

## Análisis de Textura para la detección del Síndrome de Apnea Nocturna

L.B. Contreras-Chávez<sup>1</sup>, G. Guerrero-Mora<sup>1</sup>, M.O. Méndez<sup>1</sup>, E.R. Palacios-Hernández<sup>1</sup>, A. Alba-Cadena, J. Kortelainen<sup>2</sup>

<sup>1</sup>Facultad de Ciencias, Universidad Autónoma de San Luis Potosí, San Luis Potosí, México

<sup>2</sup>VTT, Tampere, Finlandia

**Resumen**— La apnea es un problema mundial que afecta a casi el 4% de la población y que tiene implicaciones en ámbitos tanto sociales como fisiológicos. En este trabajo se presenta un algoritmo para la detección del síndrome de apnea-hipopnea del sueño (SAHS) basada en la señal respiratoria tomada de los registros polisomnográficos y de un colchón sensorizado de 10 pacientes, siguiendo los protocolos bioéticos para la investigación con seres humanos. El algoritmo utiliza la transformada wavelet y el análisis de textura para la extracción de rasgos en ventanas de 2 minutos. Estos rasgos son usados como entradas a clasificadores lineales y cuadráticos para discriminar entre ventanas con apnea y no-apnea. Los resultados muestran un nivel de exactitud de aproximadamente 90% para la señal de flujo, mientras que para la señal del colchón fue de cerca de 74%. Estos resultados sugieren que el análisis de textura es una buena herramienta en la extracción de rasgos para la detección de SAHS, y el colchón parece ser un método prometedor para el diagnóstico de este trastorno del sueño en forma indirecta.

**Palabras clave**— Sueño, flujo respiratorio, medición no invasiva.

### I. INTRODUCCIÓN

Actualmente, la evaluación del sueño ha tomado relevancia debido al considerable número de patologías del sueño que afectan de forma significativa la salud, física, mental y emocional de los individuos. Específicamente, el síndrome de apnea-hipopnea del sueño (SAHS) ha llamado la atención por su impacto en la salud del paciente y su elevada prevalencia en adultos (2% de las mujeres y 4% de los hombres [1]). El SAHS es un trastorno respiratorio caracterizado por la aparición de apneas e hipopneas de manera intermitente o cíclica durante el sueño. De acuerdo a la *American Academy of Sleep medicine* (AASM), una apnea, se define como la ausencia del flujo respiratorio por un periodo mínimo de 10 segundos, las hipopneas por su parte se definen como una reducción en la amplitud del flujo respiratorio con una duración mínima de 10 segundos y que provoque una caída en la saturación de oxígeno en la sangre  $\geq 3\%$  [2]. Estos eventos (apneas e hipopneas) pueden ser provocados por una obstrucción de la vía aérea superior, en cuyo caso se denominan obstructivas, o como resultado de una disfunción en el sistema nervioso central que provoca la inhibición transitoria del impulso respiratorio, denominadas centrales. Existen además los eventos mixtos, que presenta la combinación del factor obstructivo y el factor central, aunque estos no son muy frecuentes.

El principal síntoma del SAHS es la hipersomnolencia diurna, acompañada por dolores de cabeza matutinos, causados por la baja oxigenación del cerebro. La hipersomnolencia puede incrementar el riesgo de accidentes de tráfico y laborales. Otras consecuencias del SAHS son: fatiga, deterioro intelectual, problemas de memorización, depresión, entre otras. Además, el SAHS se relaciona con enfermedades de salud graves como la diabetes, la hipertensión y enfermedades cardiovasculares [3].

Para el diagnóstico de este y otros trastornos del sueño, se lleva a cabo un estudio denominado polisomnografía (PSG) nocturna. La PSG consiste en el registro continuo durante una noche de sueño de diversas variables fisiológicas como: la respiración, la actividad cerebral, muscular, cardíaca, la saturación de oxígeno en la sangre, entre otras. Los registros son manualmente analizados por un técnico experto para identificar las etapas del sueño y los eventos respiratorios.

A pesar de ser un método preciso, la PSG es un estudio caro y técnicamente complejo, dado que se requiere de infraestructura, equipo especializado, y personal capacitado. Por lo anterior, la PSG no está al alcance de todos los centros clínicos y debido a la gran demanda, existen grandes listas de espera [4]. Aunado a esto, la cantidad de sensores que se necesita colocar al paciente afectan los patrones normales de sueño, además de que limitan su movilidad y existe el riesgo de desconexión de alguno de ellos.

Debido a esto, han surgido equipos portátiles que proponen el diagnóstico del SAHS a través de una cantidad reducida de variables como la respiración, la variabilidad de la frecuencia cardíaca, etc, que pueden ser medidas de manera directa o indirecta [5][6][7].

En el presente trabajo se propone la comparación entre la señal respiratoria derivada de un colchón sensorizado [8] y la señal de flujo respiratorio para evaluar la factibilidad del diagnóstico del SAHS mediante la señal obtenida del colchón.

### II. METODOLOGÍA

#### A. Protocolo Clínico

En el hospital universitario de Tampere, Finlandia, se obtuvieron los registros de 10 pacientes con sospechas de SAHS mediante un estudio del sueño realizado a cada paciente. Las edades de los pacientes oscilan entre 48 y 64 años. Los registros incluyen los canales de una PSG completa, además de los obtenidos simultáneamente mediante el colchón sensorizado. Mediante el software RemLogic (Embla

systems LLC) los registros de la PSG fueron utilizados para llevar a cabo un análisis respiratorio para cada paciente. Los resultados de este análisis fueron posteriormente validados por un experto, y usados para finalmente diagnosticar o descartar la presencia de SAHS. En este estudio se utilizó la señal de flujo respiratorio muestreada a 5 Hz.

B. Colchón sensorizado

A través de sensores de presión este dispositivo mide los cambios de presión provocados por las variaciones en flujo de aire que entra y sale de los pulmones, lo cual proporciona una medición indirecta del esfuerzo respiratorio. El dispositivo incorpora 8 sensores de presión en un colchón de hule espuma. Los sensores son colocados en una matriz de 4 x 2, resultando un área total de 64 x 64 cm, que es finalmente cubierta con tela higiénica. Las dimensiones finales del dispositivo son de 100 x 72 cm y 2 cm de grosor, cuando no está comprimido. Con estas dimensiones el dispositivo cubre la región del torso del paciente. La señal de los 8 sensores son muestreadas a 50hz, las cuales son procesadas para obtener características como: respiración, pulso cardiaco y movimiento del sujeto.

C. Análisis de Wavelets

El análisis wavelets descompone una señal utilizando diferentes versiones de una wavelet madre la cual es escalada y trasladada en el tiempo [9]. En general la descomposición se realiza mediante:

$$WT(\tau, a) = \frac{1}{a} \int x(t)g^* \left( \frac{t-\tau}{a} \right) dt \tag{1}$$

donde  $g(t)$  es la wavelet madre, \* denota complejo conjugado,  $a$  es el factor de escala y  $\tau$  es el corrimiento en el tiempo. Tomando en consideración la forma de la señal que se debe procesar, en este estudio se utilizó la wavelet *sombrero mexicano*.

D. Análisis de Textura

El análisis de textura es una herramienta utilizada en diferentes áreas del procesamiento de imágenes que ayuda a cuantificar la variación de tono con respecto de la ubicación espacial en una imagen. Las variables de textura de una imagen  $I(x,y)$  de nivel de grises se basan en la matriz de co-ocurrencia  $G$ . El elemento  $G(i,j)$  representa el número de veces que una pareja de pixeles ocurre dentro de una

ventana en  $I(x,y)$ . Por ejemplo, dada la imagen siguiente de dimensión 6x6 y con 8 niveles de grises:

0	1	5	5	2	0
3	6	3	0	7	6
7	7	5	7	0	1
3	2	6	3	1	7
6	3	5	3	5	1
4	7	6	3	5	4

La matriz de co-ocurrencia se obtiene utilizando la convención  $0 \leq (i, j) < L$ , en donde cada elemento corresponde a la ocurrencia que un nivel  $i$  ocurre junto con el nivel  $j$  de la izquierda. Por ejemplo dado que el valor 6 aparece a la izquierda del valor 3 en la imagen original 4 veces, el valor  $G(6,3)$  es igual a 4 [10].

La matriz de co-ocurrencia se puede normalizar de la siguiente manera:

$$Ng(i, j) = \frac{G(i, j)}{\sum_i \sum_j G(i, j)} \tag{2}$$

Donde  $Ng$  es la matriz de co-ocurrencia normalizada. De este modo,  $Ng(i,j)$  puede verse como la probabilidad que una pareja de valores se repita en la matriz. A partir de  $Ng$  se pueden calcular diferente índices como:

$$energía = \sum_i \sum_j |Ng(i, j)| \tag{3}$$

$$contraste = \sum_i \sum_j Ng(i, j)(i - j)^2 \tag{4}$$

$$homogeneidad = \frac{\sum_i \sum_j Ng(i, j)}{1+(i-j)^2} \tag{5}$$

$$disimilaridad = \sum_i \sum_j Ng(i, j)|i - j| \tag{6}$$

$$segundo\ momento\ angular = \sum_i \sum_j Ng(i, j)^2 \tag{7}$$

$$correlación = \sum_i \sum_j Ng(i, j) \left[ \frac{(i-\mu_i)(j-\mu_j)}{\sqrt{(\sigma_i^2)(\sigma_j^2)}} \right] \tag{8}$$

Donde  $\mu_i, \mu_j$  son las medias y  $\sigma_i, \sigma_j$  son las desviaciones estándar de la suma de filas y columnas  $Ng(i)$  y  $Ng(j)$  definidas por

$$Ng(i) = \sum_i Ng(i) \tag{9}$$

$$Ng(j) = \sum_j Ng(j) \tag{10}$$

Note que es posible calcular la matriz de co-ocurrencia para pixeles distantes.

E. Discriminador Lineal y Cuadrático

El discriminador lineal (LD) y cuadrático (QD) son clasificadores que dividen un espacio de características en  $M$  regiones (número de clases), minimizando el error de probabilidad basado en la regla de máxima verosimilitud [11]. Si asumimos que la matriz de covarianza es igual para todas las clases,  $C_m = C \forall m$  entonces, la función de discriminación lineal está dada por:

$$LD_M(X) = x^T C^{-1} \mu_m - \frac{1}{2} \mu_m^T C^{-1} \mu_m + \log(\pi_m) \quad (11)$$

donde,  $x_i$  es el vector de características y :

- $\hat{\pi}_m = \frac{N_m}{N}$ ,  $N_m$  es el número de observaciones de la clase  $m$ .
- $\hat{\mu}_m = \sum_{i=m} \frac{x_i}{N_m}$
- $\hat{C} = \frac{\sum_{m=1}^M \sum_{g=m} \frac{(x_i - \hat{\mu}_m)(x_i - \hat{\mu}_m)^T}{N - M}}$

Si asumimos que las verosimilitudes no son iguales, obtenemos la función cuadrática descrita por:

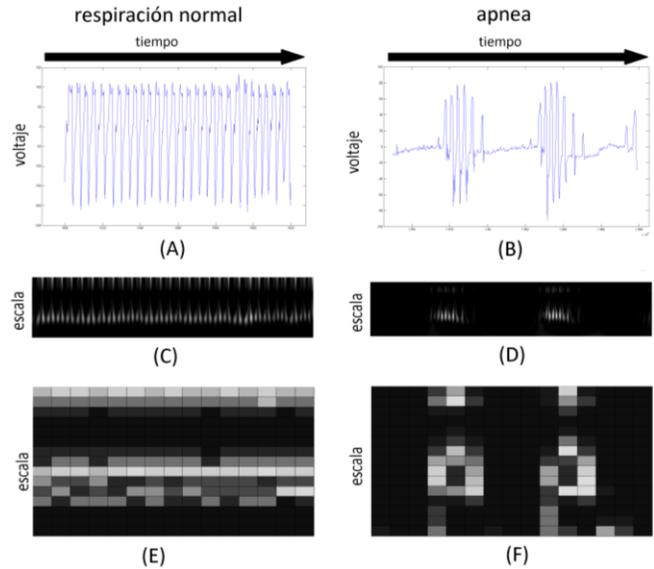
$$QD_M(X) = -\frac{1}{2} \log|C_m| - \frac{1}{2} (x - \mu_m)^T C_m^{-1} (x - \mu_m) + \log(\pi_m) \quad (12)$$

#### F. Procesamiento

Las señales  $x_1(n)$  y  $x_2(n)$  (flujo respiratorio y movimiento respiratorio obtenido del colchón, respectivamente), se segmentaron en ventanas de 2 minutos (ver Fig. 1, A y B), las cuales se normalizaron con respecto a su valor máximo. Dado que la detección de la apnea es por eventos, las ventanas fueron etiquetadas como apnea si al menos ocurría un evento de apnea o hipopnea dentro de ellas. Cada ventana fue descompuesta en sus componentes tiempo-escala utilizando la transformada Wavelet, como se muestra en la Fig. 1 (C y D). La transformación es utilizada como una imagen para realizar el análisis de textura. Sin embargo, para reducir el costo computacional, la resolución de la imagen se redujo a 16 niveles de grises y también se tomó una menor resolución tiempo-escala para obtener una imagen de 16x16 (Fig. 1 E y F). De esta imagen, se calculó la matriz de co-ocurrencia y finalmente se calcularon los índices de textura definidos en la sección D.

#### G. Clasificación

La base de datos para la clasificación contiene los índices de textura y las clases de apnea (593 ventanas) y no apnea (1549 ventanas). Esta base de datos se dividió en dos grupos, entrenamiento y prueba. El grupo de entrenamiento consistió en el 50% de las ventanas con apnea y no apnea, mientras que el otro 50% restante de ventanas se utilizó como prueba. Todos los índices fueron utilizados como entradas para los clasificadores lineal y cuadrático. Finalmente, se obtuvo la exactitud de cada clasificador



tanto para los índices de textura calculados de la señal de flujo como de la señal del colchón.

Fig. 1. Ejemplo de la señal de flujo respiratorio durante respiración normal y durante apnea. A y B señal de flujo, C y D descomposición wavelet con sobrero mexicano y, E y F imágenes utilizadas para cálculo de textura basadas en las C y D.

### III. RESULTADOS

En la Fig. 2 se muestra un ejemplo de clasificación entre apnea y no apnea utilizando un discriminante lineal y los rasgos correlación y contraste. La Fig. 2A muestra la gráfica de dispersión y la línea de separación entre clases para la señal del flujo respiratorio. Se observa que existe un bajo nivel de traslape entre las clases utilizando la señal de flujo respiratorio, lo cual conlleva a una buena separabilidad. La Fig. 2B muestra la gráfica de dispersión para la señal del colchón. Se observa un mayor nivel de traslape, lo cual produce un bajo desempeño del clasificador. Debido a limitaciones de espacio, los resultados del clasificador cuadrático no son presentados.

La Tabla I muestra los valores de exactitud obtenidos de la clasificación con los rasgos calculados a partir de la señal de flujo respiratorio y la señal del colchón. Como se puede observar el nivel de exactitud en el caso de la señal de flujo es de aproximadamente 90%, mientras que de la señal del colchón alcanza una exactitud máxima del 74%.

Tabla I. Media del desempeño de los clasificadores lineal y cuadrático en la separación de eventos de apnea y no apnea.

	Flujo	Colchón
--	-------	---------

Lineal	89.43	74.02
Cuadrático	88.68	72.70

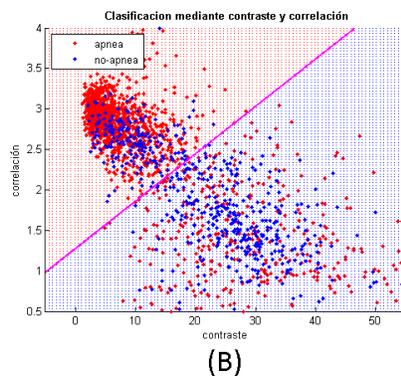
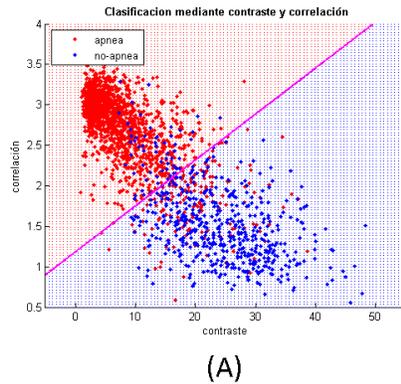


Fig. 2. Ejemplo típico de clasificación lineal entre apnea y no apnea en dos dimensiones. A) Rasgos extraídos de la señal de flujo respiratorio y B) Rasgos extraídos de la señal del colchón.

#### IV. DISCUSIÓN Y CONCLUSIÓN

En el presente trabajo se evaluó el nivel de detección de que tienen los rasgos obtenidos del flujo respiratorio y de un colchón sensorizado. Los rasgos fueron obtenidos a partir del análisis de textura de las transformadas wavelet de las señales y éstos fueron utilizados en clasificadores lineales y cuadráticos. Nuestras principales observaciones son: a) el análisis de textura parece ser una herramienta útil para obtener rasgos para la detección de la apnea y b) la señal del colchón contiene información relevante para la detección de la apnea en forma indirecta.

El análisis de textura presenta características de fácil implementación y bajo costo computacional. Además, los rasgos obtenidos del análisis de textura contienen mucha información relevante para la detección de la apnea. Tal que con un número muy reducido de rasgos ( $< 7$ ) es posible hacer una buena clasificación. Esto conlleva a mitigar el problema de la “maldición de la dimensionalidad” y a poder utilizar clasificadores simples como los propuestos en este trabajo sin sacrificar el nivel de separación.

El nivel de clasificación utilizando la señal del colchón parece ser muy bajo, esto se debe dos factores principales. Por una parte, las hipopneas presentan una reducción en el

flujo respiratorio que al parecer no es fácil detectar con los sensores de presión del colchón. Por otra parte, las apneas de tipo obstructivo eliminan el flujo respiratorio pero los movimientos mecánicos de la respiración se incrementan debido al esfuerzo realizado por los sujetos para reanudar la respiración y poder obtener el oxígeno necesario para la sobrevivencia. Sin embargo, el colchón ofrece una alternativa, económica, no invasiva, no obstructiva, de fácil manejo y sin necesidad de un experto que coloque electrodos u otros sensores al paciente una buena alternativa para realizar evaluaciones del SAHS en ambientes no hospitalarios.

Las principales limitaciones de este estudio son el reducido número de sujetos y la falta de un análisis para la selección de parámetros que podrían optimizar el desempeño del algoritmo como el tamaño de ventana óptimo para incrementar la resolución temporal del análisis, además de la implementación de algoritmos de clasificación.

#### BIBLIOGRAFÍA

- [1]. Young T, Peppard PE, Gottlieb DJ. Epidemiology of obstructive sleep apnea: a population health perspective. *American journal of respiratory and critical care medicine*, 2002; 165(9): 1217-1239.
- [2]. The report of an American Academy of Sleep Medicine task force. *Sleep-Related Breathing Disorders in adults: Recommendations for Syndrome Definition and Measurement Techniques in Clinical Research*, Sleep, 1999; 22(5): 667-689.
- [3]. Douglas T, Floras JS. Sleep Apnea and Heart Failure, Part I: Obstructive Sleep Apnea, *Circulation*, 2003; 107:1671-1678
- [4]. Douglas, T. y Jhon S. Floras (2003), Sleep Apnea and Heart Failure, Part I: Obstructive Sleep Apnea, *Circulation*, vol.107, pp. 1671-1678.
- [5]. Park, S. y S. Jayaran(2003). Enhancing the quality of life through wearable technology, *IEEE Engineering in Medicine and Biology Magazine*, vol. 22, pp.41-48.
- [6]. Conor Heneghan, Chern-Pin Chua, John F. Garvey, MB, Philip de Chazal, Redmond Shoultice, Patricia Boyle, BS3; Walter T. McNichola (2008). A portable Automated Assessment Toll for Sleep Apnea Using a combined Holter-Oximeter, *SLEEP*, vol. 31, No. 10, pp.1432-1439.
- [7]. Anliker, U, J.A. Ward, P. Lokowicz, G. Troster, F. Dolveck, M. Baer, F.Keita, E.B. Schenker, F. Catarsi, L. Coluccini, A. Belardinelli, D. Shklarsky, A. Menachem, E. Hirt, R. Schmith, and M. Vuskovic (2004). Amon: A wearable multiparameter medical monitoring and alert system. *IEEE Trans. Information Technology in Biomedicine*, vol. 8, pp.415-427.
- [8]. Kortelainen J. M., van Gils M., Pärkkä J.(2012). Multichannel Bed Pressure Sensor for Sleep monitoring. In *Proceedings of Computing in Cardiology*, Krakow, Poland.
- [9]. Torrence C and Campo G P 1998 A practical guide to wavelet analysis *Bull. Am. Meteorol. Soc.* **79** 61-78
- [10]. M. Petrou, P. Garcia, *Image processing: dealing with texture*, Wiley & sons, 1ed, 2006.
- [11]. T. Hastie, R. Tibshirani, J. Friedman, *The elements of statistical learning: data mining, inference and prediction*, Springer, 2ed, 2009.