

Apoyo en la detección de apnea del sueño mediante aprendizaje profundo

Micaela Levrino¹, Juan Felipe Restrepo^{1,2[0000-0003-0643-2552]} y Gastón Schlotthauer^{1,2[0000-0002-2692-3255]}

¹ Facultad de Ingeniería, Universidad Nacional de Entre Ríos, Oro Verde, Argentina

² Instituto de Investigación y Desarrollo en Bioingeniería y Bioinformática (IBB),

CONICET - UNER, Oro Verde, Argentina

mlevrino@ingenieria.uner.edu.ar

juan.restrepo@uner.edu.ar

gaston.schlotthauer@uner.edu.ar

Resumen El síndrome de apnea/hipopnea obstructiva del sueño constituye uno de los trastornos del sueño más prevalentes, con importantes implicaciones sociosanitarias, en el cual la detección temprana es crucial para iniciar tratamientos adecuados o tomar medidas preventivas. La polisomnografía, método de diagnóstico de elección, es muy costosa en términos de tiempo y dinero, por lo que no está disponible para un grupo de la población general. Proponemos obtener indirectamente la información de la detección de eventos de apnea/hipopnea a través de la señal de saturación de oxígeno obtenida mediante un oxímetro de pulso. La obtención de la distribución condicional de la señal de detección de eventos de apnea/hipopnea dado el comportamiento de la saturación de oxígeno se logra mediante la optimización de un límite inferior de evidencia. Para el diseño del algoritmo empleado se utilizan modelos generativos profundos, en particular redes generativas adversarias y autoencoder variacionales. En nuestro estudio, analizamos datos de 5804 pacientes de la base de datos Sleep Health Heart Study. En la etapa de prueba, alcanzamos una exactitud del 80 %, una sensibilidad del 80 % y una precisión del 79 %.

Palabras clave: Apnea del sueño · Saturación de oxígeno · Índice de apnea/hipopnea · Redes generativas adversarias.

1. Introducción

El sueño desempeña un papel fundamental en la salud y el bienestar de las personas. Un sueño saludable es importante para el funcionamiento cognitivo, el estado de ánimo, la salud mental y la salud cardiovascular, cerebrovascular y metabólica [1]. Además, la cantidad y calidad adecuadas del sueño también son fundamentales para reducir el riesgo de accidentes y lesiones causadas por la somnolencia y la fatiga, incluidos los accidentes laborales y automovilísticos. La privación del sueño a corto plazo, la restricción del sueño a largo plazo, la desalineación circadiana y los trastornos del sueño no tratados pueden tener un impacto profundo y perjudicial en la salud física, mental, estado de ánimo y

seguridad pública. La falta de sueño crónica se asocia con un mayor riesgo de mortalidad y contribuye tanto al riesgo individual como a la carga social asociada con varias epidemias médicas, incluidas las enfermedades cardiovasculares, diabetes, obesidad y cáncer [2]. En el año 2014, la Academia Americana de Medicina del Sueño (*American Academy of Sleep Medicine*) [3] publicó la tercera edición de la Clasificación Internacional de Patologías del Sueño (*International Classification of Sleep Disorders*), donde se indica que uno de los trastornos del sueño más comunes es el Síndrome de Apnea Obstructiva del Sueño (SAOS), que es causado por eventos repetidos de obstrucción parcial (hipopnea) o total (apnea) de las vías respiratorias superiores durante el sueño. En entornos con buenos recursos se están realizando esfuerzos considerables para diagnosticar y tratar a las personas con SAOS, pero los datos disponibles sugieren que la mayoría de los casos de SAOS siguen sin diagnosticarse, incluso en los países desarrollados. En 2019, un estudio realizado por Benjafield y cols. [4] estima que alrededor de mil millones de adultos de entre 30 y 69 años en todo el mundo podría sufrir SAOS basándose en los criterios fijados por la AASM, y estiman que el número de personas con SAOS de moderada a grave, para las que generalmente se recomienda tratamiento, es de 425 millones.

La polisomnografía (PSG) es el método convencional utilizado para la detección de trastornos del sueño, incluido el SAOS. La PSG típica contiene registros de electroencefalografía, electrooculografía, electromiografía, electrocardiografía, flujo de aire oronasal, esfuerzo respiratorio y saturación periférica de oxígeno en sangre (SpO_2). Sin embargo se considera incómodo (debido a la gran cantidad de cables y sensores conectados al cuerpo del sujeto), costoso y no disponible para un gran grupo de la población mundial. Además el proceso de análisis requiere mucho tiempo y trabajo. Por lo general los centros médicos cuentan con un pequeño número de profesionales capaces de diagnosticar apnea del sueño lo que genera largas listas de espera [5]. Por lo tanto, se desea tener un sustituto del sistema basado en PSG que sea simple, económico y portátil que pueda utilizarse en hogares y clínicas. La oximetría de pulso es una técnica de medición ideal para esto, ya que es económica, discreta y fácil de configurar en un entorno doméstico. La señal de SpO_2 es de particular interés para la detección de eventos de SAOS [6], esto es debido a que el cese de la respiración asociado con eventos de apnea-hipopnea siempre va acompañado de una caída en el nivel de saturación de oxígeno. Sin embargo, es apropiado mencionar que este nivel de caída puede ser muy pequeño e imposible de detectar por un observador humano, razón por la cual las técnicas avanzadas de procesamiento de señales, como los métodos de aprendizaje maquinaria, podrían proporcionar una alternativa muy valiosa. En el contexto de la detección de SAOS, las redes generativas adversarias (GANs) tienen el potencial de transformar la forma en que se recopilan y analizan los datos de los pacientes. Estas redes pueden aprender patrones sutiles en los datos de PSG y generar señales sintéticas que se asemejan a los patrones de sueño y las interrupciones respiratorias observadas en pacientes reales. Esto podría facilitar la recopilación de datos fuera del laboratorio del sueño y mejorar la eficiencia en el diagnóstico.

2. Materiales

El estudio fue realizado en las instalaciones del *Laboratorio de Señales y Dinámicas no Lineales* de la Facultad de Ingeniería de la Universidad Nacional de Entre Ríos. Para el desarrollo se emplearon GPUs instaladas en un cluster de alto desempeño equipado con tres GPU NVIDIA GTX 1080Ti. La implementación del trabajo se desarrolló en lenguaje de programación Python 3.

2.1. Base de datos

Se utilizó la base de datos *Sleep Heart Health Study* (SHHS) debido a que contiene 5424 registros obtenidos mediante estudios de PSG que fueron adquiridos por dispositivos domiciliarios y bajo la supervisión de un técnico especializado. Se escoge debido a la precisión demostrada en su utilización en proyectos anteriores, por lo que se confirma que los datos están etiquetados correctamente y se pueden utilizar para entrenar el modelo de manera más efectiva y reducir la posibilidad de errores. Además esta base de datos es accesible, lo que la convierte en una herramienta valiosa para la comunidad de investigadores y desarrolladores de aprendizaje profundo, y los estudios adquiridos en la base de datos fueron analizados bajo los estándares publicados por la AASM.

3. Metodología

3.1. Arquitectura del método propuesto

En el presente estudio el conjunto de datos toma la forma $(x_1, y_1), \dots, (x_N, y_N)$ donde (x_i, y_i) es la i -ésima observación que consiste en un segmento de la señal de SpO₂ x_i y su correspondiente señal de apnea/hipopnea y_i . Se supone que existe una representación de menor dimensión o variable latente continua, z , de un segmento de señal de SpO₂ que permite la reconstrucción del correspondiente segmento de señal de apnea/hipopnea, y . Sea $p_{\theta^*}(z|x)$ la verdadera estimación *a posteriori* sobre las variables latentes condicionadas a las muestras de SpO₂. Dado que se desconoce la verdadera distribución, se propone aprender una aproximación parametrizada $q_{\phi}(z|x)$ a la intratable verdadera estimación *a posteriori* $p_{\theta^*}(z|x)$. Sea $p_{\theta}(z|y)$ la posterior de la variable latente z condicionada a las muestras de la señal de apnea/hipopnea y , se asume que la señal de apnea/hipopnea puede ser perfectamente reconstruida por z . Entonces es intuitivo asignar las muestras de la señal de SpO₂ de entrada a un espacio latente que reconstruiría bien la señal de apnea/hipopnea. Esto puede lograrse minimizando la divergencia KL entre la distribución condicional de la señal de apnea/hipopnea, $p_{\theta}(z|y)$ y la aproximación $q_{\phi}(z|x)$ a la verdadera posterior $p_{\theta^*}(z|x)$, para transformar la

señal de SpO₂ en la señal de apnea/hipopnea. Matemáticamente:

$$\begin{aligned}
 \text{KL}[q_\phi(z|x_i) \parallel p_\theta(z|y_i)] &= \int q_\phi(z|x_i) \log \frac{q_\phi(z|x_i)}{p_\theta(z|y_i)} dz \\
 &= \log p_\theta(y_i) + \int q_\phi(z|x_i) \log \frac{q_\phi(z|x_i)}{p_\theta(y_i, z)} dz \\
 &= \mathbb{E}_{q_\phi} \left[\log \left(\frac{q_\phi(z|x_i)}{p_\theta(y_i, z)} \right) \right] + \log p_\theta(y_i) \\
 &= -\mathbb{E}_{q_\phi} \left[\log \left(\frac{p_\theta(y_i, z)}{q_\phi(z|x_i)} \right) \right] + \log p_\theta(y_i) \\
 &= -\mathcal{L}(\phi, \theta; x_i) + \log p_\theta(y_i)
 \end{aligned} \tag{1}$$

La divergencia anterior se puede reformular de la siguiente manera:

$$\begin{aligned}
 \log p_\theta(y_i) &\geq \mathcal{L}(\phi, \theta; x_i) = \mathbb{E}_{q_\phi} \left[\log \left(\frac{p_\theta(y_i, z)}{q_\phi(z|x_i)} \right) \right] \\
 &= \mathbb{E}_{q_\phi} [-\log q_\phi(z|x_i) + \log p_\theta(y_i, z)]
 \end{aligned} \tag{2}$$

Y el Límite inferior de evidencia (*Evidence lower bound*) (ELBO) de la expresión anterior $\mathcal{L}(\phi, \theta; x_i)$ se puede calcular como:

$$\begin{aligned}
 \mathcal{L}(\phi, \theta; x_i) &= -\text{KL}[q_\phi(z|x_i) \parallel p_\theta(z)] + \mathbb{E}_{q_\phi} [-\log p_\theta(y_i|z)] \\
 &= \mathbb{E}_{q_\phi} [-\log q_\phi(z|x_i) + \log p_\theta(y_i|z) + \log p_\theta(z)]
 \end{aligned} \tag{3}$$

Adoptando un enfoque basado en la máxima verosimilitud, se optimiza esta cota inferior de evidencia $\mathcal{L}(\phi, \theta; x_i)$ ELBO con respecto a los parámetros variacionales ϕ para aprender la distribución aproximada. La parametrización elegida para el modelo de inferencia $q_\phi(z|x_i)$ decide naturalmente la estrechez del límite inferior derivado anteriormente. Si existe $\phi^* \in \Phi$ tal que $q_\phi(Z|X) = p_\theta(Z|X)$ donde Φ es el espacio de parámetros de inferencia, entonces el ELBO será un límite ajustado a $\log p_\theta(y_i)$. Esto rara vez sucede en la práctica, por lo tanto, el espacio ϕ está diseñado para ser lo más expresivo posible, para permitir el aprendizaje de una aproximación cercana. En el modelo del presente proyecto se parametrizan tanto $q_\phi(z|x_i)$ como $p_\theta(y_i|z)$ como redes neuronales que son conocidas como aproximadores universales de funciones. Se construye un modelo diferenciable de extremo a extremo donde la distribución $p_\theta(z)$ es aprendida por un autoencoder separado, conocido por reproducir perfectamente la señal de apnea/hipopnea. Un autoencoder que reconstruye la señal de apnea/hipopnea impone un espacio latente z y aprende una distribución marginal sobre él dada por la siguiente ecuación:

$$p(z) = \int_y p(z|y)p(y)dy \tag{4}$$

Si se supone una reconstrucción perfecta de la señal de apnea/hipopnea por el autoencoder apnea/hipopnea (validado en el presente proyecto), esta distribución marginal puede considerarse una buena estimación *a priori*, ya que se sabe

que permite la reconstrucción de la señal de apnea/hipopnea a partir del espacio latente. A partir de esta presentación, se refiere a la distribución marginal como $p_\theta(z)$, bajo la suposición de que una baja pérdida de reconstrucción empírica implica que está cerca del anterior óptimo. Una vez que esta estimación *a priori* se aprende a través del autoencoder apnea/hipopnea, se impone el aprendizaje de la misma distribución en la capa latente de la red que convierte la señal de SpO₂ en señal de apnea/hipopnea. Esto se hace minimizando “adversarialmente” la divergencia $KL[q_\phi(z|x_i) \parallel p_\theta(z)]$ en la ecuación 3. Como se muestra en [7], el entrenamiento “adversarial” se puede utilizar para entrenar $q_\phi(z|x_i)$ como una aproximación universal de la estimación *a posteriori*, al agregar ruido aleatorio ϵ a la entrada x_i . Esto permite la construcción de estimaciones *a posteriori* arbitrarias $q_\phi(z|x_i)$, evaluando el modelo de inferencia $f_\phi(x_i, \epsilon)$ para diferentes valores de ϵ . Por lo tanto, incluso con un mapeo determinista fijo de la entrada al espacio latente, la distribución *a posteriori* no colapsará en una distribución delta de Dirac degenerada (es decir, una distribución discontinua), ya que el ruido de entrada agrega una fuente de estocasticidad diferente a la distribución que genera los datos en sí. Por lo tanto, la real estimación *a posteriori* se da por la expresión:

$$q_\phi(z|x_i) = \int_\epsilon q_\phi(z|x_i, \epsilon) p_\epsilon(\epsilon) d\epsilon \quad (5)$$

donde $q_\phi(z|x_i, \epsilon)$ es la distribución degenerada $\delta(z - f_\phi(x_i, \epsilon))$. El método utilizado en el presente proyecto elimina las restricciones de normalidad tanto en la estimación *a posteriori* como en la estimación *a priori* al utilizar el entrenamiento adversarial para minimizar la divergencia KL. Esto implica un juego minimax entre la red $q_\phi(z|x)$ y una red discriminadora T_ψ , que está diseñada para detectar si la muestra generada por la red $q_\phi(z|x)$ proviene de la estimación *a posteriori* $p_\theta(z)$ (aprendida a través del autoencoder apnea/hipopnea) o no. Matemáticamente, se optimiza la siguiente función objetivo para minimizar el término KL en ELBO:

$$\min_{\epsilon_\phi} \max_{T_\psi} V(q_\phi, T_\psi) = \mathbb{E}_{z \approx p_\theta(z)} [\log T_\psi(z)] + \mathbb{E}_{z \approx q_\phi(z|x)} [\log(1 - T_\psi(z))] \quad (6)$$

El segundo término del ELBO en 3 se interpreta como el error de reconstrucción esperado de la señal de apnea/hipopnea en la salida dado el vector latente, y se puede minimizar mediante diversas funciones de pérdida. Se elige minimizar este error midiendo la distancia coseno entre la señal de apnea/hipopnea estimada y la señal de apnea/hipopnea real. El resumen del método utilizado se muestra en la figura 1.

3.2. Agrupación de los datos

El conjunto de datos SHHS-1 se dividió en tres subconjuntos independientes aleatoriamente. Sin embargo, como se desea tener igual división cada vez que se ejecuta el entrenamiento, se utiliza una semilla aleatoria. Por lo tanto, el conjunto de datos queda dividido de la siguiente manera:

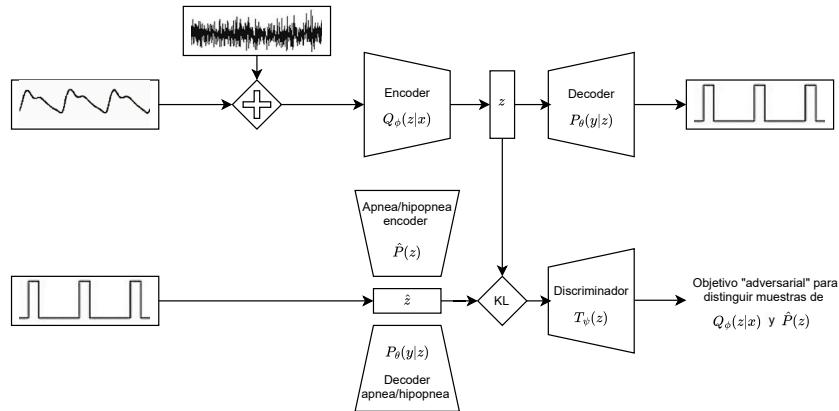


Figura 1: Representación de la arquitectura del método propuesto.

- 70% (3797 pacientes), conjunto de entrenamiento (*training*), para que el algoritmo de aprendizaje obtenga los parámetros del modelo.
- 20% (1085 pacientes), conjunto de validación (*validation*), para verificar el desempeño de cada modelo con un conjunto diferente al de entrenamiento y así poder compararlos.
- 10% (542 pacientes), conjunto de prueba (*test*), para verificar el desempeño del modelo ganador. Este conjunto nunca es mostrado a ninguno de los modelos.

En el proceso de entrenamiento de modelos de aprendizaje profundo, es común agrupar los datos en lotes, conocidos como *minibatches*. Estos minibatches se utilizan para calcular el error y actualizar los coeficientes del modelo a través del optimizador. De esta forma, los datos de entrada se dividen en minibatches, lo que permite un proceso de entrenamiento más eficiente y efectivo. Esto es particularmente útil cuando se trabaja con conjuntos de datos grandes, ya que el uso de minibatches agiliza el proceso de optimización.

3.3. Proceso de entrenamiento

El autoencoder apnea/hipopnea se entrena primero de manera independiente, seguido por el entrenamiento de la red adversaria.

Entrenamiento del autoencoder En esta etapa, se entrena el autoencoder para aprender una representación latente de los datos de apnea/hipopnea. El autoencoder consta de un codificador que mapea los datos de apnea/hipopnea a un espacio latente, y un decodificador que mapea las muestras latentes de vuelta al espacio de datos de apnea/hipopnea. El autoencoder se entrena para minimizar la diferencia entre los datos de apnea/hipopnea originales y los reconstruidos por

el decodificador. En particular, se utiliza una función de pérdida de reconstrucción que mide la diferencia entre los datos originales y los datos reconstruidos. La función de pérdida de reconstrucción se define como la suma de los errores cuadráticos medios (MSE) entre los datos de apnea/hipopnea originales y los reconstruidos por el decodificador.

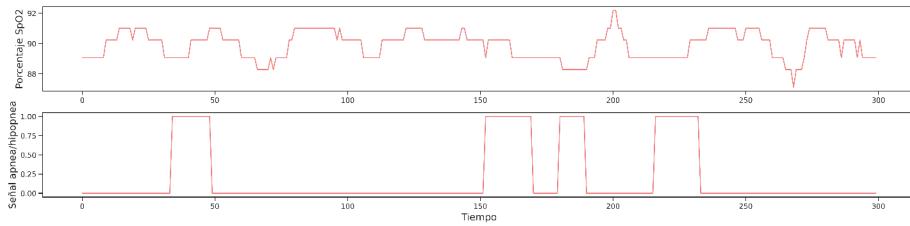
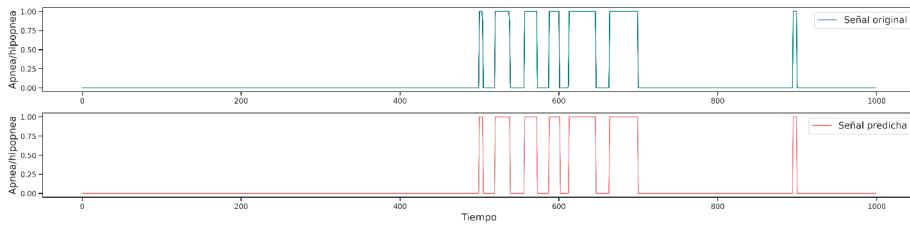
Entrenamiento de la red adversaria En esta etapa, se lleva a cabo el entrenamiento de la red adversaria para aproximar la estimación verdadera *a posteriori*. La red generadora se entrena para generar muestras de la estimación verdadera *a posteriori* mientras que la red discriminadora se entrena para distinguir entre muestras generadas por la red generadora y muestras de la estimación verdadera *a posteriori*. La optimización de la GAN implica un juego minimax entre la red generadora y la red discriminadora, donde la red generadora trata de engañar a la red discriminadora y la red discriminadora trata de distinguir entre las muestras generadas y las muestras verdaderas. El objetivo final es minimizar la divergencia KL entre la estimación verdadera *a posteriori* y la estimación aproximada generada por la red generadora. Se actualizan los pesos de la red generadora y la red discriminadora utilizando el algoritmo de retropropagación del error, y se iteran los pasos hasta que se alcance la convergencia.

4. Resultados

En el estudio se trabajó con la señal de SpO₂ como entrada al algoritmo diseñado con el propósito de detectar eventos de apnea/hipopnea. La relación entre estas señales puede observarse en el ejemplo del registro de una porción de la señal de la base de datos SHHS-2 en la figura 2. En la parte superior, se presenta el gráfico de la señal de detección de eventos de apnea/hipopnea, donde el valor 1 indica la detección de un evento y 0 representa la ausencia o no detección. En la parte inferior de la figura, se muestra la señal correspondiente a la variación de SpO₂ para el mismo instante de tiempo, obtenida de un paciente de la base de datos SHHS-1. Se puede observar que en presencia de un evento de apnea/hipopnea, hay asociada una desaturación de oxígeno en sangre, la cual se registra de manera indirecta en la señal de SpO₂. A través de la identificación de estas desaturaciones, se puede estimar el valor del IAH, lo que posibilita predecir la gravedad del SAOS en cada paciente.

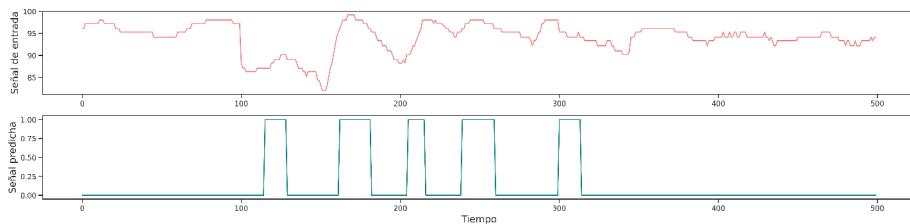
4.1. Autoencoder apnea/hipopnea

El mejor desempeño para el autoencoder apnea/hipopnea se obtuvo utilizando un *learning rate* igual a 0.001 y un *batch size* de 2048. En la figura 3 se observa una porción de la señal original de apnea/hipopnea a la izquierda, es decir, la entrada al modelo, y a la derecha la porción de señal correspondiente reconstruida por el autoencoder apnea/hipopnea aplicado al subconjunto de prueba, es decir la salida. Se indica como “0” la ausencia de apnea y como “1” la detección de SAOS.

**Figura 2:** Registro de señal de detección de apnea y SpO₂.**Figura 3:** Señal original de apnea/hipopnea y la reconstruida por el autoencoder.

4.2. Red adversaria

El mejor desempeño para el generador se obtiene utilizando un valor de *learning rate* igual a 0.0001 y *batch size* de 512. Por otro lado el mejor desempeño para el discriminador se obtiene utilizando un valor de *learning rate* de 0.0001 y *batch size* de 512. La evaluación del rendimiento de la red adversaria en el subconjunto de datos de prueba se realiza utilizando el algoritmo propuesto completo. Como entrada se toman las señales de SpO₂ y como salida se espera predecir una señal de detección de los eventos de apnea/hipopnea asociados. En la figura 4 se observan los datos de entrada, parte superior, y salida, parte inferior, al algoritmo propuesto.

**Figura 4:** Señal original de entrada y salida del algoritmo propuesto.

En la figura 5 se realiza una comparación de la salida deseada y la salida predicha por el modelo. Se puede observar que, a pesar de no coincidir exactamente las detecciones en la línea temporal, ambos fragmentos de señal presentan la misma cantidad de eventos de apnea/hipopnea, que es el objetivo.

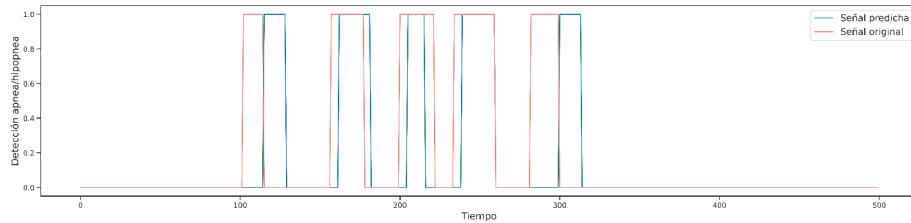


Figura 5: Señal deseada de salida y señal predicha.

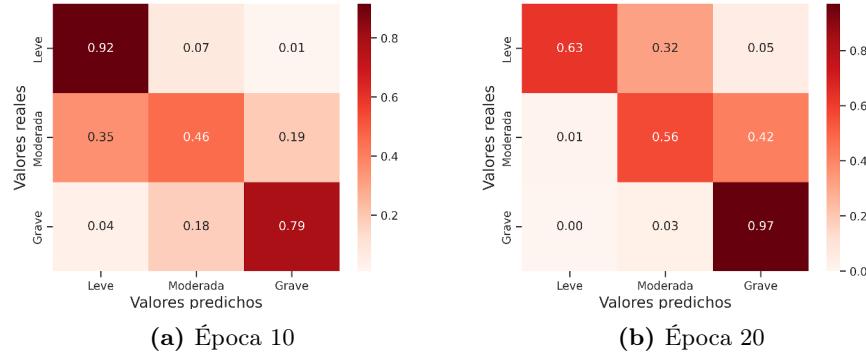
4.3. Métricas de evaluación

Una vez determinados los modelos con los mejores rendimientos, se aplicó el algoritmo diseñado para predecir el IAH de cada paciente perteneciente a la base de datos SHHS-1 y compararlo con el IAH original de cada uno. Esta evaluación se llevó a cabo mediante el empleo de la matriz de confusión. Para la evaluación del método propuesto se tiene en cuenta lo expresado por la AASM para la designación de la gravedad del SAOS mediante el IAH, como se resume en el cuadro 1. Se hace evidente la importancia de la detección del SAOS grave,

Cuadro 1: Clasificación gravedad SAOS según IAH.

IAH	Clasificación SAOS
[0, 5)	Normal
[5, 15)	Leve
[15, 30)	Moderado
≥ 30	Grave

debido que serán estos los pacientes que necesitan detección temprana para poder establecer prioridades en la lista de espera para acceder a una PSG o para ser derivados a utilizar tratamiento con resión positiva continua en la vía aérea (*Continuous Positive Airways Pressure*) de manera provisional si así lo considerase un profesional. Para diferentes épocas se obtienen las matrices de confusión que se observan en la figura 6, con sus respectivas métricas en el cuadro 2.

Figura 6: Matrices de confusión obtenidas para un *batch size* de 256.Cuadro 2: Métricas de evaluación utilizando un *batch size* de 256.

Época	Exactitud	Precisión	Sensibilidad	F1-score
10	0,80	0,79	0,80	0,80
20	0,66	0,80	0,66	0,69

5. Discusión

La detección temprana y precisa del SAOS es crucial para la salud y el bienestar de los individuos. Diversos estudios han explorado el uso de señales de oxímetría de pulso como una herramienta efectiva en este ámbito. En esta sección, se realiza una comparación exhaustiva con el estado del arte, examinando diferentes enfoques y metodologías utilizadas en la detección del SAOS a través de la monitorización de la señal de saturación de oxígeno.

En el estudio de Almazaydeh y cols. [8], publicado en 2012, utilizan la base de datos *Apnea-ECG Database* que incluye 32 sujetos hombres y mujeres entre 27 y 63 años, y aplican una red neuronal (*Neural Network*) (NN) como clasificador para identificar apnea obstructiva del sueño utilizando características de la señal de SpO₂ que actúan como entradas para la red. Lograron una exactitud de 93,3 %, sensibilidad 87,5 % y precisión de 100 %. Al año siguiente, Morillo y cols. [9] publicaron su estudio donde propusieron un sistema multivariado para la detección del SAOS a partir del análisis de la SpO₂ durante la noche. Utilizaron una base de datos compuesta de 115 sujetos adultos y calcularon 17 características en el dominio temporal, estocástico, de frecuencia y no lineales a partir de los registros de SpO₂. Obtuvieron una exactitud de 93,91 %, sensibilidad 92,42 % y precisión de 95,92 %, considerando la presencia de SAOS cuando el IAH es mayor a 10 eventos por hora. Ese mismo año, Álvarez y cols. [10] utilizaron una base de datos de 249 sujetos adultos para evaluar la utilidad de diferentes metodologías de selección de características y clasificación para analizar los registros de SpO₂ en el contexto de la detección de SAOS. Calcularon

medidas estadísticas, espectrales y no lineales para formar el conjunto inicial de características y aplicaron el análisis de componentes principales (*Principal component analysis*) (PCA), *forward stepwise feature selection* (FSFS) y algoritmos genéticos (*genetic algorithms*) (GAs) para seleccionar subconjuntos de características. En 2014 Schlotthauer y cols. [11] propusieron un método basado en la descomposición empírica de modos (*Empirical mode decomposition*) (EMD) de la señal de oximetría de pulso, considerando que las desaturaciones producen un patrón de ondas muy específico que se extrae en los modos de la descomposición. Utilizando esta información construyeron un detector basado en umbrales adecuadamente seleccionados y un conjunto de reglas. Aplicaron EMD a la señal de SpO₂ preprocesada, con un número máximo de modos establecido en seis y un número máximo de iteraciones de cribado establecido en 50. Finalmente, calcularon un índice de desaturación de oxígeno, definido como la relación entre el número de eventos de desaturación y la duración de la señal válida (en horas). El índice de desaturación de oxígeno construido a partir de estas detecciones generó un detector de SAOS con una alta sensibilidad 83,8% y especificidad 85,5%. Al siguiente año, Hangh y cols. [12] utilizaron una base de datos con 616 sujetos de entre 20 y 85 años y realizaron un análisis estadístico descriptivo de datos demográficos, antropométricos, cuestionarios y PSG de los pacientes para calcular medias y desviaciones estándar de las variables individuales. Aplicaron análisis estadísticos inferenciales, incluyendo la prueba de chí-cuadrado de Pearson y análisis de varianza (*Analysis of variance*) (ANOVA), para destacar variables significativas que discriminan entre sujetos normales, y pacientes con SAOS leve, moderada y grave. Los modelos diseñados proporcionaron una exactitud de 90,42%, sensibilidad 89,36% y precisión de 91,08% para el diagnóstico de pacientes con SAOS grave; además, lograron una exactitud de 87,33%, sensibilidad 87,71% y una precisión de 86,56% para el diagnóstico de pacientes con SAOS moderada, considerando el mismo criterio de clasificación de SAOS, según el IAH, que en el presente proyecto. En 2017, Rolón y cols. [13] presentaron su investigación que introduce dos enfoques novedosos llamados *most discriminative activation selection* (MDAS) y *most discriminative column selection* (MDCS) para la detección de eventos de apnea-hipopnea utilizando señales de oximetría de pulso. Para la implementación utilizaron una base de datos constituida por 995 sujetos, y demostraron que el método MDCS-OD supera a los demás, con una exactitud de 85,78%, sensibilidad 85,65% y precisión de 85,92%. En 2021, Sharma y cols. [14] propusieron utilizar la transformada de onda concentrada de duración-banda óptima (*Optimal duration-bandwidth concentrated wavelet transform*) para descomponer las señales de SpO₂ en diversas sub-bandas (*Sub-bands*) (SBs). Extrajeron características de entropía de Shannon de los coeficientes de varias SBs, y esas características alimentaron a varios algoritmos supervisados de aprendizaje automático, incluidos árboles de decisión y algoritmos de conjunto para la detección de SAOS. Utilizaron dos bases de datos, la primera *St. Vincents University Hospital/University College Dublin Sleep Apnea Database* (UCD) con 25 sujetos adultos, y la segunda *Sleep Apnea ECG database* (SAE) con 8 sujetos adultos. El modelo que propusieron alcanzó la mayor exactitud

de 95,97 %, sensibilidad 95,78 % y precisión 96,09 % para características óptimas de entropía de Shannon basadas en la onda cuando se emplea la técnica de *random under-sampling boosting (RUSBoost)*. Ese mismo año, Jung y cols. [15] publicaron su investigación donde utilizaron una base de datos de 230 sujetos considerando la misma clasificación de gravedad de SAOS que en el presente proyecto a partir del IAH para implementar una estrategia para la detección automática casi en tiempo real de eventos apneicos y una estimación confiable del IAH utilizando oximetría de pulso. Extrajeron características cuantitativas causadas por el evento apneico para la cantidad y duración del cambio en el valor de la SpO₂ y establecieron criterios para determinar la ocurrencia del evento apneico. Utilizaron un modelo de regresión para estimar el IAH a partir de los resultados de la detección de eventos apneicos. Lograron una exactitud promedio para el diagnóstico de SAOS de 96,7 % para los valores de corte del IAH de 5, 10, 15 y 30 eventos/h. En el cuadro 3 se resumen las metodologías utilizadas en los trabajos presentados en el área, junto con las métricas obtenidas. La columna N en la tabla indica el número de sujetos incluidos en cada base de datos. Los resultados obtenidos por diferentes investigadores indican altas tasas de exactitud, sensibilidad y precisión en la detección de SAOS, lo que sugiere que la monitorización de la señal de SpO₂ es una herramienta prometedora en este contexto. Aunque los resultados obtenidos por el modelo propuesto en el presente proyecto no superan a los obtenidos por otros en el estado del arte, es importante destacar el tamaño de la base de datos utilizada en relación con los demás trabajos. Este aspecto reduce significativamente el riesgo de sobreajuste, lo que refuerza la validez y generalización del modelo propuesto. A pesar de las diferencias en las tasas de rendimiento, la consideración del tamaño de la base de datos es crucial al interpretar y comparar los resultados entre diferentes estudios. La comparación entre diferentes algoritmos es un proceso complejo, dada la diversidad en las bases de datos utilizadas y en los enfoques metodológicos empleados. A pesar de estas dificultades, el modelo propuesto se posiciona como una contribución significativa, no solo por sus métricas, sino también por la rigurosidad en la selección y manipulación de datos, lo que fortalece su aplicabilidad en un contexto más amplio.

6. Conclusión

El éxito del proyecto actual como primera aproximación a la detección de SAOS grave mediante señales obtenidas por oximetría de pulso, sugiere diversas direcciones para futuras investigaciones y mejoras en el ámbito. Se podría explorar la posibilidad de mejorar la arquitectura del modelo actual, incorporando capas adicionales o variando la complejidad de las redes neuronales. La implementación de técnicas de transferencia de aprendizaje también podría considerarse para optimizar el rendimiento. Por otro lado, la robustez del modelo podría evaluarse en conjuntos de datos externos, lo que permitiría verificar su capacidad de generalización a diferentes poblaciones y contextos clínicos.

Cuadro 3: Comparación con trabajos que detectan SAOS a partir de señales de oximetría de pulso.

Autor	N	Metodología	Exactitud	Sensibilidad	Precisión
Almazaydeh y cols. [8]	32	NN	93,30	87,50	100,00
Morillo y cols. [9]	115	PNN	93,91	92,42	95,92
Álvarez y cols. [10]	249	FLD + GAs	81,20	80,00	83,30
		FSFS + LR	88,70	95,20	86,00
		SVM + GAs	84,50	95,20	80,00
Schlotthauer y cols. [11]	996	EMD	85,02	84,11	85,94
Hang y cols. [12]	616	SVM	87,33	87,71	86,56
Rolón y cols. [13]	995	MDCS-OD	85,78	85,65	85,92
Sharma y cols. [14]	25	RUSBoosted trees	89,21	92,34	89,13
	8	RUSBoosted trees	95,97	95,78	96,09
Jung y cols. [15]	230	Regresión	96,70	97,10	96,50
Presente trabajo	5804	GAN	80,00	80,00	79,00

Referencias

1. C. C. Panel; N. F. Watson, M. S. Badr, G. Belenky, D. L. Bliwise, O. M. Buxton, D. Buysse, D. F. Dinges, J. Gangwisch, M. A. Grandner, *et al.*, “Joint consensus statement of the american academy of sleep medicine and sleep research society on the recommended amount of sleep for a healthy adult: methodology and discussion,” *Journal of Clinical Sleep Medicine*, vol. 11, no. 8, pp. 931–952, 2015.
2. F. S. Luyster, P. J. Strollo Jr, P. C. Zee, and J. K. Walsh, “Sleep: a health imperative,” *Sleep*, vol. 35, no. 6, pp. 727–734, 2012.
3. R. B. Berry, R. Brooks, C. E. Gamaldo, S. M. Harding, C. Marcus, B. V. Vaughn, *et al.*, “The aasm manual for the scoring of sleep and associated events,” *Rules, Terminology and Technical Specifications, Darien, Illinois, American Academy of Sleep Medicine*, vol. 176, p. 2012, 2012.
4. A. V. Benjafield, N. T. Ayas, P. R. Eastwood, R. Heinzer, M. S. Ip, M. J. Morrell, C. M. Nunez, S. R. Patel, T. Penzel, J.-L. Pépin, *et al.*, “Estimation of the global prevalence and burden of obstructive sleep apnoea: a literature-based analysis,” *The Lancet Respiratory Medicine*, vol. 7, no. 8, pp. 687–698, 2019.
5. S. S. Mostafa, F. Mendonça, A. G. Ravelo-García, and F. Morgado-Dias, “A systematic review of detecting sleep apnea using deep learning,” *Sensors*, vol. 19, no. 22, p. 4934, 2019.
6. M. Deviaene, D. Testelmans, B. Buyse, P. Borzée, S. Van Huffel, and C. Varon, “Automatic screening of sleep apnea patients based on the spo 2 signal,” *IEEE journal of biomedical and health informatics*, vol. 23, no. 2, pp. 607–617, 2018.
7. A. Makhzani, J. Shlens, N. Jaitly, I. Goodfellow, and B. Frey, “Adversarial auto-encoders,” *arXiv preprint arXiv:1511.05644*, 2015.
8. L. Almazaydeh, M. Faezipour, and K. Elleithy, “A neural network system for detection of obstructive sleep apnea through spo2 signal features,” *International Journal of Advanced Computer Science and Applications*, vol. 3, no. 5, 2012.
9. D. S. Morillo and N. Gross, “Probabilistic neural network approach for the detection of sahs from overnight pulse oximetry,” *Medical & biological engineering & computing*, vol. 51, pp. 305–315, 2013.

14 M. Levrino y cols.

10. D. Alvarez, R. Hornero, J. V. Marcos, N. Wessel, T. Penzel, M. Glos, and F. Del Campo, "Assessment of feature selection and classification approaches to enhance information from overnight oximetry in the context of apnea diagnosis," *International journal of neural systems*, vol. 23, no. 05, p. 1350020, 2013.
11. G. Schlotthauer, L. E. Di Persia, L. D. Larrateguy, and D. H. Milone, "Screening of obstructive sleep apnea with empirical mode decomposition of pulse oximetry," *Medical engineering & physics*, vol. 36, no. 8, pp. 1074–1080, 2014.
12. L.-W. Hang, H.-L. Wang, J.-H. Chen, J.-C. Hsu, H.-H. Lin, W.-S. Chung, and Y.-F. Chen, "Validation of overnight oximetry to diagnose patients with moderate to severe obstructive sleep apnea," *BMC pulmonary medicine*, vol. 15, no. 1, pp. 1–13, 2015.
13. R. E. Rolón, L. D. Larrateguy, L. E. Di Persia, R. D. Spies, and H. L. Rufiner, "Discriminative methods based on sparse representations of pulse oximetry signals for sleep apnea–hypopnea detection," *Biomedical Signal Processing and Control*, vol. 33, pp. 358–367, 2017.
14. M. Sharma, D. Kumbhani, A. Yadav, and U. R. Acharya, "Automated sleep apnea detection using optimal duration-frequency concentrated wavelet-based features of pulse oximetry signals," *Applied Intelligence*, pp. 1–13, 2022.
15. S. H. Hwang, J. G. Cho, B. H. Choi, H. J. Baek, Y. J. Lee, D.-U. Jeong, K. S. Park, *et al.*, "Real-time automatic apneic event detection using nocturnal pulse oximetry," *IEEE Transactions on Biomedical Engineering*, vol. 65, no. 3, pp. 706–712, 2017.