

Polisomnografía con Redes de Sensores Inalámbricas en el estudio y diagnóstico de la Apnea del Sueño

Polysomnography with Wireless Sensor Networks in the study and diagnosis of Sleep Apnea
Fawssy Evans Obregón Garcés
faevobg@gmail.com

PhD. Milton Orlando Sarria Paja
milton.sarria00@usc.edu.co

Universidad Santiago de Cali, Facultad de Ingeniería, Programa de Ingeniería Electrónica

Resumen

En Colombia el síndrome de la apnea obstructiva del sueño (SAOS), es una enfermedad poco conocida o diagnosticada, siendo incierto el número real de personas afectadas, debido al difícil acceso a los equipos necesarios para el diagnóstico, falta de personal calificado y déficits en el sistema de salud en general. El objetivo de este estudio es sintetizar la investigación o implementación de los sensores inalámbricos en el diagnóstico y control del SAOS. Con este fin, es posible destacar metodologías y dispositivos para la orientación de futuros estudios o desarrollos de este tipo sensores, orientados principalmente al SAOS. Facilitando así la ejecución de estudios a nivel nacional que permitan conocer el estado de salud real de personas afectadas por SAOS en el país. La revisión se centró principalmente en dos metodologías de diagnóstico basados en máquina de soporte vectorial y redes neuronales artificiales, alcanzando valores superiores al 80% en la clasificación y detección de eventos de SAOS, y se hace mención de dos tecnologías complementarias como la recolección de datos polisomnográficos sin contacto y el desarrollo de un sensor inalámbrico para circuitos integrados. La implementación de estos dispositivos en futuros proyectos, permitirán el diagnóstico y monitorización remota de esta enfermedad y la miniaturización la integración a relojes inteligentes.

Palabras Clave: Sensores inalámbricos, señales fisiológicas, apnea obstructiva de sueño

Abstract

In Colombia, obstructive sleep apnea syndrome (OSAS) is a little known or diagnosed disease, the real number of people affected being uncertain, due to the difficult access to the necessary equipment for diagnosis, lack of qualified personnel and deficits in The health system in general. The objective of this study is to synthesize the research or implementation of wireless sensors in the diagnosis and control of OSAS. To this end, it is possible to highlight methodologies and devices for the orientation of future studies or developments of this type sensors, oriented mainly to SAOS. Thus facilitating the execution of studies at national level that allow to know the real state of health of people affected by SAOS in the country. The review focused mainly on two diagnostic methodologies based on vector support machine and artificial neural networks, reaching values higher than 80% in the classification and detection of OSAS events, and mention is made of two complementary technologies such as data collection Contactless polysomnographic and the development of a wireless sensor for integrated circuits. The implementation of these devices in future projects, will allow the diagnosis and remote monitoring of this disease and the miniaturization integration to smart watches.

Keywords: Wireless sensors, physiological signals, obstructive sleep apnea

1. INTRODUCCIÓN

La importancia del estudio de enfermedades respiratorias crónicas y de trastornos generales del sueño, como la del síndrome de apnea obstructiva del sueño (SAOS), ha aumentado en los últimos años (Young T. et al, 2009). En Colombia se estima que estas enfermedades afectan a un 30% de la población, según estudios realizados por el ministerio de salud (convenio 519 de 2015), no obstante, se desconoce el porcentaje real de personas que padecen de SAOS, debido al alto costo del proceso de diagnóstico, control y tratamiento de esta enfermedad. Esto se debe que actualmente no toda la población colombiana tiene acceso a un sistema de salud de buena calidad, principalmente en las áreas rurales por su difícil acceso, la falta de instrumentación necesaria y personal calificado. Mientras en las grandes ciudades existen clínicas especializadas con falencias en el diagnóstico oportuno y sin un control efectivo en el tratamiento a personas diagnosticadas con algún trastorno del sueño, entre ellas el SAOS.

Los síntomas más comunes que presenta un paciente con SAOS son: la somnolencia excesiva durante el día, dolores de cabeza matutinos, problemas de memoria, dificultad para concentrarse y estado emocional inestable (como irritación, depresión o cambios de humor). El SAOS no diagnosticado puede aumentar el riesgo para el desarrollo de enfermedades cardiovasculares como hipertensión, insuficiencia cardíaca, accidentes cerebrovasculares, diabetes, entre otras (Young, Terry, et al, 1997).

En la actualidad existen diferentes investigaciones para el desarrollo de nuevos dispositivos que permitan el diagnóstico y control de diversas enfermedades, en este artículo se indagarán algunas técnicas utilizadas para el diagnóstico oportuno del SAOS con la ayuda de las redes inalámbricas de sensores corporales (WBSN), resolviendo en parte el problema del costo y accesibilidad, que se presenta con la instrumentación y exámenes necesarios para un diagnóstico confiable. Por lo general es necesario que el paciente vaya a un laboratorio especializado donde se monitorea el sueño durante una o dos noches, con un sistema dedicado a adquirir registros fisiológicos del paciente entre los que se destacan el *electrocardiograma (ECG)*, *electroencefalograma (EEG)*, *electromiograma (EMG)*, esfuerzo respiratorio, saturación de oxígeno (**SaO₂**), flujo de aire y grabaciones de audio y video (D. Sopic et al,2017; Surrel, G et al, 2018). Sin embargo, esto resulta supremamente incómodo para el paciente debido que es necesario conectar diferentes dispositivos electrónicos para la recolección de datos. A esto se suma el efecto de la **primera noche**, este efecto ocurre con regularidad la primera vez que se duerme en una nueva cama o entorno diferente al habitual. (Adrados, M. R. P. ,2002).

Estos sistemas utilizan algoritmos de clasificación para determinar los posibles eventos que se presentan durante el sueño mediante la polisomnografía realizada al paciente y descartar si se trata de SAOS u otra enfermedad relacionada con el sueño (D. Sopic et al,2017; Surrel, G et al, 2018; P. De Chazal et al, 2003; G. Surrel et al, 2016; T.Penzel, J. et al, 2002), entre estos avances está la utilización de algoritmos de aprendizajes con redes neuronales artificiales en la identificación y clasificación de patrones que se presentan durante un episodio de SAOS, estos sistemas utilizan un solo canal polisomnografico como es el ECG para el procesamiento en tiempo real.

MATERIAL Y METODOS

Fundamentos: Se realiza una revisión sistemática de artículos para el diagnóstico de la apnea del sueño así como documentos y estudios relacionados con la polisomnografía, SAOS y redes de sensores inalámbricos.

Estrategia de búsqueda: En primer lugar se lleva a cabo la búsqueda en Google académico de documentación y publicaciones tanto a nivel nacional como internacional sobre la apnea del sueño, sus síntomas y complicaciones para la salud a corto y largo plazo esta búsqueda se realiza especialmente en el idioma español . Como segunda medida se realiza una búsqueda en Google académico sobre estudios y publicaciones de la polisomnografía, donde se resaltan los equipos, los grados de complejidad y la importancia de la interpretación de los datos que estos puede recolectar; esta búsqueda se realiza completamente en español con documentación de universidades iberoamericanas. En última instancia se realiza una búsqueda con la base de datos IEEE Xplore, en artículos científicos relacionados con apnea del sueño, metodologías y redes de sensores inalámbricos, esta búsqueda se realiza incluyendo artículos en idioma español e inglés. Las búsquedas se realizaron sin límite de fecha de publicación y contenido bibliográfico.

Criterios de inclusión y exclusión: En la búsqueda de la literatura se incluyeron documentación aportada de diferentes fuentes y sociedades profesionales donde se encontraron diversas propuestas para el estudio, diagnóstico y control de esta enfermedad. En la revisión de la documentación se aplicó como criterio de inclusión el año de la publicación (año 2000 hasta la presente fecha), método propuesto (facilidad de implementación) y nivel de impacto socioeconómico. Para el criterio de exclusión el principal motivo fue artículos publicados en años anteriores año 2000 y artículos publicados en otros idiomas diferentes al español e inglés

Extracción de datos: En la búsqueda inicial se preseleccionaron 40 estudios relacionados con el SAOS, Polisomnografía y las WBSN, se excluyeron 23 debido al poco aporte que estos representaban para el artículo de revisión. Finalmente se seleccionaron 14 artículos, una revisión bibliográfica, una tesis doctoral y un informe del ministerio de salud y protección social. Para proceder se revisaron los resúmenes y en caso de ser necesario los artículos completos con el fin de verificar si la información contenida estaba relacionada con el objetivo propuesto.

Análisis de datos: La información se sintetizó a partir de dos metodologías con los resultados más sobresalientes en el diagnóstico del SAOS y dos métodos complementarios a nivel de hardware. Los métodos principales fueron evaluados con base a los resultados obtenidos en el análisis comparativo con la base de datos de dominio público para el desarrollo de tecnologías en el diagnóstico del SAOS y bajo el criterio de los estudios realizados por De Chazal et al (2003).

1.1 Niveles de Polisomnografía

La polisomnografía es el diagnóstico de los trastornos respiratorios del sueño y evaluación de tratamiento con dispositivos electrónicos y de presión positiva en el estudio de patologías del sueño. Existen 4 niveles de polisomnografía según los estudios realizados por Steve y Diana (2011):

Nivel I: Este nivel evalúa como mínimo 7 parámetros entre los cuales se encuentran: electroencefalografía, electrocardiografía, electrooculografía, flujo respiratorio, movimientos toracoabdominales, saturación de oxígeno (oximetría) y electrocardiograma. Este brinda una completa información para el estudio de las diversas patologías contando con grabación de audio y video durante el estudio, pero se realiza en clínicas especializadas causando incomodidad por la numerosa cantidad de cables para la adquisición de datos y también se presenta el síndrome de la primera noche.

Nivel II: En este nivel se encuentran los dispositivos portátiles, contando con los mismos parámetros del nivel I sin las grabaciones audiovisuales y en algunos casos sin electromiografía, puede ser realizadas en un laboratorio de sueño o de forma ambulatoria, sus desventajas son la cantidad de dispositivos que se deben manejar y la falta de precisión por los canales no registrados o por mal posicionamiento de los electrodos.


Nivel III: Este nivel está dedicado a los dispositivos móviles para la recolección de datos para el estudio de la apnea del sueño modificados especialmente para esta actividad, estos dispositivos pueden evaluar 4 parámetros como mínimo: ventilación, movimientos respiratorios, frecuencia cardíaca, electrocardiograma y oximetría. Son fáciles de usar y de fácil acceso, estos dispositivos están solo limitados por cantidad de información que pueden adquirir, de acuerdo con el consumo energético.

Nivel IV: En este nivel se encuentran dispositivos capaces de evaluar de dos a un parámetro como mínimo generalmente son la oximetría y electrocardiografía limitando su capacidad y siendo utilizado por lo general en el seguimiento de arritmias cardíacas por hipoxia.

1.2 Arquitectura de una WBSN


Las WBSN (redes de sensores corporales inalámbricos) se diferencian de su predecesora WSN (red de sensores inalámbricos) principalmente en el número de nodos. Las WBSN poseen arquitectura de transmisión similar con las WSN cada nodo o mota puede monitorear uno o más parámetro (como son: temperatura, humedad, radiación solar, actividad sísmica, entre otras) con múltiples combinaciones, caso contrario de las WBSN en donde cada nodo o mota se configura para capturar un solo parámetro o tarea específica (aceleración, pulso, saturación de oxígeno en la sangre, entre otras). Este tipo de señales exigen altas velocidades de muestreo (100 Hz hasta los 1 kHz). Una WBSN debe ser mínimamente invasiva, de tamaño reducido, fácil de usar, consumo energético eficiente y alta precisión; con el fin de favorecer su portabilidad y la comodidad del portador (Francisco R, 2013).

Figura 1. Esquema general de una WBSN



En la **figura 1** se muestra un esquema general de una WBSN, la posición y los parámetros de monitorización para cada nodo o mota, por lo general cada mota está compuesta de una fuente de alimentación (batería); un hardware encargado de la filtración y obtención de las señales; un software con un sistema operativo, actualmente existen 3 compañías para sensores inalámbricos como: **CROSSBOW** con las plataformas Mica, Mica2, Micaz, Mica2dot, telos y telosb(Jea D & Srivastava. 2005), **MOTEIV** con plataformas como Tmote Sky y Tmote Invent(Otto C et al. 2006)) y **SHOCKFISH**(empresa suiza que desarrolla TinyNode (Dubois et al 2006); encargadas del control de accesos a los medios y los paquetes de datos; un microcontrolador, encargado de los cálculos para el procesamiento; una memoria, encargada de almacenar la información; un radio transceptor para enviar la información recolectada y finalmente el sensor (Francisco R. 2013), que puede variar dependiendo de las necesidades como se muestra en la **figura 2**.

Figura 2. Diagrama de bloques de la arquitectura general de un nodo



Fuente: Francisco R. (2013)

1.3 Metodologías utilizadas para la detección

A continuación, se analizarán 2 de los métodos sobresalientes encontrados durante esta revisión sistemática, donde se proponen la solución a diversos problemas que acarrear los dispositivos móviles especializados para este campo:

1ro. Detección del SAOS en línea con un clasificador de máquina de soporte vectorial (SMV)(G. Surrel et al,2016)

2do. Detección del SAOS usando un clasificador Neuro-difuso para grabaciones de ECG (S. Gopal, 2017).

1.3.1 Detección del SAOS en línea con un clasificador de maquina de soporte vectorial(SMV)

Este método fue desarrollado por los investigadores: **Gregoire Surrel, Amir Aminifar, Francisco Rincón, Srinivasan Murali y David Atienza**

El sistema de detección de SAOS en línea es compatible con la monitorización cardiaca desarrollada por Sopic, Aminifar, A. Aminifar atienza (2017) y E. D. Giovanni et al (2017), permitiendo un método de clasificación de puntos atípicos eficiente mediante la evaluación de los patrones presentes en el SAOS en el dominio del tiempo, dando como resultado un menor consumo computacional, como es el caso en el dominio de la frecuencia cardiaca. La eficiencia obtenida por este método prolonga la vida útil del dispositivo hasta 46 días otorgándole una autonomía considerable.

1.3.1.1 Sistema de monitorización del SAOS

Se presentan los parámetros utilizados y características implementadas en el hardware y software para el sistema portátil.

A. Plataforma portátil

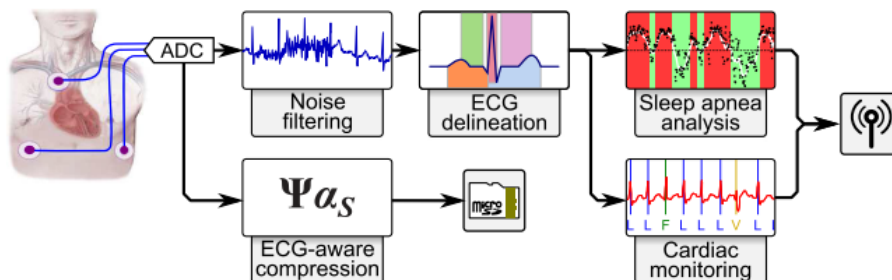
Se considera el sensor portátil SmartCardia INYU (Fig. 3), equipado con un microcontrolador de 32 bit (STM32L151RDT6) con una frecuencia máxima de 32 MHz, 48 kB de RAM, 384 kB de almacenamiento y alimentación de 710 mAh. Esto permite una importante eficiencia energética que proporciona una grabación de ECG con un ADC de 24 bits con una frecuencia de 250 Hz a 16 kHz.

Fig. 3. Sensor INYU. Delanero: 1: STM32L151RDT6 (ARM Cortex-M3 MCU, 384 KB Flash, 48 KB RAM), 2: MPU-6000 (6 ejes I sensor Cmotion), 3: nRF8001 (Bluetooth baja energía v4.0 radio). Atrás: 4: ADS1191 (interfaz analoga para aplicaciones de ECG).



Fuente: Gregoire et al (2018)

Fig. 4. Diagrama de bloques general del procesamiento de la señal ECG.



Fuente: G. Surrel et al (2016)

Gracias a las características mencionadas anteriormente, este dispositivo puede funcionar autónomamente durante varios días de grabación continua, y posteriormente transmitir los datos grabados y procesados a una puerta de enlace o Gateway, este puede ser un smartphone compatible con bluetooth para ser compartidos online y ser revisado por personal calificado.


Como se puede apreciar en la figura 4 el latido cardiaco pasa por diferentes procesos comenzando por el ADC encargado de la conversión análogo-digital de los latidos del corazón capturados por medio de los electrodos conectados al pecho del paciente, compresión y filtrado de los datos obtenidos, y la delineación o clasificación de los parámetros utilizados en busca de episodios de SAOS para finalmente ser transmitido al Gateway más cercano.

B. Proceso de clasificación y detección del SAOS

En esta sección se analiza los procesos necesarios para la correcta clasificación y diagnóstico de los eventos que puedan ser producidas por el SAOS o enfermedades con síntomas parecidos para descartar con eficiencia si se trata o no de este trastorno

Extracción de características


Fig. 5. La morfología del ECG con el intervalo RR y la amplitud RS.



Fuente: E. Ashley and J. Niebauer (2004).

La selección de características para clasificación del SAOS se basa en los estudios realizados por P. De Chazal et al (2003) donde establece los parámetros para un dispositivo autónomo que depende solamente de la señal de ECG para la detección del SAOS y estipula que esta clase de dispositivos debe alcanzar una precisión superior al 90%, donde la morfología del ECG se derivan 52 características y otras 32 adicionales del EDR (señal de respiración derivada del ECG) basados en el estudio de T.Penzel et al (2002). Gracias a estos se ha demostrado que, durante un evento de SAOS hay un desplazamiento de la energía de la señal a baja frecuencias para dos series distintas: la serie de intervalos de 2 latidos cardiacos (intervalo RR) y la serie de amplitud R-pico con respecto a la amplitud S (Amplitud RS) como se muestra en la Figura.5


Fig. 6. La morfología del ECG con el intervalo RR y la amplitud RS etiquetados.



Fuente: Espectrograma de la potencia de registro de la serie RR-intervalos de la grabando x32 con la señal lógica SAOS etiquetada en un mismo eje de tiempo (G. Surrel, et al, 2016).

En la figura 6 se ilustra el desplazamiento de la frecuencia minuto a minuto, donde el eje Y es la medida de la frecuencia con respecto al tiempo en el eje X, aislando las frecuencias más relevantes en los intervalos RR y RS es posible optimizar los datos recolectados y asociarlos con los eventos de SAOS. Los valores altos están relacionados con el color rojo para altas frecuencias y azul para las frecuencias bajas, con estos parámetros es posible realizar barridos de frecuencias (altos y bajos) para la precisión de clasificación de los eventos de SAOS como se ilustra en la figura 7 para los parámetros normalizados del intervalo RR (G. Surrel et al, 2016).

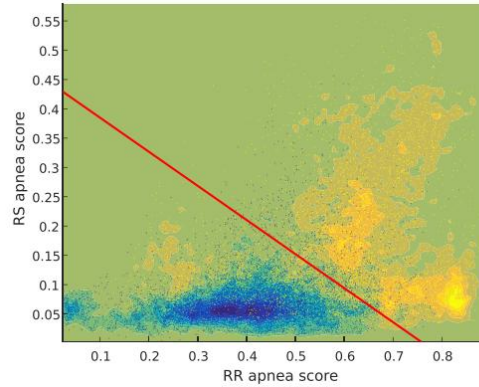
Fig. 7. Precisión de clasificación de SAOS.



Fuente: (G. Surrel et al, 2016).

Según los estudios realizados por G. Surrel et al (2016) los mejores resultados de clasificación se presentan entre el rango de 0,045 a 0,075, menos la zona comprendida de 0,010 a 0,020 por su poca tolerancia. En la figura 7 se puede apreciar con precisión como los eventos de SAOS están ligados al color. Entre más brillante es, mejor será la clasificación alcanzada y dando como resultado una precisión del 76 % para los intervalos RR y amplitudes RS normalizados.

Fig. 8. Distribución de los eventos de apnea (amarillo) y no apnea (azul) del conjunto de entrenamiento de grabaciones para las dos características generadas a partir de la serie de intervalos RR y amplitudes RS. Las dos clases están separadas en función del clasificador lineal de SVM.




Fuente: (G. Surrel et al, 2016).

En la figura 8 se puede apreciar la puntuación de la clasificación de los eventos de SAOS en los intervalos RR-RS utilizando una función de clasificación SVM (máquina de soporte vectorial) alcanzando una clasificación de 80% y 90% basados en los resultados de Baile Xie y Hlaing Minn (2012). Las SVM se utilizan debido a su alto rendimiento de clasificación y alta eficiencia energética con respecto al tiempo de procesamiento y este método es complementado con el algoritmo 1 para valores atípicos donde al cambiar la tolerancia se puede mejorar la clasificación en un 5% más al valor alcanzado anteriormente (G. Surrel et al, 2016).

Fig. 9. Algoritmo de eliminación de baja complejidad y comportamiento de la precisión con respecto al filtro Thompson (D. Sopic et al, 2017)

```

Algorithm 1: Low-Complexity Outlier Removal.
1: function FASTOUTLIERREMOVAL( $x, \tau, k$ )
2:    $N \leftarrow \text{LENGTH}(x)$ ;  $start \leftarrow 1$ ;  $end \leftarrow N$ ;
3:    $\mu \leftarrow \text{COMPUTEMEAN}(x)$ ;
4:    $\sigma \leftarrow \text{COMPUTESTD}(x)$ ;
5:    $low \leftarrow \text{QUICKSELECT}(x, k)$ ;  $\triangleright$  Sorts the
   beginning of the array
6:    $high \leftarrow \text{QUICKSELECT}(x, N - k)$ ;  $\triangleright$  Sorts
   the ending of the array
7:   while  $x[start] < low$  or  $x[end] > high$  do
8:     if  $low > \tau \cdot \sigma$  then
9:        $\mu \leftarrow \text{UPDATEMEAN}(x[start], N, \mu)$ ;
10:       $\sigma \leftarrow \text{UPDATESSTD}(x[start], N, \sigma, \mu)$ ;
11:       $start \leftarrow start + 1$ ;
12:       $N \leftarrow N - 1$ ;
13:     else if  $high < \tau \cdot \sigma$  then
14:        $\mu \leftarrow \text{UPDATEMEAN}(x[end], N, \mu)$ ;
15:        $\sigma \leftarrow \text{UPDATESSTD}(x[end], N, \sigma, \mu)$ ;
16:        $end \leftarrow end - 1$ ;
17:        $N \leftarrow N - 1$ ;
18:     end if
19:   end while
20: end function
    
```



Fuente: Thompson (D. Sopic et al, 2017)

El algoritmo utilizado en la fig.9 se basa en el método de tau de Thompson, el cual permite extraer los valores atípicos o valores que no coinciden con el resto de los datos, donde se utiliza la modificación del valor τ con respecto al número de puntos de datos con respecto a la media de la muestra (\bar{x}) y la desviación estándar de x (J.M. Cimbala, Outliers. 2011), en la herramienta Matlab puede ser calculada con el comando “find_outliers_Thompson(x , *Alpha*, *método*, *pri*)” donde x es igual al conjunto de valores de muestreo, Alpha es el valor crítico comprendido de 0 a 0.5(de 0% a 50%) generalmente la herramienta utiliza un valor de 0.01(1%), el método corresponde si se desea predeterminado, media o robusto para valores de τ , y *pri* permite graficar los resultados obtenidos por la ecuación para *pri* =1(M. Rienzner. 2010).

C. Resultados experimentales

Los resultados obtenidos por G. Surrel et al (2018) se realizaron con la base de datos públicos de Physionet(<https://physionet.org/>), conocida como una de las mayores bases de datos de apnea grabadas por medio de ECG y puestas a disposición de todo público para estimular la investigación de instrumentos capaces de detectar los eventos del SAOS. Cuenta con más de 70 grabaciones de ECG proveniente de 32 sujetos con y sin SAOS, con una totalidad de 34.313 minutos grabados. Las grabaciones tienen un promedio de 8 horas de sueño y una oscilación de 6 a 9 horas por paciente, de esta base de datos el 62% está clasificada como apnea y si se evalúan en su totalidad las grabaciones existentes no podrán superar el porcentaje anterior.

Tabla 1. Grabaciones disponibles en Physionet.

Paciente	grabaciones	Paciente	grabaciones
1	a01, a14	17	b05,x11
2	a02,x14	18	c01, x35
3	a03, x19	19	c02, x35
4	a04, x12	20	c03, x04
5	a05,a10,a20, x07	21	c04, x29
6	a06, x15	22	c05, x33
7	a07,a16,x01, x30	23	c06
8	a08, a13, x20	24	c07, x34
9	a09, a18	25	c10,x18
10	a11	26	x02
11	a15, x27, x28	27	x06,x24
12	a17, x12	28	x09, x23
13	a19, x05, x08,x25	29	x10
14	b01,x03	30	x13,x26
15	b02,b03, x16, x21	31	x17, x22
16	b04, c08	32	x31, x32

Fuente: Goldberger AL et al, 2000


La tabla 1 agrupa las grabaciones disponibles por cada paciente en la base de datos disponible en PHysionet, donde se observar el número exacto de grabaciones correspondiente a cada uno de ellos, por ejemplo, para los pacientes 10, 23, 26 y 29 solo cuentan con 1 grabación a comparación de los pacientes 5, 7, 13 y 15 que cuentan con cuatro grabaciones cada. Por esta razón los pacientes del primer grupo (10, 23, 26 y 29) son descartados para el estudio ya que es necesario contar como mínimo con 2 grabaciones como lo estipula G. Surrel et al (2018), ya que la primera grabación es necesaria para el entrenamiento de la SVM, esto permite que el valor de la clasificación obtenida mejore considerablemente, en el estudio se considera al paciente 15 como sujeto principal ya que este posee 4 grabaciones en donde sus resultados son inferiores al 70% en la precisión de la clasificación, una vez realizado el entrenamiento de la SVM esta

alcanza un precisión de 88.2% o superior, esto quiere decir que agrega en promedio 20% en la clasificación de manera positiva, este proceso se repite con el resto de pacientes con un mínimo 2 grabaciones disponibles para el estudio. En el caso de un paciente ideal la clasificación alcanza un valor de 91.3% y sensibilidad de 89.2%, estos resultados se obtienen con las configuraciones establecidas por G. Moody et al (2000) del desafío de Physionet.

Tabla 2. EXACTITUD DE LA CLASIFICACIÓN Y MEJORAS RELATIVAS REPORTADAS (EN%) SOBRE LA BASE ESPECÍFICA PARTICULAR

Patient	1	2	3	4	5	6	7	8	9	11	12	13	14	15	16	17	18	19	20	21	22	24	25	27	28	30	31	32	Avg.	Std.	
<i>P.A.</i>	64	54	90	72	74	66	80	83	86	92	80	85	95	70	98	98	100	100	100	100	98	99	98	99	100	98	69	100	87	84	12
<i>P.S.-P.A.</i>	17	67	1	-2	6	11	-5	-1	5	-7	8	5	2	30	2	-0	0	0	0	2	1	1	0	0	-3	1	0	11	4	13	
<i>P.A.</i>	75	90	91	70	78	73	76	82	90	85	86	89	97	91	100	97	100	100	100	100	100	99	99	100	100	95	70	100	96	88	10
<i>P.S.</i>	1	0	1	32	4	14	5	4	-0	9	8	4	0	0	0	0	0	0	0	0	0	0	0	0	3	20	0	-0	3	7	
<i>P.I.-P.S.</i>	76	90	92	93	81	84	79	86	90	93	92	93	97	91	100	97	100	100	100	100	100	99	99	100	100	98	83	100	96	91	7

Fig. 10. Evolución de la precisión de la clasificación OSA



Fuente: G. Surrel et al (2018)


La tabla 2 contiene los resultados obtenidos por G. Surrel et al (2018) para cada paciente, exceptuando a los pacientes (10, 23, 26 y 29) por falta de grabaciones adicionales que permitan el entrenamiento de la SVM, esta tabla especifica los valores alcanzados en precisión para un clasificador independiente (PA), un clasificador específico (PS) y finalmente un clasificador específico para el paciente ideal (PI), “nuestra técnica de detección de OSA PS es un 3% menos precisa que el enfoque de PI. Aunque en muy pocos casos el rendimiento se degrada, ofreciendo mejoras significativas para la mayoría de los pacientes con precisión baja en un contexto de diagnóstico” (G. Surrel et al, 2018, p.9) ver Tabla II y Figura 10.

Los resultados alcanzados por el método de SVM en palabras de G. Surrel et al (2018) “Nuestro sistema tiene una precisión de clasificación del 88.2%, para una clasificación minuto a minuto, con una vida útil de la batería de 46.8 días”.

1.3.2 Detección del SAOS usando un clasificador Neuro-difuso para grabaciones de ECG

Este método es propuesto por el estudiante Soumya Gopal (2017), donde plantea utilizar el método neuro-difuso, que combina las redes neuronales y la lógica difusa para una mejor clasificación de las características en eventos de SAOS en el análisis de las señales proporcionadas por el ECG.

Fig. 11. Morfología del ECG con los intervalos RR y RQS



Fuente: S. Gopal (2017)

Este método es desarrollado con el fin de superar las falencias que presentan las SVM, ya que este descarta por completo a pacientes con antecedentes de enfermedades cardiacas por la dificultad adicional que estas agregan a la detección de los eventos de SAOS por las irregularidades en los latidos cardiacos, afectando el intervalo RR y a su vez la señal respiratoria derivada de ECG. En este método se observan los picos QRS para calcular el intervalo RR y la señal EDR para obtener información crucial de la respiración para los eventos de SAOS.

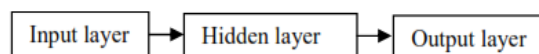
A. Extracción de las características

Para la extracción de las características se utilizan cálculos estadísticos del intervalo RR, como la media, desviación estándar, asimetría, entre otros; con el fin de reducir la selección de características insignificantes y reducir el riesgo de una mala detección en el proceso. Se tienen en cuenta los valores normalizados de las frecuencias muy bajas (VLF), frecuencias bajas (LF) y las frecuencias altas (HF) del intervalo RR y la señal EDR., donde la selección de características se lleva a cabo durante una prueba *t*, donde *t* es utilizado para obtener las características de hipótesis citando los estudios realizados por Mendez MO. et al (2009).

B. Clasificación

S. Gopal (2017), aclara que el clasificador Neuro-Fuzzy o neuro difuso “es una combinación de red neuronal y lógica difusa. Aquí el sistema difuso utiliza el algoritmo de aprendizaje derivado de la red neuronal para determinar los parámetros (es decir, conjunto difuso, reglas difusas) mediante el procesamiento de la muestra de datos”.

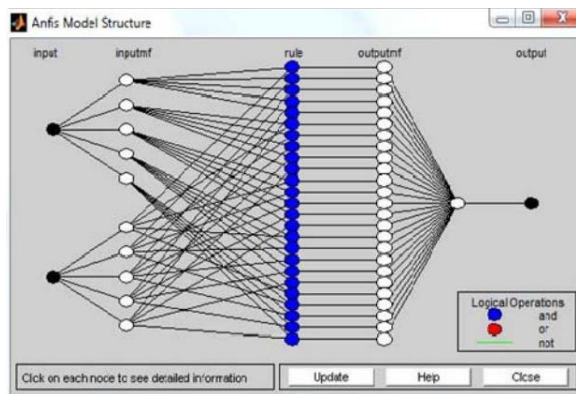
Fig. 12. Diagrama de bloques del clasificador por neuro-difuso



Fuente: S. Gopal (2017)

El clasificado posee una capa de entrada: encargada del ingreso de las características obtenidas del intervalo RR, una capa oculta: conformada por el conglomerado de reglas difusas y finalmente la capa de salida donde se muestran los resultados deseados.

Fig. 13. Vista de Matlab del clasificador neuro-difuso



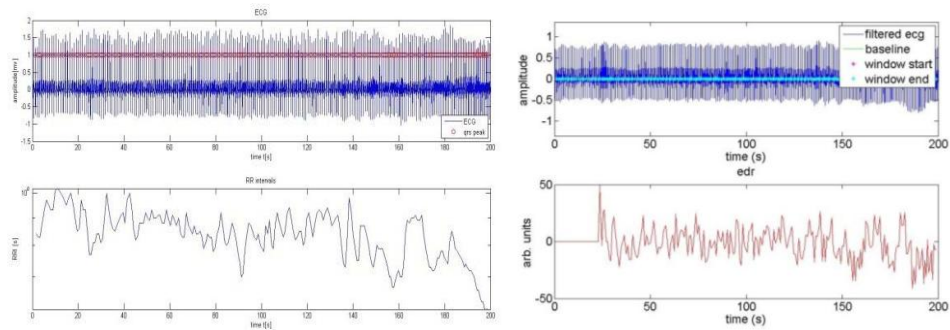
Fuente: S. Gopal (2017)

Como se puede observar en la figura 13 la red neuronal está compuesta por 5 capas, la capa pasiva (capa 0), capa función de membresía (capa 1), capa de regla (capa 2), capa de norma (capa 3) y finalmente la capa de salida (capa 4). En la capa 0 se ingresan las características como entradas al sistema, la capa 1 o capa función de membresía es utilizada para la representación de los conjuntos difusos donde cada punto en el espacio recibe un valor o grado de pertenencia, capa 2 o capa de regla es la encargada de las condiciones del sistema para la selección de caracteres, capa 3 o capa de norma encargada de la comparación de máximos y mínimos de los caracteres utilizados, capa 4 o capa de salida es determinada por el total o conjunto de salida de la capa anterior y presenta los resultado obtenidos (J. S. Toro, 2007).

C. Resultados experimentales


Los resultados obtenidos utilizando la red neuronal por clasificación difusa se pueden apreciar claramente en la figura 13, donde los datos aportados por el ECG permiten la identificación del intervalo RR y extracción de la señal EDR, los experimentos para evaluar la efectividad del clasificador se realizaron con la base de datos públicos de Physionet al igual que el método anterior.

Fig. 14. Vista de Matlab la salida del intervalo RR y EDR obtenidas del ECG



Fuente: S. Gopal (2017)

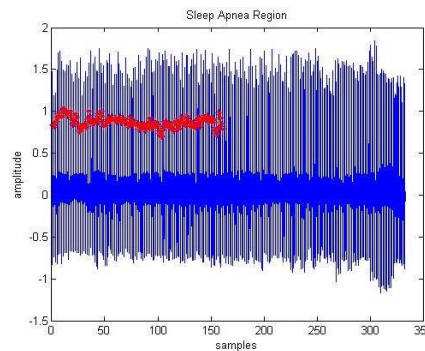
Fig. 15. Graficas de las características representativas de SAOS



Fuente: S. Gopal (2017)

En la figura 15 se muestran las características seleccionadas de las señales ECG y EDR de la figura 14, donde se presentan episodios de SAOS, siendo un total de 31 eventos registrados con un valor máximo de 0.27 para P , donde P es el valor confidencial de los cálculos estadísticos y en la figura 16 se muestra la gráfica de la zona donde se presenta los eventos con relación a su amplitud y numero de muestras obtenidas.

Fig. 16. Grafica de la salida del clasificador neuro-difuso



Fuente: S. Gopal (2017)

Para el cálculo de los porcentajes obtenidos por el sistema S. Gopal (2017) utiliza una matriz de confusión la cual permite extraer los siguientes parámetros del sistema como: la exactitud, TP (casos positivos clasificados correctamente), FP (casos falsos clasificados como positivos), TN (casos negativos que se clasificaron correctamente), FN (casos positivos clasificados incorrectamente como negativos) y la precisión.

Tabla 2. Matriz de confusión

Output Class	0	5 62.5%	1 12.5%	83.3% 16.7%
	1	0 0.0%	2 25.0%	100% 0.0%
		100% 0.0%	66.7% 33.3%	87.5% 12.5%
		0	1	
		Target Class		

Fuente: S. Gopal (2017)


Los resultados arrojados por la matriz de confusión indican que los valores alcanzados para la exactitud y la sensibilidad es de 100% y una especificidad de 83.3% y para los falsos positivos (FP) un valor del 16%, dando como resultado una precisión del 87.5 % en la clasificación general con un margen de error de 12.5%. La red neuronal permite separar adecuadamente los casos en donde la información es insuficiente de manera automáticamente.

1.3.3 Otras tecnologías aplicadas a las WBSN

Además de las técnicas mencionadas en la sección 1.3.1 y 1.3.2 existen dos investigaciones prometedoras para la WBSN que permitirán avanzar circunstancialmente en el estudio y control del SAOS.

La primera de ellas es desarrollada por Y. Sun, J. Tao, G. Wu y X. Yu (2013) donde proponen el desarrollo de una WBSN sin contacto con la capacidad de detectar múltiples señales vitales a una distancia máxima de la piel de 30 mm y compatible con el estándar 802.15.1 (Bluetooth) y 802.11(WiFi) de la IEEE.


Fig. 17. Diagrama de bloque de la parte frontal análoga



Fuente: Y. Sun et al (2013)

Como segunda pero no menos importante está el trabajo realizado por L. Wang et al (2010), donde describe el desarrollo de un sistema de interfaz de sensor inalámbrico biométrico directamente en un circuito integrado y que tiene como objetivo combinar muchas de las funciones que poseen los microsistemas de BSN sobre esta plataforma, con una capacidad de hasta 8 canales biométricos.

Fig. 18. Micrografía del sistema fabricado en el circuito integrado que muestra los bloques del sistema.



Fuente: L. Wang et al (2010)

2. CONCLUSIONES

El síndrome de apnea obstructiva del sueño (SAOS), es una enfermedad ligada al desarrollo de afecciones del sistema cardiovascular y respiratorio, reduciendo en gran medida la calidad de vida de las personas que la padecen, en Colombia se desconoce el número de personas que son afectadas por esta enfermedad, ya que el sistema de salud es precario y solo un pequeño porcentaje de las personas son diagnosticadas a tiempo y los controles implementados son deficientes por los altos costos de los equipos necesarios para la monitorización continua.

Al implementar dispositivos basados en los métodos presentados en este artículo se puede mejorar significativamente el número de pacientes a diagnosticar, el dispositivo y método propuesto por G. Surrel et al (2018) con una batería de hasta 46 días de vida útil y una precisión del 88.2% permite una recolección de datos casi de manera interrumpida para el control y monitoreo de los pacientes que padecen de SAOS y superando las limitaciones de los dispositivos utilizados en Polisomnografía de nivel 3.

El método planteado por S. Gopal (2017) con clasificador neuro difuso para la selección de las características alcanza 87,5% en su efectividad al momento de diagnosticar el SAOS, siendo inferior al método utilizado por G. Surrel et al (2018) en un 0.7%. Pero gracias a la implementación de la red neuronal este método posee una eficiencia de cómputo superior lo que reduce el tiempo de diagnóstico de la enfermedad y permite descartar automáticamente los pacientes con un número inferior al necesario para realizar el diagnóstico.

Por otro lado, las investigaciones realizadas por Y. Sun et al (2013) que permiten captar las señales biométricas con el mínimo contacto y la miniaturización de estos dispositivos propuestos por L. Wang et al (2010), darán paso a dispositivos cada vez más pequeños y menos invasivos y con diagnósticos más precisos.

Los métodos propuestos por G. Surrel et al (2018) y S. Gopal (2017) no cumplen con los parámetros establecidos por P. De Chazal et al (2003) para dispositivos autónomos con precisión superior de 90%, esto indica que en ambos dispositivos los resultados arrojados deben ser examinados por un profesional capacitado para confirmar el diagnóstico alcanzado por los dispositivos.

Con todo lo visto anteriormente se puede proyectar la integración de estos métodos en dispositivos portátiles como smartwatch (relojes inteligentes) y rastreadores fitness en los próximos años, ya que por lo general posee un oxímetro y fotopletismógrafo que integrados pueden permitir el control del SAOS en una APP que transmite en tiempo real el estado del paciente, evitando la incomodidad generada por múltiples dispositivos y cableado.

Tabla 3. TABLA DE VENTAJAS Y DESVENTAJAS

Método de clasificación	Ventajas	Desventajas
<p style="text-align: center;">SVM (máquina de vector de soporte)</p>	<ul style="list-style-type: none"> • Alto rendimiento y bajo consumo energético. • Tiempo de grabación continuo hasta 46 días. • Valor de clasificación de 88.2%%. • Fácil implementación • El método ya posee un dispositivo con parámetros establecidos de hardware, donde se realizaron los resultados obtenidos durante la investigación de G. Surrel et al, 2016 	<ul style="list-style-type: none"> • Se presentan problemas de clasificación en pacientes con antecedentes cardiacos. • La clasificación de pacientes que cumplen con el numero eventos necesarios debe realizarse de forma manual • La sensibilidad del dispositivo es de 89.2% lo que quiere decir que algunos eventos son clasificados erróneamente. • El valor de la clasificación del método es inferior 90%, clasificándolo como un método no autónomo según los parámetro establecidos por por P. De Chazal et al (2003)
<p style="text-align: center;">Neuro-Fussy</p>	<ul style="list-style-type: none"> • Este método permite que pacientes con antecedentes de enfermedades cardiacas puedan ser diagnosticados sin que sus afecciones afecten los resultados. • En los resultados obtenidos el método de clasificación posee una sensibilidad de 100% esto quiere decir que la prueba es totalmente 	<ul style="list-style-type: none"> • El costo económico es superior al de las SVM. • El método de clasificación no se ha implementado en un dispositivo móviles y los resultados experimentales se obtuvieron por medio de simulación de la herramienta MatLAB. • El valor de la clasificación del método es inferior 90%,

	confiable en el diagnóstico del SAOS.	clasificándolo como un método no autónomo según los parámetros establecidos por P. De Chazal et al (2003)
--	---------------------------------------	---

3. REFERENCIAS

1. Ministerio de salud (2015). Estrategia para la prevención y control de las enfermedades respiratorias crónicas. *Convenio 519 de 2015*, 36-38.
2. Young, T., Palta, M., Dempsey, J., Peppard, P. E., Nieto, F. J., & Hla, K. M. (2009). Burden of sleep apnea: rationale, design, and major findings of the Wisconsin Sleep Cohort study. *WMJ: official publication of the State Medical Society of Wisconsin*, 108(5), 246.
3. Young, T., Peppard, P., Palta, M., Hla, K. M., Finn, L., Morgan, B., & Skatrud, J. (1997). Population-based study of sleep-disordered breathing as a risk factor for hypertension. *Archives of internal medicine*, 157(15), 1746-1752.
4. Sánchez Armengol, A., Carmona Bernal, C., & Ruiz García, A. P. (2009). poligrafía, oximetría. Requisitos e interpretación de resultados. Manual de diagnóstico y terapéutica en Neumología (2ª edición). ERGON, Majadahonda (Madrid).
5. Francisco R. (2013). Técnicas de diseño de redes inalámbricas de sensores corporales inteligentes y energéticamente eficientes. Departamento de arquitectura de computadoras y automática. *Facultad de informática - Universidad complutense de Madrid*
6. Sopic, D., Aminifar, A., Aminifar, A., & Atienza, D. (2017, October). Real-time classification technique for early detection and prevention of myocardial infarction on wearable devices. In *Biomedical Circuits and Systems Conference (BioCAS), 2017 IEEE* (pp. 1-4). IEEE. E. D.
7. Giovanni, A. Aminifar, A. Luca, SYaxdani, J. M. Vesin and D. Atieza. (2017) "A patient-specific methodology for prediction of paroxysmal atrial fibrillation onset" in Proc. Comput. Cardiology. 1-4
8. Surrel, G., Aminifar, A., Rincón, F., Murali, S., & Atienza, D. (2018). Online Obstructive Sleep Apnea Detection on Medical Wearable Sensors. *IEEE Transactions on Biomedical Circuits and Systems*, (99), 1-12.
9. G. Surrel, F. Rincon, S. Murali and D. Atienza. (2016) "Low-power wearable system for real-time screening of obstructive sleep apnea". IEEE VLSI (ISVLSI). 230-235
10. Adrados, M. R. P. (2002). Aportación de la polisomnografía en el diagnóstico y en el tratamiento del Síndrome de apnea obstructiva del sueño (Doctoral dissertation, Universidad Complutense de Madrid).
11. Ashley, E. A., & Niebauer, J. (2004). *Cardiology explained*. Remedica.
12. De Chazal, P., Heneghan, C., Sheridan, E., Reilly, R., Nolan, P., & O'Malley, M. (2003). Automated processing of the single-lead electrocardiogram for the detection of obstructive sleep apnoea. *IEEE Transactions on Biomedical Engineering*, 50(6), 686-696.
13. Penzel, T., McNames, J., De Chazal, P., Raymond, B., Murray, A., & Moody, G. (2002). Systematic comparison of different algorithms for apnoea detection based on electrocardiogram recordings. *Medical and Biological*

Engineering and Computing, 40(4), 402-407.

14. Hsu, C. W., Chang, C. C., & Lin, C. J. (2003). A practical guide to support vector classification.
15. Xie, B., & Minn, H. (2012). Real-time sleep apnea detection by classifier combination. *IEEE Transactions on Information Technology in Biomedicine*, 16(3), 469-477.
16. Goldberger AL, Amaral LAN, Glass L, Hausdorff JM, Ivanov PCh, Mark RG, Mietus JE, Moody GB, Peng C-K, Stanley HE. PhysioBank, PhysioToolkit, and PhysioNet: Components of a New Research Resource for Complex Physiologic Signals. *Circulation* 101(23): e215-e220 [*Circulation Electronic Pages*; <http://circ.ahajournals.org/content/101/23/e215.full>]; 2000 (June 13).
17. Moody, G. B., Mark, R. G., Goldberger, A., & Penzel, T. (2000). Stimulating rapid research advances via focused competition: The Computers in Cardiology Challenge 2000. In *Computers in Cardiology 2000* (pp. 207-210). IEEE.
18. Gopal, S., & Devi, T. A. (2017, July). Obstructive sleep apnea detection from ECG signal using neuro-fuzzy classifier. In *Intelligent Computing, Instrumentation and Control Technologies (ICICICT), 2017 International Conference on* (pp. 910-915). IEEE.
19. Mendez, M. O., Bianchi, A. M., Matteucci, M., Cerutti, S., & Penzel, T. (2009). Sleep apnea screening by autoregressive models from a single ECG lead. *IEEE transactions on biomedical engineering*, 56(12), 2838-2850.
20. Sun, Y., Tao, J., Wu, G., & Yu, X. (2013, November). A non-contact wearable wireless body sensor network for multiple vital signal detection. In *SENSORS, 2013 IEEE* (pp. 1-4). IEEE.
21. Atanassov, R., Bose, P., Couture, M., Maheshwari, A., Morin, P., Paquette, M., ... & Wuhrer, S. (2009). Algorithms for optimal outlier removal. *Journal of discrete algorithms*, 7(2), 239-248.
22. Dubois-Ferriere, H., Meier, R., Fabre, L., & Metrailler, P. (2006, April). TinyNode: a comprehensive platform for wireless sensor network applications. In *2006 5th International Conference on Information Processing in Sensor Networks* (pp. 358-365). IEEE.
23. Jea, D., & Srivastava, M. B. (2005). Channels characteristics for on-body mica2dot wireless sensor networks. In *IEEE International Conference on Mobile and Ubiquitous Systems (MobiQuitous)*.
24. Otto, C., Milenkovic, A., Sanders, C., & Jovanov, E. (2006). System architecture of a wireless body area sensor network for ubiquitous health monitoring. *Journal of mobile multimedia*, 1(4), 307-326.
25. M. Rienzner, "Find Outliers with Thompson Tau," 2010. [Online]. Available: https://www.mathworks.com/matlabcentral/fileexchange/27553-find-outliers-with-thompson-tau/content/find_outliers_Thompson.m
26. J.M. Cimbala, Outliers. (2011) <https://www.mne.psu.edu/cimbala/me345/Lectures/Outliers.pdf>
27. Physionet database: <https://physionet.org/>