

Clasificación de las fases y la calidad del sueño en señales de electroencefalografía (EEG)

Perdomo Yesid

Resumen—El sueño es un proceso biológico de reposo, en el cual se llevan a cabo funciones importantes para el cuerpo como consolidación de la memoria, crecimiento y reparación. El monitoreo del sueño, resulta de gran relevancia a nivel clínico, ya que la aparición de desórdenes del sueño ha aumentado drásticamente. En este proyecto se implementaron y compararon diferentes métodos de clasificación automática de etapas de sueño, a partir de las señales EEG. Además, se analizó la calidad del sueño obtenida a partir de las señales EEG y se comparó con respecto a aplicaciones en dispositivos móviles. Se obtuvieron resultados de la clasificación aceptables (80 % de exactitud). Con esta información, fue posible analizar la calidad del sueño y compararla con aplicaciones móviles.

Index Terms—Aprendizaje de máquina, Procesamiento de Señales, Señales EEG, Sueño, dispositivos móviles.

I. INTRODUCCIÓN

Los procesos biológicos son aquellos que permiten que el organismo pueda vivir. El sueño es un proceso biológico de reposo [1], en el cual se llevan a cabo funciones importantes de consolidación de la memoria, crecimiento y reparación de los órganos [2]. Se estima que se duerme una tercera parte de la vida. Un adulto promedio debe dormir entre 7 y 8 horas, dependiendo de factores como edad, género, actividad física y otros factores externos. Una noche de sueño está conformada por varios ciclos, cada uno de los cuales tiene una duración entre 90 y 100 minutos. Sin embargo, cuando no se cumple con la duración de los ciclos del sueño durante la noche, aparecen diversos problemas físicos y psicológicos, como la somnolencia, fatiga e hipertensión, falta de atención, problemas de aprendizaje, depresión, entre otros [3]. Por lo tanto, asegurar una buena calidad de sueño es indispensable para mantener una buena salud física y mental [2].

Por lo tanto, el desarrollo de herramientas que permitan el monitoreo del sueño, ayudaría a estimar su calidad, para la cual se tienen en cuenta factores como duración total, latencia, número de despertares, profundidad y reparabilidad, los dos últimos de carácter subjetivo [4]. Adicionalmente, estas herramientas ayudarían a detectar trastornos del sueño, facilitando un diagnóstico temprano y evaluando las posibles causas.

A nivel clínico, el método estándar en estudios de sueño es el electroencefalograma (EEG), que captura la actividad eléctrica del cerebro. A partir del EEG el personal médico realiza una clasificación visual de las diferentes fases de sueño [5, 6, 7, 8].

Adicionalmente, con el reciente auge de los dispositivos móviles, han aparecido diversas aplicaciones de monitoreo del sueño en el celular que reportan la calidad del sueño de una persona durante la noche (i.e. Sleep Analyzer, SleepBot,

Sleep Genius o Sleep Cycle). Estos dispositivos determinan la calidad del sueño a partir de la cantidad movimiento y del sonido de la respiración de la persona. Sin embargo, estos dispositivos no distinguen las diferentes etapas observables en las señales EEG, ni las clasifican, haciendo sus resultados menos detallados. Por lo tanto, comparar la cuantificación de la calidad del sueño que realizan estos dispositivos con métodos de clasificación del EEG, podría ser de gran ayuda para validar la confiabilidad de estas aplicaciones.

En este proyecto se propuso implementar y comparar diferentes métodos de clasificación automática de etapas de sueño, y analizar la calidad de éste, con respecto a las aplicaciones en dispositivos móviles. En primer lugar, se realizó una interfaz gráfica que permite al usuario clasificar etapas de sueño usando transformadas tiempo-frecuencia, redes neuronales y/o máquinas de soporte vectorial, cambiando diferentes parámetros para obtener el mejor desempeño. Esta clasificación se comparó y validó con una extensa base de datos. En segundo lugar, se implementó un protocolo experimental, en el que se adquieren señales EEG de dos voluntarios con el sistema gMOBilab+, y se integra a Matlab, para realizar la clasificación y determinar la calidad del sueño. Aquí se realiza una comparación con las aplicaciones móviles.

En conclusión, a nivel clínico es importante reducir el tiempo de los análisis de sueño utilizando métodos de detección y clasificación automática de las fases a través del EEG, con porcentajes de desempeño altos. Además, es importante el desarrollo de dispositivos portátiles de clasificación de sueño confiables, el cual permitiría realizar monitoreo en casa, aumentando las posibilidades el acceso a muchos más usuarios. El tener acceso a estas herramientas permitiría conocer y mejorar la calidad del sueño y por ende mejorar el bienestar de las personas.

II. METODOLOGÍA

En este proyecto se desarrolló una plataforma de monitoreo de sueño, que detecta las diferentes fases y estima la calidad del sueño. Además, se realizó una protocolo experimental para comparar los resultados del análisis de sueño entre la plataforma de monitoreo y dos aplicaciones de dispositivos móviles.

II-A. Base de datos

Una primera fase del proyecto consiste en implementar diferentes algoritmos de procesamiento de señales EEG, para la clasificación automática de fases de sueño. Estos algoritmos se realizaron en una interfaz gráfica en el computador en Matlab. La comparación se hizo sobre señales EEG provenientes de

dos bases de datos disponibles en Physionet.org, The Sleep-EDF Database [Expanded] y MIT-BIH Polysomnographic. Ambas son colecciones de grabaciones de sueño, que cuentan con sus anotaciones. La primera tiene 61 registros de sueño provenientes de la ubicación de los electrodos en Fpz-Cz y Pz-Oz . La segunda tiene 18 grabaciones utilizando un solo canal.

II-B. Procesamiento

Para la segunda fase del proyecto, se realiza la adquisición de las señales, utilizando gMOBILab+. Se usa dos canales bipolares para el EEG (Canal 1 - Canal 2 y Canal 3 - Canal 4). Una vez adquiridas las señales en el computador, se procede a hacer el procesamiento digital de éstas, con el fin de extraer la información relevante durante el estado de sueño.

II-C. Extracción de Características

Para las señales EEG adquiridas, se usa dos métodos de análisis en tiempo-frecuencia, Transformada Wavelet y Transformada Wigner-Ville. Éstas permiten capturar la información de la señal bajo múltiples resoluciones, como se muestra en la Figura 1.

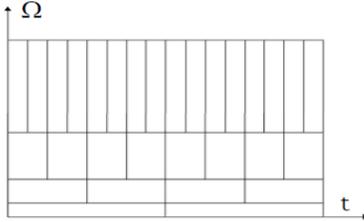


Figura 1: Resolución Transformada Wavelet [9]

II-C0a Transformada Wavelet en Tiempo Continuo

La función Wavelet, esta definida como:

$$W_{\psi}(\tau, s) = \langle x(t), \psi_{\tau, s}(t) \rangle = \frac{1}{\sqrt{s}} \int_{-\infty}^{\infty} x(t) \psi^* \left(\frac{t - \tau}{s} \right) dt \quad (1)$$

La transformada Wavelet permite discriminar entre señales no estacionarias con diferentes características de frecuencia, es decir, descompone una señal en un conjunto de funciones básicas, llamadas onditas. Estas funciones se obtienen por dilataciones, contracciones, y cambios de una función única llamada prototipo Wavelet.[9]

$$\psi_{s, \tau} = \frac{1}{\sqrt{s}} \psi \left(\frac{t - \tau}{s} \right) \quad (2)$$

Donde τ es el parámetro que controla la ubicación temporal de la ondita, para poder analizar la señal en un determinado segmento de tiempo. Y el parámetro s indica la duración del soporte temporal de la ondita [9].

II-C0b Transformada Wigner-Ville (WVD)

La Transformada Wigner-Ville (WVD), es muy útil para el análisis y la clasificación de señales no estacionarias[7].

La versión modificada del WVD, es el pseudo suavizado de la distribución de Wigner-Ville (SPWVD), que ha demostrado ser útil en la extracción de características, para la detección de ataques epilépticos de señales de EEG [7].

La expresión matemática de WVD, esta definida como:

$$S(t, f) = \int h(\tau) \left[\int g(u-t) s(u + \frac{\tau}{2}) s^*(u - \frac{\tau}{2}) du \right] \exp(-j\omega\tau) d\tau \quad (3)$$

Donde S es la señal, t es el tiempo, w es la frecuencia, g y h son el tiempo y la frecuencia de las funciones de la ventana suavizada, respectivamente. Sea $S [p, q]$ la representación de SPWVD en tiempo discreto de la señal de EEG, donde p y q representan índices correspondientes a tiempo y frecuencia discreta. La relación entre p, q, t y f es dado por $p = tfs$, $q = 2fM/fs$. [7].

El objetivo es extraer las características a partir del histograma de la imagen segmentada de tiempo-frecuencia (TFI), que corresponde a las bandas de frecuencia de los ritmos de las señales de EEG que se obtiene a partir del pseudo suavizado de la distribución Wigner-Ville [7].

II-D. Clasificación

Para la clasificación se hace uso de aprendizaje de máquina, específicamente de aprendizaje supervisado. Se escoge Máquinas de Soporte Vectorial y Redes Neuronales.

II-D0a Máquinas de Soporte Vectorial (SVM)

Es un algoritmo de aprendizaje supervisado, con el objetivo de encontrar el hiperplano óptimo.[10]. Transforma el espacio de entrada en otro, de dimensión superior, en el que el problema puede ser resuelto mediante un hiperplano óptimo (Maximizando el Márgen entre los puntos de datos en los límites). [10]

La ecuación del hiperplano, esta definida por la siguiente ecuación :

$$\vec{w} \cdot \vec{x} + b = 0 \quad (4)$$

La función del Kernel, representa un producto punto de los puntos de datos de entrada asignados en el espacio de características de mayor dimensión por transformación, es decir, transforma el espacio para poder distinguir las clases. Este proyecto utiliza 5 diferentes kernel, lineal, cuadrático, cúbico, gaussiano y función de base radial.

II-D0b Redes Neuronales Artificiales (ANN)

Una neurona artificial, pretende imitar el funcionamiento de una neurona biológica, siendo la unidad de procesamiento de datos en una red neuronal, el cual recibe señales de entrada provenientes de neuronas conectadas ponderadas por los pesos de las conexiones, calculando un valor en la salida. [11]

La salida de una neurona artificial, puede ser descrita mediante la siguiente expresión matemática:

$$y_i(x^k) = \phi(Z_i) = \phi(w'_i x^k + b_i) = \phi\left(\sum_{j=1}^n w_{ij} x_j^k + b_i\right) \quad (5)$$

Donde w_i hace referencia a los pesos, x^k al número de las neuronas y ϕ la función de activación.

En la estructura de la red neuronal se tiene:

- **Entrada:** Matriz de características obtenida al aplicar cualquiera de las dos transformadas en tiempo frecuencia, para calcular las bandas de frecuencia.
- **Capas Ocultas:** Se hace uso de una sola oculta
- **Salida:** Respuesta de la red neuronal, clasificación de las etapas de sueño.

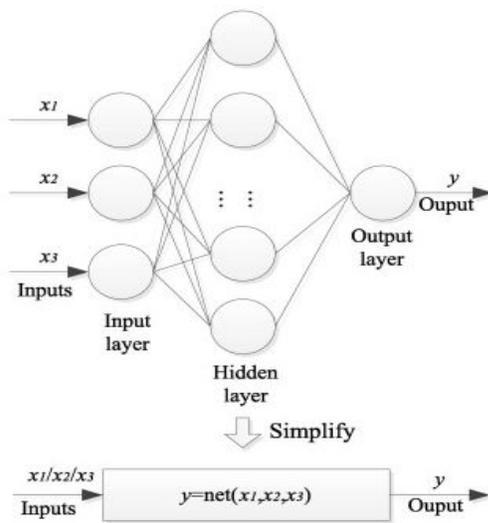


Figura 2: Estructura de una red neuronal. [12]

Para el entrenamiento se hace uso de dos algoritmos el Bayesiano y Levenberg–Marquardt.

II-E. Validación estadística

Para determinar el rendimiento de los clasificadores que se implementaron, se usó la sensibilidad, especificidad y exactitud.

Con la ayuda de una matriz o tabla de contingencia, se puede conocer la relación entre dos o más atributos [13] (etapas de sueño) con relación a la frecuencia, es decir, podemos calcular la sensibilidad y la especificidad.

- **Sensibilidad:** Es una medida estadística que indica lo verdaderos positivos de un test, también conocida como True Positive Rate (TPR). [14] Y puede calcularse mediante la siguiente ecuación:

$$TPR = \frac{TP}{TP + FN} \quad (6)$$

- **Especificidad:** Es una medida estadística que mide los negativos presentes de un test, que están identificados correctamente, también llamada como True Negative Rate

(TNR). [14] Y puede calcularse mediante la siguiente ecuación:

$$TNR = \frac{TN}{TN + FP} \quad (7)$$

II-F. Protocolo experimental

Se realizó experimentos simultáneos con EEG y las aplicaciones móviles. Para registrar la actividad cerebral, se utiliza electrodos superficiales que son puestos a los voluntarios y distribuidos según el Sistema Internacional 10-20.

Para las pruebas con voluntarios se diseña un protocolo experimental con un consentimiento en donde la persona acepta la realización del experimento. Se le explica que el procedimiento es de carácter no invasivo, sin contraindicaciones y seguro.

Además, se le pide a la persona que se quite cualquier objeto como aretes, reloj, celular, anillo, entre otros que pueda interferir con la señal que se adquiere.

Se limpia los electrodos con alcohol, y con ayuda de palillos se retira la mayor cantidad de cabello posible, para tener mayor contacto con el cuero cabelludo aplicándole gel conductor.

Fue necesario realizar pruebas preliminares durante el día, en donde el voluntario tomaba una siesta de aproximadamente 3 horas. Se toma nota de algunas recomendaciones por parte del voluntario, como el ambiente para el experimento debe ser más oscuro y en silencio.

II-G. Interfaz gráfica

Se desarrolló en Matlab un interfaz gráfica que integra la adquisición de las señales de los voluntarios, junto con el entrenamiento de los clasificadores y la estimación de la calidad de sueño. Lo anterior permite al usuario interactuar en todo el proceso.

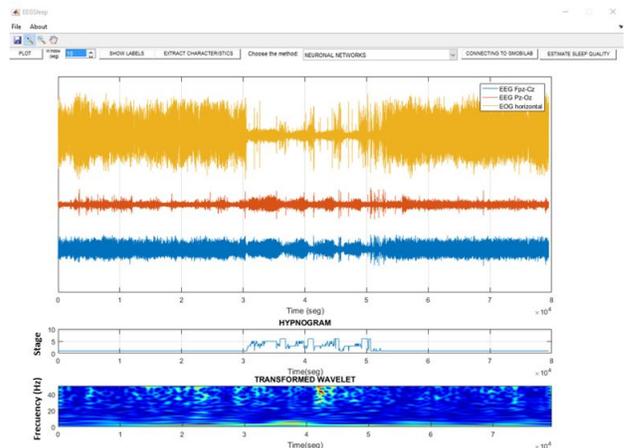


Figura 3: Interfaz Gráfica

III. RESULTADOS

III-A. Clasificación de las fases de sueño utilizando las bases de datos

Para la base de datos MIT-BIH Polysomnographic, se analiza la exactitud para las Redes Neuronales utilizando

Levenberg–Marquardt y Bayesiano como algoritmo de entrenamiento.

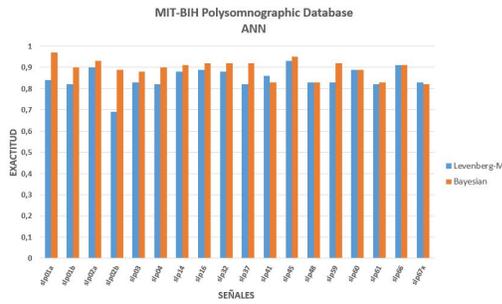


Figura 4: Exactitud Clasificador Red Neuronal para MIT-BIH Polysomnographic

Para la Máquina de Soporte Vectorial, se utiliza el Kernel lineal, cuadrático, cúbico, gaussiano, y función de base radial (RBF).

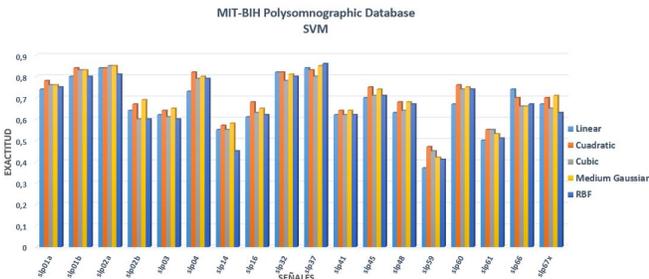


Figura 5: Exactitud Clasificador SVM para MIT-BIH Polysomnographic

Para la base de datos, The Sleep-EDF Database [Expanded], se obtuvieron los siguientes resultados de exactitud aplicando Redes Neuronales con dos algoritmos de entrenamiento.

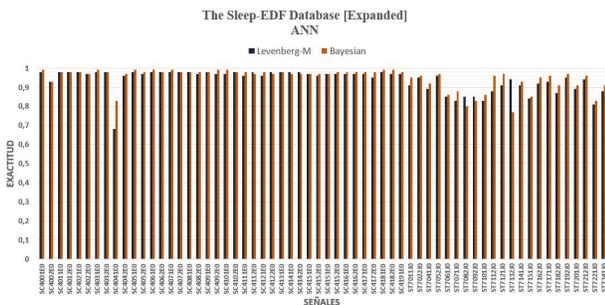


Figura 6: Exactitud Clasificador ANN para The Sleep-EDF Database [Expanded]

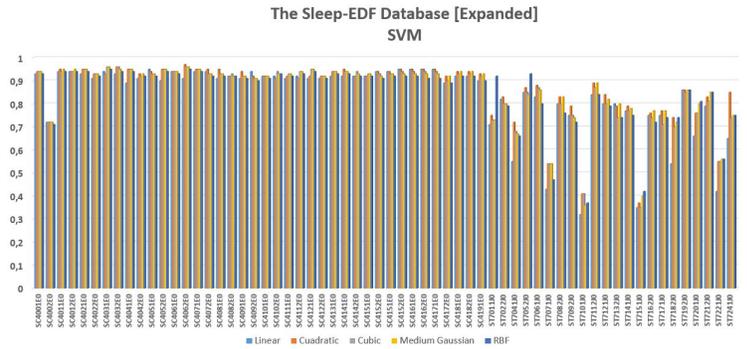


Figura 7: Exactitud Clasificador SVM para The Sleep-EDF Database [Expanded]

Los clasificadores implementados, tuvieron un buen rendimiento a excepción de dos señales (slp14 y slp59) de la base de datos MIT-BIH Polysomnographic y otras dos señales de la base de datos The Sleep-EDF Database (ST7101J0 y ST7151J0), al aplicar SVM.

III-B. Fase experimental

Para el Voluntario 1, el SVM con Kernel lineal fue el que tuvo mejor rendimiento.

Stage	Sensitivity	Specificity
1	0.971443	0.695253
2	0.362069	0.994211
3	0.76	0.994581
4	0.326733	0.990973
5	0.226891	0.993676
6	0.68	0.988906

Performance General: 0.86259

Note: The values are between 0 - 1

Figura 8: Resultado del mejor modelo para clasificar las fases de sueño del Voluntario 1

Para el Voluntario 2, el SVM con Kernel lineal fue el que tuvo mejor rendimiento.

Stage	Sensitivity	Specificity
1	1	0.0015313
2	0	1
3	0	1
4	0	1
5	0	1
6	0.04	0.998811

Performance General: 0.721027

Note: The values are between 0 - 1

Figura 9: Resultado del mejor modelo para clasificar las fases de sueño del Voluntario 2

El modelo del clasificador implementado para las señales de los voluntarios con mejor rendimiento se obtuvo fue el SVM con kernel lineal.

Para determinar la calidad del sueño se tuvieron en cuenta, la latencia del sueño (1), el número de despertares (2), el despertar después del inicio del sueño (3) y la eficiencia (4). Además de la presencia de la Etapa REM (5), Etapa 1 (6) y Etapa 2 (7).

Indicadores	Volu 1	Volu 2
1	5 minutos	20 minutos
2	0	4
3	0 minutos	8 minutos
4	90 %	80 %

Para el Voluntario 1.

Indicador	EEG	SleepBot	Sleep Analyzer
5	2,75 %	-	-
6	49,25 %	5 %	9,4 %
7	2 %	2 %	3,1 %
8	42,25 %	50 %	87,5 %

Para el Voluntario 2.

Indicador	EEG	SleepBot	Sleep Analyzer
5	0	-	-
6	40 %	20 % -	10 %
7	3,6 %	3 %	5 %
8	25 %	60 %	70 %

Las aplicaciones móviles, no tienen en cuenta la etapa REM del sueño, haciendo que la información no sea la suficiente para determinar su calidad.

Para el método estándar del EEG, la calidad del sueño del Voluntario 1, cumple con los primeros 4 indicadores. Sin embargo los otros cuatro indicadores, están por fuera del rango. Ésto quiere decir, que la calidad del sueño no fue bueno.

Para el voluntario 2, cumple solo tres de los primeros 4 indicadores, ya que no se encuentre en el rango para el indicador 1. Y los otros indicadores no los cumple. Determinándose así, que la calidad del sueño no fue bueno.

IV. CONCLUSIONES

- Se probaron algoritmos con una especificidad, sensibilidad y exactitud del 80 %.
- La cantidad de muestras que se tienen para cada de una de las etapas de sueño, juega un papel muy importante. Esto determina si la sensibilidad, especificidad o exactitud sea alta. Lo anterior se ve reflejado en la etapa 2 del sueño, en donde la cantidad de muestras es grande permitiendo diferenciarse de las otras.
- Se desarrolló una interfaz gráfica en Matlab, que integra la adquisición de la actividad neuronal de cada voluntario, el entrenamiento y clasificación. Además de poder estimar la calidad del sueño.
- Se desarrolló un fase experimental, con dos voluntarios en donde la adquisición de la actividad neuronal implicó diferentes pruebas. Debido al desplazamiento de los electrodos, la incomodidad para dormir y sobretodo el espacio en donde se desarrolla la prueba.
- Se comparó la calidad del sueño con el EEG y las aplicaciones móviles, siendo esta última no tan buena. Debido a que su análisis lo realiza según los movimientos

y sonidos que se realizan durante la noche. Esto hace que sean muy vulnerables a ruidos externos, como alarmas de los carros, o caída de un objeto.

- Al realizar las etiquetas que forma visual de las señales de los voluntarios, ocasionó que al implementar el modelo entrenado de los clasificadores no fuera el esperado.

REFERENCIAS

- [1] Division of Sleep Medicine at y Harvard Medical School. *What is Sleep? — Healthy Sleep*. URL: <http://healthysleep.med.harvard.edu/healthy/science/what> (visitado 14-09-2017).
- [2] Kirstie N Anderson y Andrew J Bradley. “Sleep disturbance in mental health problems and neurodegenerative disease.” En: *Nature and science of sleep* 5 (2013), págs. 61-75. URL: <http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=PMC3674021>.
- [3] “Sleep-Wake Cycle: Its Physiology and Impact on Health”. En: *Its Physiology and Impact on Health* (). URL: www.sleepfoundation.org.
- [4] Dexy Prieto-Rincón y col. “Calidad del sueño en pacientes psiquiátricos hospitalizados.” En: *Investigación Clínica* 47.1 (2006), págs. 5-16. ISSN: 0535-5133.
- [5] Vance Gao, Fred Turek y Martha Vitaterna. “Multiple classifier systems for automatic sleep scoring in mice”. En: *Journal of Neuroscience Methods* 264 (2016), págs. 33-39. ISSN: 1872678X. DOI: 10.1016/j.jneumeth.2016.02.016. URL: <http://dx.doi.org/10.1016/j.jneumeth.2016.02.016>.
- [6] Abdulhamit Subasi y col. “Automatic recognition of vigilance state by using a wavelet-based artificial neural network”. En: *Neural Computing and Applications* 14.1 (2005), págs. 45-55. ISSN: 09410643.
- [7] Elena Alexandra Fríncu. “Automatic classification of sleep stages based on physiological signals”. En: 2 (2011), pág. 249.
- [8] Farid Yaghoubi y Sridhar Sunderam. “Quasi-supervised scoring of human sleep in polysomnograms using augmented input variables”. En: *Computers in Biology and Medicine* 59 (2015), págs. 54-63. ISSN: 18790534. DOI: 10.1016/j.combiomed.2015.01.012. URL: <http://dx.doi.org/10.1016/j.combiomed.2015.01.012>.
- [9] Julian Quiroga. “Fundamentos de señales y sistemas”. En: (2011), págs. 1-430.
- [10] Alexander Statnikov y col. “A Gentle Introduction To Support Vector Machines in Biomedicine”. En: *Journal of AMIA* (2011). DOI: 10.1142/7922. URL: <http://www.worldscientific.com/worldscibooks/10.1142/7922>.
- [11] A*; PALMER POL y J.J.** MONTAÑO MORENO. “¿Qué son las redes neuronales artificiales? Aplicaciones realizadas en el ámbito de las adicciones”. En: (). URL: <http://disi.unal.edu.co/%7B~%7Dlctorress/RedNeu/LiRna001.pdf>.
- [12] Chena Yanni y col. “A nested-ANN prediction model for surface roughness considering the effects of cutting forces and tool vibrations”. En: *Measurement* 98 (feb. de 2017), págs. 25-34. ISSN: 0263-2241. DOI: 10.1016/J.MEASUREMENT.2016.11.027.

- [13] Shusaku Tsumoto y Shoji Hirano. “Contingency matrix theory”. En: *2007 IEEE International Conference on Systems, Man and Cybernetics*. IEEE, 2007, págs. 3778-3783. ISBN: 978-1-4244-0990-7. DOI: 10.1109/ICSMC.2007.4413917. URL: <http://ieeexplore.ieee.org/document/4413917/>.
- [14] Rajul Parikh y col. “Understanding and using sensitivity, specificity and predictive values.” En: *Indian journal of ophthalmology* 56.1 (2008), págs. 45-50. ISSN: 0301-4738. URL: <http://www.pubmedcentral.nih.gov/articlerender.fcgi?artid=PMC2636062>.



Yesid Perdomo Ingeniero Electrónico de la Universidad Surcolombiana (2015). Estudiante de Maestría de la Pontificia Universidad Javeriana (2017).