forma de la distribución de probabilidad. Se calcula mediante la Ecuación 4 y en MATLAB® se ha calculado con la función *kurtosis()*.

$$k = \frac{E(X - \mu)^4}{\sigma^4} \quad (4)$$

De nuevo, μ es la media aritmética de la variable X , σ es la desviación típica y $E(X)$ es el valor esperado de X .

3.2.2. Características de potencia

SWA

Por último, para distinguir el sueño profundo, se añadirá la característica conocida como potencia o SWA (*Slow Wave Activity*).

Se define como la potencia en la banda delta (0.5-4 Hz) de la señal EEG y se considera como el mejor indicador de la intensidad de sueño profundo. (Terzano et al. 2001).

Para calcular esta característica, se ha obtenido primero el espectro de la señal mediante el periodograma modificado de Welch y, a continuación, se ha calculado la potencia en la banda de 0.15 a 4 Hz, con el comando *bandpower()* de MATLAB®.

Valor eficaz

Debido a que la señal tiene valores positivos y negativos, la media aritmética puede tener valores muy próximos al cero. Por lo tanto, se añade como característica el valor eficaz, denominado en inglés RMS (*root mean square*). Se define como el valor cuadrático medio de una magnitud eléctrica. En el caso actual, se ha calculado el valor eficaz de manera discreta, para cada época de la señal, de la expresión de la Ecuación 5.

$$\text{Valor eficaz} = \sqrt{\text{media}(\text{datos}^2)} \quad (5)$$

3.2.3. Características no lineales

Sample Entropy

Sample Entropy (SE) es una modificación de *Approximate entropy* (ApEn), usada para evaluar la complejidad de una serie temporal fisiológica (Richman and Moorman 2000).

SE tiene dos ventajas respecto a ApEn: es independiente de la dimensión de los datos y se puede implementar evitando el caso de $\log(0)$, calculando el logaritmo al final.

Se define de la siguiente manera (Sundar et al. 2015):

$$\text{SampEn}(m, r) = \lim_{N \rightarrow \infty} [\ln(\phi^m(r) - \phi^{m+1}(r))] \quad (6)$$

donde r es la tolerancia y, m , la dimensión (*embedded dimension*). En el estudio actual se han tomado los siguientes valores: $r = 0.1$ y $m = 3$.

Zero crossing

La característica *Zero Crossing* (ZC) informa del número de veces que la señal cambia de valor positivo a negativo en cada época.

En MATLAB® se calcula el ZC utilizando el Objeto de Sistema `dsp.ZeroCrossingDetector`; un algoritmo proporcionado por el *toolbox* Digital Signal Processing (DSP System Toolbox™).

3.3. Representación de características

En el Gráfico 2 y Gráfico 3 se representan las 8 características mencionadas en función del tiempo para 3 canales: Fz, Pz, Cz (la selección de canales se describirá en otro capítulo).

Para graficar varios gráficos en una misma ventana, se ha llamado a la función *subplot* de MATLAB®.

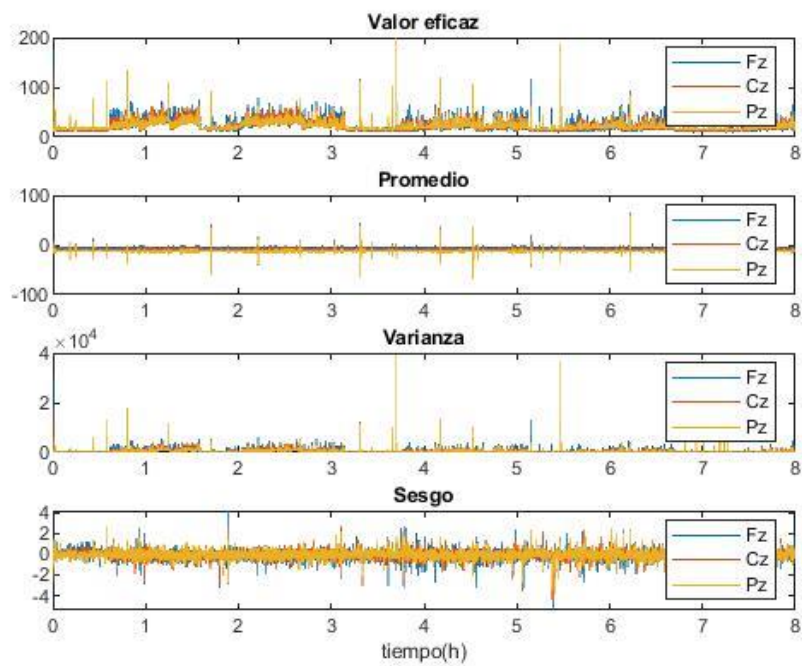


Gráfico 2. Representación de características para el sujeto 1 y 3 canales (Fz, Cz y Pz)

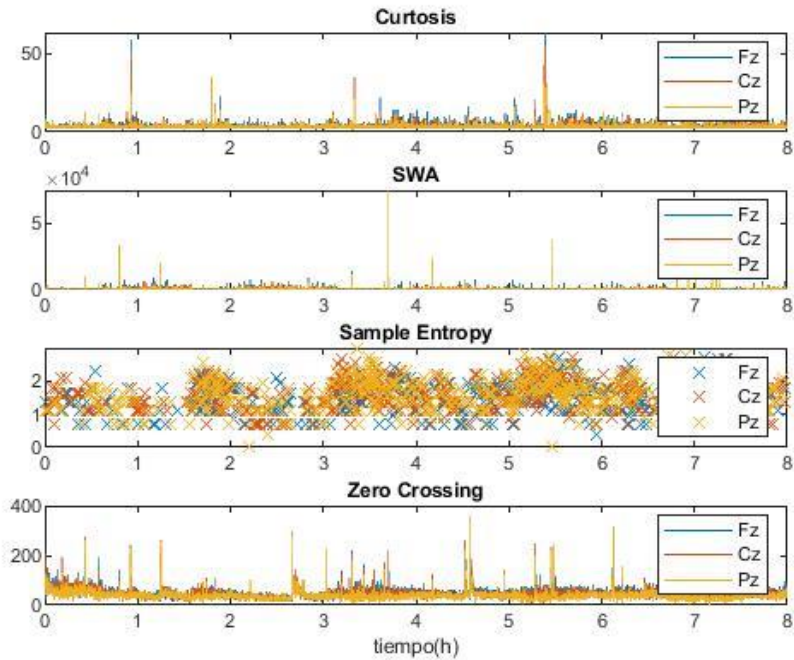


Gráfico 3. Representación de características para el sujeto 1 y 3 canales (Fz, Cz y Pz)

3.4. Mejora de las características

Los gráficos anteriores permiten observar qué forma tienen las características extraídas de la señal y, por lo tanto, poder introducir mejoras.

3.4.1. Interpolación de los datos

Como se muestra en el Gráfico 3, la característica de *Sample Entropy* (SE), la cual se ha representado mediante aspas ("X") tiene algunos instantes de tiempo sin valor. Para resolverlo se ha realizado una interpolación de la señal (código en el anexo). En el Gráfico 4 se puede observar que ya no hay instantes de tiempo sin valor de señal.

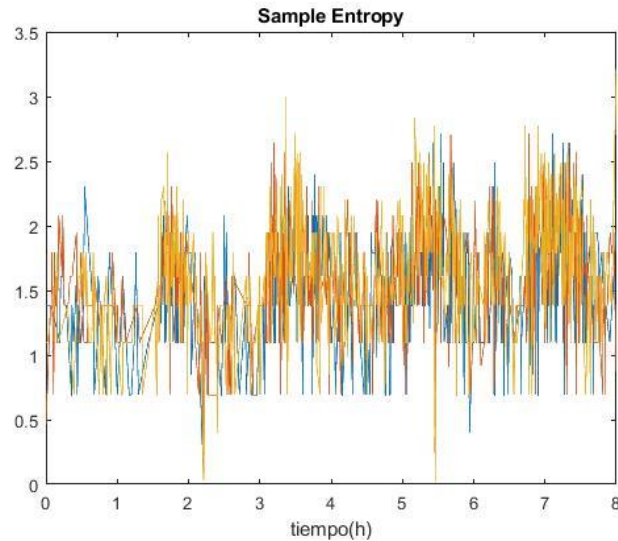


Gráfico 4. Representación de SE después de hacer la interpolación

3.4.2. Media móvil

Por otra parte, algunas de las características tienen valores muy altos en instantes de tiempo puntuales. Esto provoca que el resto de señal con valores inferiores no tengan tanto peso en la predicción. Por lo tanto, se ha aplicado una media móvil de 10 datos en todas las características, de manera que estos picos no eclipsen el valor de los demás puntos.

Este procesamiento se ha calculado mediante un algoritmo que sigue la siguiente estructura para cada época:

L = longitud de los datos

N = número de datos con los que se hace la media móvil

N2 = redondeo al entero más cercano de (N/2)

Se abre un bucle para todos los valores de "i" entre 1 y L. Dentro del bucle:

indices = vector desde el máximo (1, i-N2) hasta el mínimo de (L, i+N2).

se calcula la media aritmética para todos los valores de *indices*.

En este caso, con N=10, la media aritmética se va calculando con un dato y sus 10 siguientes datos. Es decir, para el primer dato, se calcula la media con los siguientes 10 datos, para el segundo dato, lo mismo, y así sucesivamente.

En el Gráfico 5 y Gráfico 6, se muestra la mejora de la señal con la media móvil aplicada, de manera que esta ya no presenta valores puntuales tan altos como anteriormente y se puede apreciar mejor la tendencia de la señal a lo largo del tiempo.

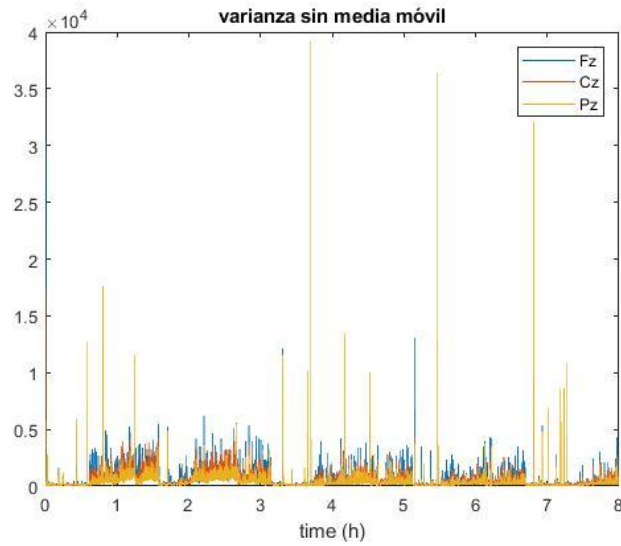


Gráfico 5. Representación de la varianza en función del tiempo sin haber aplicado la media móvil

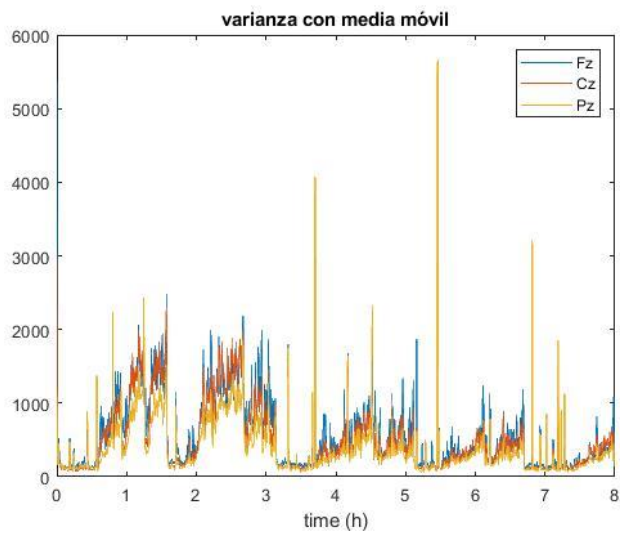


Gráfico 6. Representación de la varianza en función del tiempo con la media móvil aplicada

3.4.3. Normalización de las variables

Por último, para que todas las características tengan el mismo peso en la predicción, se han normalizado las variables. Se ha realizado el cálculo de la Ecuación 7 para cada variable X y para cada canal.

$$X_{\text{normalizada}} = \frac{X - \mu}{\sigma}, \quad (7)$$

donde μ es la media de la variable X y σ es la desviación estándar de este conjunto de datos.

En el Gráfico 7 puede verse el efecto de normalizar la característica varianza (característica que ya se ha mostrado en los anteriores gráficos):

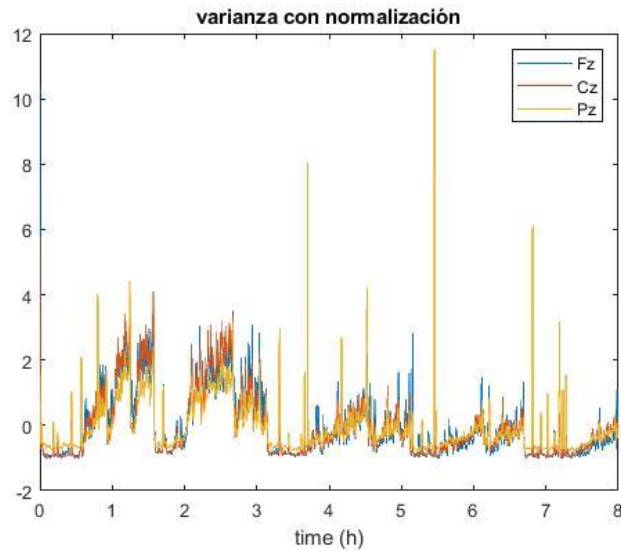


Gráfico 7. Representación de la varianza en función del tiempo una vez normalizada la variable

3.5. Extracción del hipnograma para cada sujeto

De cada sujeto se dispone de un hipnograma con las fases que han clasificado los expertos del sueño. Cada hipnograma se representa con un vector de longitud 5754, que corresponde a 5754 épocas de 5 segundos. Inicialmente, este hipnograma contiene valores del 1 al 9, representando las diferentes fases del sueño. Mediante un algoritmo de MATLAB®, se transforman las 9 fases a 5 fases, según la siguiente numeración:

2 = N3

3 = N2

4 = N1

5 = REM

6 = AW

El algoritmo funciona de la siguiente manera: cuando en el hipnograma de los expertos hay un 4, se convierte en un 2. Si hay un 3, se convierte en un 2 también. Va haciendo lo mismo con cada valor. Excepto cuando en el hipnograma inicial hay un 8. Entonces, el nuevo hipnograma coge los valores precedentes a este.

Para la extracción de características de la señal, esta se ha segmentado también en épocas de 5 segundos, de manera que cada época se pueda relacionar con una fase del sueño: N1, N2, REM, etc.

3.6. Clasificación

3.6.1. Matriz de características

Una vez extraídas de la señal las características anteriores y aplicada la media móvil y la normalización a todas ellas, se ha creado una matriz de dimensiones 5754 x Y para cada sujeto. El valor 5754 resulta de igualar las filas de características a las del hipnograma (dimensiones 5754 x 1), para poder comprobar los resultados al final (originalmente, cada característica tenía 5760 filas, correspondientes a las 5760 iteraciones). El valor Y, corresponde al producto del número canales por las 8 características extraídas, añadiendo el vector del tiempo en la penúltima columna y el vector hipnograma de las fases del sueño clasificadas manualmente por los expertos del sueño, en la última columna.

Para clasificar, se introducen las columnas correspondientes a las características y a los canales. La última columna sirve para validar los resultados y el vector de tiempo no se aplica como característica, ya que para cada sujeto puede presentar diferentes valores para diferentes fases.

3.6.2. Aprendizaje automático

MATLAB® dispone de la aplicación *Classification Learner*, la cual permite entrenar modelos para clasificar datos usando aprendizaje automático (*machine learning*) supervisado.

El aprendizaje automático es una técnica de análisis de datos donde los ordenadores aprenden de la experiencia. De esta manera, no es necesaria una ecuación predeterminada para clasificar los datos. A medida que aumenta el número de muestras, los algoritmos mejoran su rendimiento.

Para clasificar, el aprendizaje automático puede usar dos técnicas: el aprendizaje supervisado, en el que se dispone de unos datos de entrada y unos de salida para predecir datos futuros, y el aprendizaje no supervisado, el cual busca patrones ocultos detrás de los datos, sin conocer la salida. En este trabajo son utilizadas técnicas de aprendizaje supervisado.

La aplicación de MATLAB® dispone de los siguientes algoritmos de clasificación: árboles de decisión, análisis discriminante, Máquinas de vectores soporte (SVM), regresión logística, vecinos más cercanos y conjunto de clasificadores. A continuación, se detallan los modelos que han dado mayores resultados de manera más rápida en este estudio, que son los árboles de clasificación y los k-vecinos más cercanos (Liang, Kuo, Hu, and Cheng 2012; Phan et al. 2013).

3.6.3. Métodos de clasificación

Arboles de decisión (Decision Trees, DT)

Este algoritmo se encuentra dentro del conjunto *Decision trees* (árboles de clasificación). Es un paradigma que se basa en el particionamiento recursivo de los datos.

Según (Rokach and Maimon 2007), un árbol de decisión es un modelo jerárquico de toma de decisiones y sus consecuencias. Es un modelo de partición recursiva de las muestras según cumplan una condición u otra. La clasificación de los datos es en base a un conjunto de clases predefinido.

El árbol de decisión está compuesto de nodos y aristas, que unen los diferentes nodos. Para clasificar, empieza por el nodo denominado "nodo raíz", el cual no tiene aristas que lleguen a él. Los nodos que tienen aristas que salen de ellos, se llaman nodos internos y los que no tienen salidas de arista son los nodos de decisión o finales, los cuales pertenecen cada uno a una clase predefinida. En los nodos raíz e internos, hay que tomar siempre una decisión para escoger una arista saliente u otra e ir a otro nodo.

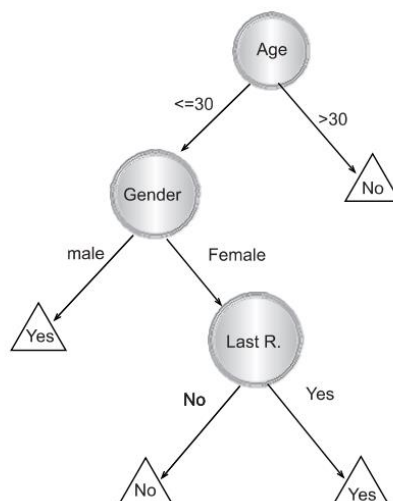


Figura 2. Ejemplo de árbol de decisión (Rokach and Maimon 2007)

El árbol de decisión aplicado en la clasificación de las fases del sueño ha sido *Fine Tree* (árbol fino), con una flexibilidad alta y posibilidad de hacer muchas distinciones entre las clases (como máximo 100 divisiones).

K - Vecinos Más Cercanos (k - Nearest neighbors, KNN)

K-Vecinos más cercanos es un método de clasificación no paramétrico que distribuye, en un espacio, los datos según la probabilidad de que un dato pertenezca a una clase. En función de la distancia entre la clase a predecir y las clases definidas y en función del valor de k (número de vecinos), el método atribuye una clase determinada al dato en cuestión.

En general, se emplea la distancia euclidiana para calcular lo cerca que está el dato objetivo de los demás datos. A medida que k aumenta, se observan más vecinos, y se atribuye al dato la clase que corresponde al mayor número de vecinos observados (Güneş, Polat, and Yosunkaya 2010).

En este estudio, se aplicará el modelo *Fine KNN*, de MATLAB®, el cual presenta una distinción entre las fases fina y un número de vecinos k=1. La distancia métrica entre las clases es la euclidiana y para el peso de la distancia se ha seleccionado *Equal* (sin peso).

3.7. Validación de los resultados

Después de extraer las características y predecir las fases del sueño para un sujeto, estas se han comparado con las fases que los expertos del sueño han clasificado manualmente. Para evaluar cada clase, se emplearán los conceptos relacionados con la matriz de confusión.

3.7.1. Matriz de confusión

La matriz de confusión es una matriz en la que las filas corresponden a las clases según la detección automática y, las columnas, a las clases que han detectado los expertos del sueño manualmente. A partir de esta matriz, para determinar la conducta de los diferentes clasificadores se pueden calcular la exactitud, la sensibilidad, la especificidad, la precisión y F1_score, aplicando las Ecuaciones 8, 9, 10 y 11.

$$\text{Exactitud (accuracy)} = \frac{TP + TN}{TP + FP + TN + FN} ; \quad (8)$$

$$\text{Sensibilidad} = \frac{TP}{TP + FN} ; \quad (9)$$

$$\text{Precisión} = \frac{TP}{TP + FP} ; \quad (10)$$

$$\text{F1 score} = \frac{2 * TP}{2 * TP + FP + FN} ; \quad (11)$$

Donde TP, que significa verdadero positivo (en inglés, *True Positive*), indica aquellas clases detectadas automáticamente que coinciden con la detección de los expertos. TN simboliza verdadero negativo (*True Negative* en inglés) y se define como la clase que no ha sido detectada ni automáticamente ni por los expertos del sueño. FN son los falsos negativos (en inglés *False Negative*) y representan las clases que no se han detectado automáticamente como según los expertos del sueño han indicado que son. Finalmente, se definen como FP (Falso positivo, *False Positive* en inglés) aquellas clases detectadas automáticamente que en realidad no lo son.

En la Tabla 2 se muestra un ejemplo de una matriz de confusión con sus valores de TP, FN, TN y FP para la clase llamada A.

		Detección automática	
		Clase A	No clase A
Detección manual de los expertos del sueño	Clase A	TP	FP
	No clase A	FN	TN

Tabla 2. Ejemplo de matriz de confusión para una clase A. TP = verdadero positivo, TN = verdadero negativo, FP = falso positivo y FN = falso negativo. Las casillas que están en verde representan los valores acertados. Las otras son errores de predicción.

Para cada clasificación, se obtendrá una matriz de confusión y, para cada fase del sueño (clase), se calcularán la sensibilidad, la especificidad y *F1 score*, que se define como la media armónica de la precisión y la sensibilidad.

3.7.2. Estructura de validación de resultados

Para validar los cálculos anteriores, se seguirá el siguiente orden:

1. Selección del mejor clasificador a partir de todos los sujetos y todas las configuraciones propuestas de canales.
2. Selección de la mejor configuración de canales con el mejor clasificador y todos los sujetos.
3. Selección de la mejor configuración de características con la mejor configuración de canales y todos los sujetos.
4. Predicción de un sujeto a partir del entrenamiento de 3 sujetos.

El método de clasificación será, para los puntos 1, 2 y 3, un 75% de *training* y un 25% de *test* para cada sujeto. Para el punto 4, se entrenará el clasificador con 3 sujetos y se predecirá el cuarto sujeto.

Para la selección de la mejor configuración de canales, con el fin de reducir las dimensiones de las matrices para hacer los cálculos, se han planteado las siguientes configuraciones de canales en base a otras investigaciones ya realizadas:

- Configuración 1: 6 canales: F3, F4, C3, C4, P3, P4
- Configuración 2: 9 canales: F3, Fz, F4, C3, Cz, C4, P3, Pz, P4
- Configuración 3: 3 canales: Fz, Cz, Pz
- Configuración 4: 2 canales: Fp1, Fp2
- Configuración 5: 1 canal: Fz
- Configuración 6: 1 canal: Cz

En cuanto a la selección de características, se probarán diferentes conjuntos a partir de la matriz perteneciente a la configuración de canales seleccionada previamente. Cada conjunto será aplicado a cada sujeto y, seguidamente, se calculará la media y la desviación estándar de los resultados de *F1 score* para cada fase del sueño. Los conjuntos de características son los siguientes:

1. Todas las características sin el valor eficaz
2. Todas sin la característica promedio
3. Todas sin la característica varianza
4. Todas sin la característica sesgo
5. Todas sin la característica curtosis
6. Todas sin la característica SWA
7. Todas sin la característica SE
8. Todas sin la característica ZC

A partir de los resultados que se obtengan, se estudiará qué característica, al ser eliminada, no hace empeorar el resultado más que un 0.5%, y se procederá a sacar la característica como predictor.

Finalmente, con los predictores que no se han eliminado, se clasificarán todas las fases de un sujeto a partir del clasificador entrenado con los otros tres sujetos y utilizando el sujeto dejado afuera para evaluar el rendimiento del modelo resultante (técnica Leaving-One-Out). También se hará para cada sujeto y se mostrarán la media y la desviación estándar.

4. Resultados

4.1. Selección de canales

Para los 4 sujetos, probando *Fine KNN* y *Fine Tree*, se obtienen los valores de la Tabla 3 de exactitud (*accuracy*), sensibilidad, precisión y *F1 score* para cada configuración de canales.

		Clasificador							
		<i>Fine Tree</i>				<i>Fine KNN</i>			
		E	S	P	F	E	S	P	F
Conf. 1	μ	89,53%	82,99%	85,56%	84,04%	96,05%	93,15%	93,44%	93,23%
	σ	1,81%	17,18%	13,33%	15,52%	1,01%	7,50%	6,20%	6,98%
Conf. 2	μ	90,35%	84,32%	85,48%	84,63%	96,43%	94,25%	93,65%	93,93%
	σ	2,15%	15,06%	13,21%	14,66%	0,72%	6,16%	7,11%	6,66%
Conf. 3	μ	88,35%	81,69%	82,97%	82,15%	94,80%	92,47%	92,14%	92,29%
	σ	3,32%	17,68%	16,64%	17,27%	1,27%	6,77%	7,44%	7,10%
Conf. 4	μ	82,80%	74,91%	79,31%	76,43%	91,85%	87,78%	87,80%	87,70%
	σ	3,62%	21,52%	15,41%	19,00%	2,50%	12,63%	10,96%	11,86%
Conf. 5	μ	83,25%	74,61%	79,77%	75,66%	86,50%	83,32%	83,88%	83,56%
	σ	4,66%	26,74%	12,21%	22,26%	6,16%	15,32%	12,33%	13,86%
Conf. 6	μ	84,43%	75,24%	79,66%	76,43%	88,93%	84,64%	85,22%	84,84%
	σ	2,04%	24,79%	16,60%	22,00%	2,16%	14,02%	11,32%	12,80%

Tabla 3. Valores de exactitud del clasificador (E), sensibilidad (S), precisión (P) y F1 score (F) para diferentes configuraciones de canales y diferentes clasificadores. "Conf." se refiere a configuración. μ es la media aritmética y σ la desviación estándar.

En la Tabla 3 se muestran los resultados de exactitud (E), sensibilidad (S), precisión (P) y F1 score (F) para los dos clasificadores ensayados, presentándolos con la media (μ) y la desviación estándar (σ) de los cuatro sujetos. Como se puede observar, el clasificador *Fine KNN* tiene mayores resultados en todas las configuraciones (el mejor resultado es para la configuración

3). Por lo tanto, se selecciona como clasificador el *Fine KNN*. Los próximos resultados se calcularán únicamente con este clasificador.

Una vez seleccionado el clasificador, se seleccionará la mejor configuración de canales. En la Tabla 4 se muestran los resultados de F1 score para cada fase (clase) del sueño a partir de los datos de 4 sujetos.

F1 score							
Clase	Conf. 1	Conf. 2	Conf. 3	Conf. 4	Conf. 5	Conf. 6	
N3	97,51%	97,92%	96,69%	95,56%	92,31%	91,70%	μ
	0,18%	0,46%	0,53%	1,14%	1,38%	0,82%	σ
N2	96,20%	96,95%	94,97%	92,04%	87,56%	88,67%	μ
	1,36%	0,40%	0,84%	2,10%	3,71%	3,35%	σ
N1	80,97%	82,08%	79,66%	66,78%	59,09%	62,22%	μ
	4,58%	3,75%	6,41%	9,97%	5,90%	9,31%	σ
REM	97,30%	96,83%	95,42%	90,31%	87,37%	88,48%	μ
	1,99%	1,81%	2,05%	5,18%	8,18%	5,16%	σ
AW	94,17%	95,86%	94,69%	93,79%	91,45%	93,12%	μ
	3,03%	2,08%	2,78%	5,26%	2,04%	2,42%	σ
Media	93,23%	93,93%	92,29%	87,70%	83,56%	84,84%	
Desv. estándar	6,24%	5,96%	6,35%	10,60%	12,39%	11,45%	

Tabla 4. Resultados de F1 score para las diferentes configuraciones a partir de 4 sujetos. Conf. hace referencia a "configuración". μ y σ son el promedio y la desviación estándar, respectivamente, para todos los sujetos

Como se puede observar en la Tabla 4, la mejor configuración de canales es la 2, compuesta por 9 canales, con una media aritmética para todas las clases de F1 score de 93,93%. En la siguiente sección, por tanto, se estudiará la mejor configuración de características con esta configuración.

4.2. Selección de características

Con la configuración 2 (9 canales), se estudiarán las diferentes configuraciones de características descritas en el Capítulo 3.6.2.

		<i>F1 score</i> [%]									
Configuración de CARACTERÍSTICAS	Clase	N3		N2		N1		REM		AW	
		μ	σ	μ	σ	μ	σ	μ	σ	μ	σ
	1	97,89	0,48	96,59	0,32	85,09	4,85	97,72	2,06	94,60	2,24
2	98,37	0,71	97,39	0,76	86,97	3,70	98,27	1,70	94,60	3,33	
3	97,73	0,29	96,51	0,52	84,17	5,82	97,71	2,27	94,59	2,23	
4	97,46	0,39	96,55	0,80	81,02	4,36	97,44	1,78	94,21	2,09	
5	97,33	0,54	96,15	0,55	83,60	3,34	97,34	2,04	94,78	2,60	
6	97,79	0,27	96,48	0,48	83,53	6,90	97,94	2,14	93,98	2,81	
7	96,27	0,55	94,66	1,02	80,61	3,24	96,56	2,31	94,15	2,90	
8	97,48	0,54	96,09	0,68	82,86	6,15	97,52	2,57	93,45	1,92	

Tabla 5. Resultados para cada clase y para cada configuración de características. μ y σ son el promedio y la desviación estándar, respectivamente, para todos los sujetos

Configuración de características	Clase				
	N3	N2	N1	REM	AW
1	-0.03%	-0.36%	3.01%	0.89%	-1.26%
2	0.45%	0.44%	4.89%	1.44%	-1.26%
3	-0.19%	-0.44%	2.09%	0.88%	-1.27%
4	-0.46%	-0.40%	-1.06%	0.61%	-1.65%
5	-0.59%	-0.80%	1.52%	0.51%	-1.08%
6	-0.13%	-0.47%	1.45%	1.11%	-1.88%
7	-1.65%	-2.29%	-1.47%	-0.27%	-1.71%
8	-0.44%	-0.86%	0.78%	0.69%	-2.41%

Tabla 6. Diferencia resultados entre Tabla 5 y Tabla 4 (Tabla 5 – Tabla 4). Las configuraciones de características se explican en el Capítulo 3.7.2.

En la Tabla 5 las columnas corresponden a la media (μ) y desviación estándar (σ) del *F1 score* de los cuatro sujetos. Las diferentes configuraciones de características se representan con un número, siguiendo la numeración detallada en el apartado 3.6.2. Se puede observar que, el hecho de eliminar una característica no hace disminuir considerablemente los resultados. En la Tabla 6 se muestra la diferencia de resultados de la Tabla 5 respecto la Tabla 4, en la que los resultados son con todas las características. Para el caso 2 (todas las variables sin el promedio), además, se puede ver que la media aumenta en las clases: N3, N2, N1 y REM (la diferencia es positiva, lo cual indica una mejora en la predicción). En el siguiente apartado, por lo tanto, se eliminará el promedio como predictor.

4.3. Predicción de las fases del sueño dejando un sujeto afuera

Una vez seleccionados la configuración de canales y de características, se predecirán el 100% de las fases de un sujeto.

Cada sujeto se ha predicho a partir de los 3 sujetos restantes y para cada uno MATLAB® proporciona medidas de exactitud, sensibilidad, precisión y *F1 Score* sobre los valores de todas las clases. Calculando el promedio y la desviación estándar de todos los sujetos, se han obtenido los valores de la Tabla 7.

	Media	Desv. estándar
Exactitud del clasificador (25% Holdout)	97,43%	0,36%
Exactitud	64,60%	4,08%
Sensibilidad	51,43%	4,21%
Precisión	56,65%	4,89%
F1 score	51,41%	4,56%

Tabla 7. Resultados de entrenar con 3 sujetos y predecir el cuarto con la configuración de 9 canales y 7 características

Como se puede observar en la Tabla 7, el F1 score sobre todos los valores ha disminuido respecto a los valores anteriores de F1 score.

Para estudiar cómo han sido detectadas las diferentes clases, en la Tabla 8 se muestra la matriz de confusión de la predicción del sujeto 4 a partir de los datos de los sujetos 1, 2 y 3. En la Tabla 9, se detallan las épocas que hay en total para cada fase del sueño.

	Predicción clase N3	Predicción clase N2	Predicción clase N1	Predicción clase REM	Predicción clase AW
Clase actual N3	86.43%	11.86%	0.34%	0.00%	1.37%
Clase actual N2	19.02%	72.77%	1.48%	3.35%	3.39%
Clase actual N1	6.62%	55.34%	9.40%	17.74%	10.90%
Clase actual REM	0.83%	53.98%	3.68%	40.99%	0.53%
Clase actual AW	37.59%	16.31%	7.45%	1.42%	37.23%

Tabla 8. Matriz de confusión de la predicción del sujeto 4. Los valores en formato negrita son los correspondientes a verdaderos positivos

Clase	Actual	Predicción
N3	1164	1006
N2	2508	1825
N1	468	44
REM	1332	546
AW	282	105

Tabla 9. Número de épocas para cada clase del sujeto 4. Actual se refiere a las clases detectadas manualmente por los expertos del sueño. Predicción hace referencia a la que se han clasificado automáticamente

5. Discusión

En este trabajo se ha propuesto un nuevo método de detección automática de las fases del sueño mediante características del dominio temporal y frecuencial a partir de señales EEG. Se trata de un método de clasificación sencillo y, a la vez, que ofrece buenos resultados.

En muchas de las investigaciones que existen en este campo, los resultados se obtienen habiendo dividido la señal en dos grupos de manera aleatoria: uno para entrenar (70-75%) y se predice el 20-25% restante. En este estudio, se han procurado predecir todas las fases del sueño de un sujeto (el 100%), de manera que sea útil para la aplicación médica.

Para llevar a cabo el desarrollo del detector, primero ha habido una fase de familiarización con las señales EEG y con el programa informático MATLAB® y sus aplicaciones. A continuación, se ha empezado por extraer características estadísticas de la señal. Poco a poco, a base de ir leyendo otras investigaciones y de ir obteniendo diferentes resultados, se han ido añadiendo características y mejoras y se han ido estudiando diferentes clasificadores y diversas configuraciones de canales. Finalmente, se han presentado los resultados, los cuales se comentan a continuación.

En primer lugar, los resultados de la selección de configuración de canales (Tabla 3) han sido como se podían esperar, ya que, cuantos más canales, se tienen más datos para clasificar y el clasificador rinde mejor. Por otro lado, se ha podido ver que configuraciones con menos canales (6 canales y 3 canales) no dan resultados muy inferiores y se podrían proponer para futuras investigaciones.

En segundo lugar, al estudiar la importancia de cada característica en la detección mediante el método de ir sacando una característica en cada iteración, se observa en la Tabla 5 que los resultados no empeoran mucho e incluso algunos mejoran. Con la característica SE eliminada es cuando la diferencia es mayor: un -2.29% como máximo. Por lo tanto, se puede decir que SE es muy buen predictor. En el caso del promedio, en cambio, al ser este eliminado, los resultados mejoran en 4 de las 5 clases. Por eso el promedio se pudo descartar como predictor.

En la segunda parte, usando la técnica "dejando uno fuera" (*leaving one out*), el promedio de la exactitud para todos los sujetos es de un 64,60% (previamente únicamente se predecía el 25% de la señal, mientras que ahora, el 100%). Esto es debido a que algunas fases se predicen bien pero otras no tienen un comportamiento tan bueno.

Observando la matriz de confusión de la predicción del sujeto 4 (Tabla 8), se percibe que la clase N1 es la que se ha predicho como clase actual con un porcentaje menor: solo un 9,4% de todas las épocas que eran fase N1 se ha valorado como tal. Más de la mitad de la clase N1 se confunde con la fase N2 (el 55.34%). El 17.74%, con la fase REM, el 10.90% de N1 se confunde con AW y el resto (6.62%) con la clase N3.

Uno de los motivos que podrían explicar que la fase N1 tenga resultados bajos es que el número de épocas en el hipnograma con esta clase es inferior. Por lo tanto, aunque el número de épocas que se han confundido no sea muy elevado, para esta clase cada muestra representa un porcentaje más elevado que en las otras clases. Además, el hecho de que la fase N1 sea una transición entre la vigilia y el sueño, puede hacer que esta se confunda con las fases vecinas.

Otra explicación a los resultados de N1 es que las fases N1 y N2 se caracterizan por tener ondas theta (4-8 Hz) con una amplitud parecida. Por eso es fácil que sean confundibles y, con las características extraídas en el trabajo, es difícil discriminarlas. Una manera de separar estas dos fases fácilmente sería con la detección de *sleep spindles* (12–14 Hz) y complejos-K en la clase N2 (Huang et al. 2014). Para ello, sería interesante aplicar características de potencia espectral (PSD, *Power spectral features*) para detectar estos fenómenos (Acir and Güzeliş 2004).

En tercer lugar, la fases REM y N1 es habitual que se confundan ya que, como se ha dicho, siguen un modelo muy similar: ninguna de las dos tiene una banda de frecuencia única. En la fase REM la señal tiene una frecuencia mixta y, en la N1, ondas alfa y beta. En algunos estudios se ha decidido unificar estas dos fases en una sola (Ebrahimi et al. 2008). Otra alternativa sería aplicar otras características no lineales como el LZC (Lempel-ziv complexity) para distinguir de manera efectiva las clases N1 y REM (Koley and Dey). Por último, para eliminar los efectos de pocos datos de la fase N1, se podría aplicar la Agregación de Bootstrap para generar más datos (Phan et al.; Hassan et al.).

Las fases REM y AW son las dos siguientes con peores resultados: la fase REM se confunde principalmente con N2 y, la fase AW, con N3 y N2. La fase AW contiene ondas alfa y beta y los expertos del sueño la clasifican con la condición de que estas ondas aparezcan más de un 50% en la época (Huang et al. 2014). Según (Koley and Dey 2012), la varianza es adecuada para discriminar la fase REM de las fases N2 y N3, pero se ha visto en este estudio que no es

suficiente. Otra manera de detectar la fase REM podría ser añadiendo las señales EOG, ya que presentan un nivel alto debido al movimiento ocular rápido. No obstante, estas señales están excluidas de este estudio. La fase N3, por su parte, podría ser discriminada mejor de las demás con el algoritmo *Higuchi fractal dimensión (HFD)*, según proponen (Koley and Dey 2012).

Por último, para las fases N2 y N3, la detección se puede considerar buena: se ha detectado el 71,77% y el 86,43%, respectivamente. La fase N3 tiene buenos resultados gracias a la característica extraída *SWA*, que calcula la potencia en la banda delta; muy representativa del sueño profundo. Para la fase N2, uno de los motivos que podría justificar los buenos resultados, es que esta representa el 50% del sueño y, por lo tanto, hay más posibilidades de acertar.

6. Conclusiones y futuras líneas de investigación

En este estudio, se ha hecho una investigación de distintos métodos de clasificación automática y se ha experimentado con alguno de ellos. Seleccionado un conjunto de características, se han podido predecir las fases del sueño mediante aprendizaje automático supervisado y se ha calculado el rendimiento de diferentes clasificadores.

La experimentación se ha realizado con señales EEG de 4 sujetos sanos. Cada señal se ha dividido en épocas y en cada época se han calculado las características. Seguidamente, mediante aprendizaje automático, se han clasificado las fases del sueño y se han podido validar los resultados en función del número de canales en los que se ha hecho la detección y según el número de características. El resultado obtenido, con el clasificador KNN, 9 canales, 7 características y con 3 sujetos de entrenamiento y prediciendo uno, es un clasificador con un *F1 score* 51,41%. Este resultado se puede considerar bueno teniendo en cuenta que se predice el 100% de la señal y que no únicamente hay una característica en el dominio frecuencial (*SWA*). Si se predice el 25% de las fases con los cuatro sujetos (entrenando el 75%), los resultados mejoran mucho: un *F1 score* del 93,93% sobre todas las fases del sueño.

Como futuras línea de investigación, para mejorar los resultados, se propone añadir características del dominio frecuencial como pueden ser la potencia espectral en las diferentes bandas de frecuencia (mencionado en el capítulo 5. Discusión), potencias espectrales relativas o ratios de potencia (Koley and Dey 2012). Añadiendo estas nuevas características, se podrían disminuir el número de canales EEG; por ejemplo, a los tres canales centrales Cz, Pz y Fz o

incluso a un canal (Pz o Fz son los más aplicados). Por último, se podrían probar diferentes medidas de épocas (en el estudio actual las épocas son de 5 segundos). Ampliando la época, se disminuiría el coste computacional.

Por último, otra propuesta para el futuro sería añadir datos de sujetos al estudio, con el fin de adquirir mayor robustez de los resultados. En cuanto al clasificador, se podrían probar más valores de K en el clasificador KNN, así como estudiar la implementación de nuevos clasificadores más sofisticados.

7. Agradecimientos

Me gustaría agradecer principalmente a las co-directoras de este trabajo: Dra. Carolina Migliorelli Falcone y Dra. Leidy Yanet Serna Higueta, por haberme dado la oportunidad de poder investigar en el ámbito tan interesante como es el sueño. Con ellas he aprendido a desenvolverme con MATLAB® fácilmente, su dedicación ha sido constante y me han ofrecido ánimos hasta el último momento

El otro agradecimiento es para mi familia por la mucha paciencia que han tenido y el interés que han mostrado en el proyecto.

8. Bibliografía

- Aboalayon, Khalid Ali I., Miad Faezipour, Wafaa S. Almuhammadi, and Saeid Moslehpour. 2016. "Sleep Stage Classification Using EEG Signal Analysis: A Comprehensive Survey and New Investigation." *Entropy*.
- Acir, Nurettin, and Cüneyt Güzeliş. 2004. "Automatic Recognition of Sleep Spindles in EEG by Using Artificial Neural Networks." *Expert Systems with Applications*.
- Allan Hobson, J. 1969. "A Manual of Standardized Terminology, Techniques and Scoring System for Sleep Stages of Human Subjects." *Electroencephalography and Clinical Neurophysiology*.
- Anderer, Peter, Georg Gruber, Silvia Parapatics, and Georg Dorffner. 2007. "Automatic Sleep Classification According to Rechtschaffen and Kales." In *Annual International Conference of the IEEE Engineering in Medicine and Biology - Proceedings*,.
- Carrillo, P, J Ramírez, and K Magaña. 2013. "Neurología Del Sueño y Su Importancia: Antología Para El Estudiante Universitario." *Division de rehabilitacion neurologica*.
- Ebrahimi, Farideh, Mohammad Mikaeili, Edson Estrada, and Homer Nazeran. 2008. "Automatic Sleep Stage Classification Based on EEG Signals by Using Neural Networks and Wavelet Packet Coefficients." In *2008 30th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*,.
- Fraivan, Luay et al. 2012. "Automated Sleep Stage Identification System Based on Time-Frequency Analysis of a Single EEG Channel and Random Forest Classifier." *Computer Methods and Programs in Biomedicine*.
- Güneş, Salih, Kemal Polat, and Şebnem Yosunkaya. 2010. "Efficient Sleep Stage Recognition System Based on EEG Signal Using K-Means Clustering Based Feature Weighting." *Expert Systems with Applications*.
- Hassan, Ahnaf Rashik, Syed Khairul Bashar, and Mohammed Imamul Hassan Bhuiyan. 2015. "On the Classification of Sleep States by Means of Statistical and Spectral Features from Single Channel Electroencephalogram." In *2015 International Conference on Advances in Computing, Communications and Informatics, ICACCI 2015*,.
- Homan, Richard W., John Herman, and Phillip Purdy. 1987. "Cerebral Location of International 10-20 System Electrode Placement." *Electroencephalography and Clinical Neurophysiology*.
- Huang, Chih Sheng et al. 2014. "Knowledge-Based Identification of Sleep Stages Based on Two Forehead Electroencephalogram Channels." *Frontiers in Neuroscience*.
- Iber, C., S. Ancoli-Israel, A. Chesson, and S. F Quan. 2007. "The AASM Manual for the Scoring of Sleep and Associated Events: Rules, Terminology and Technical Specification." *Journal of Clinical Sleep Medicine*.
- Koley, B., and D. Dey. 2012. "An Ensemble System for Automatic Sleep Stage Classification Using Single Channel EEG Signal." *Computers in Biology and Medicine*.
- Lan, Kun Chan et al. 2015. "Using Off-the-Shelf Lossy Compression for Wireless Home Sleep Staging." *Journal of Neuroscience Methods*.

- Liang, Sheng Fu, Chin En Kuo, Yu Han Hu, Yu Hsiang Pan, et al. 2012. "Automatic Stage Scoring of Single-Channel Sleep EEG by Using Multiscale Entropy and Autoregressive Models." *IEEE Transactions on Instrumentation and Measurement*.
- Liang, Sheng Fu, Chin En Kuo, Yu Han Hu, and Yu Shian Cheng. 2012. "A Rule-Based Automatic Sleep Staging Method." *Journal of Neuroscience Methods*.
- Phan, Huy, Quan Do, The Luan Do, and Duc Lung Vu. 2013. "Metric Learning for Automatic Sleep Stage Classification." In *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBS*.
- Radha, Mustafa, Gary Garcia-Molina, Mannes Poel, and Giulio Tononi. 2014. "Comparison of Feature and Classifier Algorithms for Online Automatic Sleep Staging Based on a Single EEG Signal." In *2014 36th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, EMBC 2014*.
- Richman, Joshua S., and J. Randall Moorman. 2000. "Physiological Time-Series Analysis Using Approximate Entropy and Sample Entropy." *American Journal of Physiology-Heart and Circulatory Physiology*.
- Rodríguez-Sotelo, Jose Luis et al. 2014. "Automatic Sleep Stages Classification Using EEG Entropy Features and Unsupervised Pattern Analysis Techniques." *Entropy*.
- Rokach, Lior, and Oded Maimon. 2007. *Data Mining and Knowledge Discovery Data Mining with Decision Trees: Theory and Applications*.
- Şen, Baha, Musa Peker, Abdullah Çavuşoğlu, and Fatih V. Çelebi. 2014. "A Comparative Study on Classification of Sleep Stage Based on EEG Signals Using Feature Selection and Classification Algorithms." *Journal of Medical Systems*.
- Shuyuan, Xiao et al. 2015. "An Improved K-Means Clustering Algorithm for Sleep Stages Classification." In *2015 54th Annual Conference of the Society of Instrument and Control Engineers of Japan, SICE 2015*.
- Sundar, Aditya et al. 2015. "MATLAB Analysis of EEG Signals for Diagnosis of Epileptic Seizures PROJECT REPORT- BACHELOR ' S THESIS MATLAB ANALYSIS OF EEG SIGNALS." (July).
- Terzano, Mario Giovanni et al. 2001. "Atlas, Rules, and Recording Techniques for the Scoring of Cyclic Alternating Pattern (CAP) in Human Sleep." *Sleep Medicine*.

9. Anexos

Anexo 1. Código desarrollado para la extracción de características

```
warning off

%% Abrir señales

close all
clear all
[dir_datos, dir_result] = config_function();
subject='V05.rec'; %rec: dispositivo: deltamed , .edf:
dispositivo:profusion
dispositivo='deltamed'; %deltamed o profusion
duracion=28800; % Duración en segundos de la señal(28800s = 8h)
epoca=0;% Epoca
[EDF]=abrir_edf([dir_datos filesep 'EDF' filesep subject]);
% Lee la epoca entrada
[senyals, EDF1] = leeredf_DEF(EDF,duracion,epoca,dispositivo);
senyals(:, 1:2) = []; % Remove EOG

%% Tiempo y frecuencia

fs=EDF1.SampleRate(1); %Frecuencia de muestreo de la señal EEG.
time=linspace((epoca*duracion)/3600,((epoca+1)*duracion)/3600,size(sen-
yals,1)); % Vector de tiempo

%% Calculo de características

% rms, mean, variance, skewness, kurtosis, SWA, SE, ZC
ventana = 5
nmuestras=ventana*fs; % Ventanas de 5 segundos (5*256 muestras en cada
ventana)
niter=size(senyals,1)/nmuestras;
zcd = dsp.ZeroCrossingDetector; % Para el ZC

for j=1:size(senyals,2) %Ho fa pels 19 canals

    for i=1:niter % para cada ventana

        rms(i,j)=sqrt(mean(senyals((i-
1)*nmuestras+1:i*nmuestras,j).^2));
        promedio(i,j)=mean(senyals((i-1)*nmuestras+1:i*nmuestras,j));
        varianza(i,j)=var(senyals((i-1)*nmuestras+1:i*nmuestras,j));
        skw(i,j)=skewness(senyals((i-1)*nmuestras+1:i*nmuestras,j));
        kurt(i,j)=kurtosis(senyals((i-1)*nmuestras+1:i*nmuestras,j));
        tiempo_promedio(i)=(time((i-
1)*nmuestras+1)+time(i*nmuestras))/2;

        %Calculo SWA
```

```

    param.longTram = 5*fs; % 5 segundos de tramo
    param.longSolap = 0; % round(param.longTram/4); % 25 de
        solapamiento
    param.fm = fs;
    param.nfft = 1e3;
    param.finestra = 'hanning';
    param.tipus = 'psd';
    [Pxx, freqs, ~] = periodogramaDeWelch(senyals((i-
1)*nmuestras+1:i*nmuestras, j), param); % j es el canal,
segmento es el segmento de la senyal que cogemos
    pot(i,j) = bandpower(Pxx, freqs, [0.15 4], 'psd'); % La banda
es de 0.15 a 4 Hz, con bandpower calculamos su potencia

    %Sample Entropy
    r=0.1;
    m=3;
    sEnt(i,j)= SampEn(m,r,senyals((i-
1)*nmuestras+1:i*nmuestras,j),1);

    %Zero Crossing

    data = senyals((i-1)*nmuestras+1:i*nmuestras,j);
    zc(i,j) = zcd(data);

end
end

%% Interpolació de sample entropy (per treure Inf i NaN)

for i = 1:size(senyals,2)
    sEnt1 = sEnt(:,i);
    sEnt1(isinf(sEnt1)) = NaN;
    idx = find(~isnan(sEnt1)); %agafa els indexs dels que no son NaN
    sEnt1 = sEnt1(idx);
    idxi=1:length(sEnt(:,1));
    sEnt1(:,i) = interp1(idx,sEnt1,idxi,'linear','extrap');
end

%% Hiponograma

load('C:\Users\Carmina\Documents\TFG\ArxiusMatlab\BBDD\Hipnogramas\V01
.mat');
hipnograma = EDF.hipno;
for ep = 1 : length(hipnograma)
    pos = ep;
    if hipnograma(ep) == 4
        hipnograma(ep) = 2; % SWS or N3 (former S4)
    elseif hipnograma(ep) == 3
        hipnograma(ep) = 2; % SWS or N3 (former S3)
    elseif hipnograma(ep) == 2
        hipnograma(ep) = 3; % Light sleep or N2 (S2)
    elseif hipnograma(ep) == 1

```

```

        hipnograma(ep) = 4; % Transition to sleep or N1
elseif hipnograma(ep) == 9
    hipnograma(ep) = 6; % Awake
elseif hipnograma(ep) == 8
    while hipnograma(pos) == 8
        pos = pos-1;
    end
    hipnograma(ep) = hipnograma(pos);
end
end
end

%% Crear matriz de características X

X= [rms,promedio,varianza,skw,kurt,pot,sEntli, zc, tiempo_promedio'];
X = X(1:length(hipnograma),:);
X = [X hipnograma'];

%% Media movil (se aplica sobre la matriz de características)

function senyali=mediamovil(senyal,N)

L=length(senyal);
N2=floor(N/2);
for i=1:L,
    indices=max(1,i-N2):min(L,i+N2);
    Li=length(indices);
    senyali(i)=sum(senyal(indices))/Li;
end

%% Normalización (se aplica sobre la matriz de características)
function funcio = Normalitzacio(X)

for i = 1:(size(X,2)-2)
    mitjana_i = mean(X(:,i));
    desv_i = std(X(:,i));
    Xnorm(:,i) = (X(:,i)-mitjana_i)/desv_i;
end

Xnorm = [Xnorm X(:,(size(X,2)-1)) X(:,(size(X,2)))];
funcio = Xnorm;
end

```