



Regresión Logística y Máxima Verosimilitud para clasificación de personas diagnosticadas con Trastorno de Déficit de Atención e Hiperactividad

Iván Alejandro García Amaya, Marco Antonio Aceves Fernández*, Saúl Tovar Arriaga, Juan Manuel Ramos Arreguín

Universidad Autónoma de Querétaro, Facultad de Ingeniería
marco.aceves@gmail.com

Resumen

En este trabajo se presenta una metodología para la correcta clasificación de personas diagnosticadas con Trastorno de Déficit de Atención e Hiperactividad con respecto a personas que no tienen dicho trastorno (Control). Esto se realizó mediante el uso de las de electroencefalograma. La metodología propone una primera fase de filtrado donde se retira el ruido de las señales, además de extraer la banda β , tomando en cuenta solamente 5 canales (Cz, Pz, Fz, C3, C5), se hace la extracción de las diferentes características; Desviación Estándar, Varianza, Poder Absoluto y Poder Relativo, cada una de estas características aporta información relevante. Con dicha información se implementaron dos modelos, Regresión Logística y Máxima Verosimilitud, esto modelos se entrenan con el 70% del conjunto de datos y se usas el 30% para validación que se seleccionan de manera aleatoria. Este proceso se repite un número de veces y los mejores resultados obtenidos son 80.30% de exactitud en el modelo de Regresión Logística y 84.40% en el modelo de Máxima Verosimilitud, concluyendo que una mayor extracción de características se traduce en una mayor cantidad de información. La correcta extracción de información nos permite la implementación de algoritmos como lo son Regresión Logística y Máxima Verosimilitud.

Palabras clave: Trastorno de Déficit de Atención e Hiperactividad, señales de electroencefalograma, Regresión Logística, Máxima verosimilitud.

Abstract

In this work, a methodology is presented for the correct classification of people diagnosed with Attention Deficit Hyperactivity Disorder concerning people who do not have said disorder (Control). This was done using EEG. The methodology proposes a first filtering phase where the noise is removed from the signals, in addition to extracting the β band, considering only 5 channels (Cz, Pz, Fz, C3, C5), the different characteristics are extracted; Standard Deviation, Variance, Absolute Power and Relative Power, each of these characteristics provides relevant information. With this information, two models were implemented, Logistic Regression and Maximum Likelihood, these models are trained with 70% of the data set and 30% are used for validation that is randomly selected. This process is repeated several times and the best results obtained are 80.30% accuracy in the Logistic Regression model and 84.40% in the Maximum Likelihood model, concluding that a greater extraction of characteristics translates into a greater amount of information. Correct information extraction allows us to implement algorithms such as Logistic Regression and Maximum Likelihood.

Keywords: Attention Deficit Hyperactivity Disorder, EEG signals, Logistic Regression, Maximum likelihood.



1. Introducción

El Trastorno por Déficit de Atención (TDAH) es un trastorno que afecta a una gran cantidad de individuos, los criterios para el diagnóstico se establecen en el DSM-5 (Diagnostic and Statistical Manual of Mental Disorders) [7]. El uso de señales EEG como medio para la clasificación de personas de control y TDAH, ha sido investigado ampliamente, tomando en cuenta que la hiperactividad e impulsividad en niños incrementa el poder de la onda δ y la onda θ y su falta de atención muestra decremento del poder de las bandas α y β [6]. En este trabajo se pretende obtener información relevante de la onda β .

Tabla 1. Resumen de trabajos en el estado del arte.

Autor	Año	Medidas	Modelo	Exactitud
Vicent Monastra	2001	θ/β radio	ANOVA	91.00%
Christopher Magee	2005	Poder Relativo y absoluto δ , θ , α y β	Regresión Logística	87.00%
Steven Snyder	2008	θ/β radio	ANOVA	89.00%
Khadijeh Sadtnezhad	2011	Fractal-based, poder de banda y Coeficientes wavelet	FLDA	80.92%
Geir Ogrim	2012	Poder Absoluto θ y β	ANCOVA	85.00%
Mehran Ahmadi	2012	Inter-electrode synchronization	LDA	88.20%
Bedakh Abibullaev	2012	Radio θ/α θ/β , poder relativo θ y β	SVM	97.00%
Aleksandar Tenev	2013	Poder Absoluto δ , θ , α y β	SVM	82.30%
Halla Helgadóttir	2015	Multi-channels, Características optimas.	SVM	79.00%
Reza Mohammadi	2016	Multi-channels fractal dimension	MLP	93.65%
Reza Yaghoobi	2017	Multi-channels, Características optimas.	MEFM	99.01%
Reza Yaghoobi	2018	RQA, poder y entropía	SVM	98.25%
Nuestro Trabajo	2021	Poder Absoluto y Poder Relativo de la banda β , Entropía	Regresión Logística - Máxima verosimilitud	80.30%-84.40%

Observando los trabajos del estado del arte presentados en esta investigación, se puede resaltar el algoritmo de Máquina de Soporte de Vectores (SVM por sus siglas en inglés Support Vector Machine), ya que 4 de estos trabajos hacen uso de este algoritmo, pero se observa una variación relevante en el uso de diferentes características, usando características optimas obtiene una exactitud de 79% [19], Aleksandar Tenev en su investigación [10] usa poder absoluto de las bandas δ , θ , α y β obteniendo 82.30% de exactitud, con el uso del radio de poder entre β/θ , θ/β y poder relativo θ y β , se obtuvo una exactitud de 91% [9], la investigación con mayor exactitud en el uso de SVM y como características RQA, poder y entropía, obtuvo 98.25% de exactitud [6].

El uso de algoritmos de Regresión Logística, se han implementado con éxito [8], usando un número considerable de características, como lo son Poder Absoluto y Relativo de las bandas δ , θ , α y

β , además de del uso de técnicas con análisis de componentes principales o análisis de agrupamiento, obteniendo una exactitud de 87%.

El uso de ANOVA y las características θ/β radio fueron implementadas en dos diferentes investigaciones [12] [13] obteniendo 89% y 91% de exactitud, además de la variante ANCOVA donde usan el Poder Absoluto de θ y β , donde obtuvo 85% [11]. El uso de Análisis Discriminante Lineal (LDA por sus siglas en inglés Linear Discriminant Analysis) con características como Inter-electrode synchronization dando como resultado 88.20% [14], con su variante Fisher Análisis Discriminante Lineal (FLDA por sus siglas en inglés Fisher Linear Discriminant Analysis) y el uso de Fractal-based, Poder de las bandas y coeficientes Wavelet obteniendo 80.92% de exactitud [15]. El trabajo [5] con mayor exactitud es con el uso de un híbrido difuso (MEFM por sus siglas en inglés Mixture of Expert Fuzzy Model) usando características optimas con una exactitud de 99%, y con el uso de Perceptrón Multicapa (MLP por sus siglas en inglés Multilayer perceptron) y Dimensión Fractal con 93.65% de exactitud [16].

2. Marco Teórico.

La frecuencia es uno de los criterios más importantes para evaluar anomalías en las señales clínicas EEG y para comprender los comportamientos funcionales en la investigación cognitiva. La frecuencia se refiere al ritmo repetitivo de la actividad en Hz y el número de ciclos en segundos [20]. En humanos los potenciales de EEG se manifiestan como impredecibles de oscilaciones a periódicas con ráfagas intermitentes de oscilaciones. En la figura 1 se observan las señales EEG.




Figura 1. Señales de los canales de Electroencefalograma (EEG).

En adultos sanos, las amplitudes y las frecuencias de tales señales cambian de un estado a otro, como en estado de despierto y sueño. Hay cinco ondas cerebrales principales que se distinguen por sus diferentes rangos de frecuencia [20]. En la figura 2 se observa un ejemplo de una cantidad de dispositivos electrónicos que se usan o tienen la funcionalidad de recolectar señales EEG.



Figura 2. Dispositivo electrónico Open BCI.

Las bandas de frecuencia de bajas a altas frecuencias, respectivamente, se clasifican típicamente en bandas específicas como: δ (0.5-4 Hz), θ (4-8 Hz), α (8-13 Hz), β (13-30 Hz) y γ (>30 Hz) [20]. En la figura 3 se observa el sistema internacional 10-20 para las posiciones de los electrodos.




Figura 3. Sistema Internacional 10-20 [20].

2.1 Materiales y Métodos

En la figura 4 se observa la metodología implementada en este trabajo de investigación, donde lo primero que se hace es el filtrado de las señales EEG, después se extrae la banda β , de esta se extraen las características que son: Desviación Estándar, Varianza, Entropía, Poder Absoluto y Poder Relativo, estos son los valores que se utilizan para el entrenamiento y validación de los modelos de Regresión Logística y Máxima Verosimilitud.

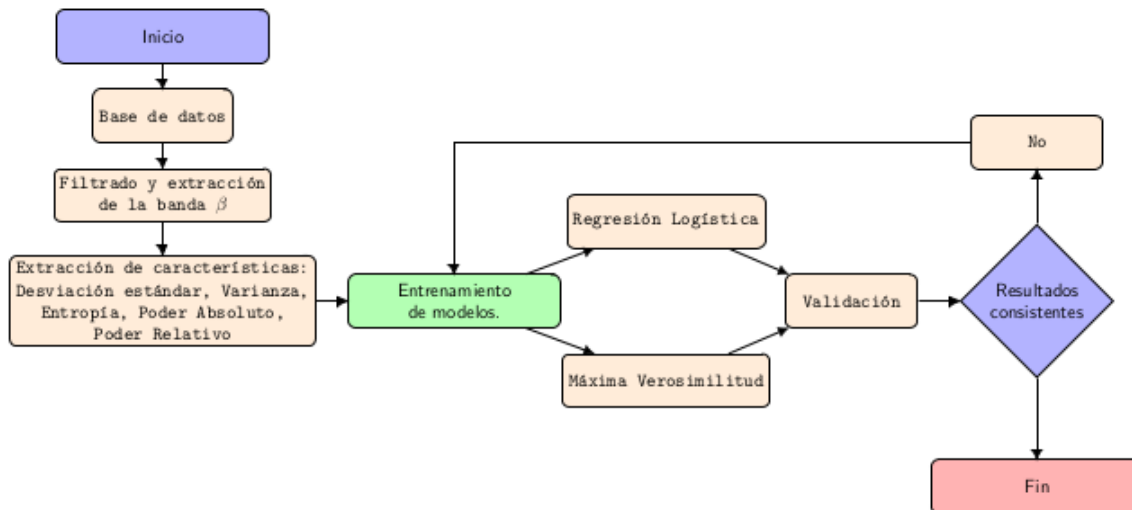


Figura 4. Metodología propuesta.

2.2 Base de datos y procesamiento.

En este trabajo se usó una base de datos de señales EEG, estas señales fueron recolectadas de 60 sujetos diagnosticados con TDAH y 60 sujetos de Control de una edad entre 7 y 12 años, se recolectaron las señales de 19 canales basados en el sistema internacional 10-20 (Fz, Cz, Pz, C3, T3, C4, T4, Fp1, Fp2, F3, F4, F7, F8, P3, P4, T5, T6, O1, O2), además de dos electrodos de referencia A1, A2 [4].

El procesamiento de los datos se hizo agregando la frecuencia de muestro de 128 Hz, además de los nombres de los respectivos canales, para retirar épocas malas o con excesivo ruido, después se aplica un filtro pasa-banda de 12 Hz de límite inferior y 30 Hz de límite superior.

Investigaciones anteriores [5] [6] han obtenido excelentes resultados usando las características de 5 canales en específico (Fz, Pz, Cz, C3 y C4), en este trabajo se hace uso de las características extraídas de estos canales.

2.3 Extracción y selección de características.

En este trabajo se propone un conjunto de características como los son: Desviación estándar, Varianza, Entropía, Poder Absoluto y Poder Relativo de la onda β , se propone el uso de todas las características, ya que aportan información relevante para la clasificación de los sujetos de estudio.

Desviación estándar y Varianza. En estadística la medida de la variabilidad de un conjunto de números es conocida como la Desviación Estándar y es dada por la ecuación.

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2} \quad (1)$$

donde N es el número de datos en nuestro conjunto x_i y μ la media definida por:



$$\mu = \frac{1}{N} \sum_{i=1}^N x_i \quad (2)$$

entonces el cuadrado de la Desviación Estándar nos da la Varianza que viene dada por la ecuación.

$$\sigma^2 = \frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2 \quad (3)$$

Entropía. La complejidad de espectro, puede ser cuantificada por el Poder de Espectro de Entropía, esto es la información de entropía de un sistema incierto y la información de entropía de un sistema es dada por la siguiente ecuación:

$$H = - \sum_{i=1}^n p_i \ln p_i \quad (4)$$

Poder Absoluto. El Poder Absoluto de una banda es la integral de todos los valores en un respectivo rango de frecuencia, el poder promedio en $y(n)$ es

$$E\{|y(n)^2|\} = y_y(0) = \frac{1}{2\pi} \int_{-\pi}^{\pi} P_y(e^{jw}) dw \quad (5)$$

entonces, tenemos

$$E\{|y(n)^2|\} \approx \frac{\Delta w}{2\pi} P_x(e^{jw_0}) \quad (6)$$

donde, $P_x(e^{jw})$ puede ser tomado como la función de densidad que describe como el poder en $x(n)$ varia respecto a w [2].

Poder Relativo. El poder relativo de su respectiva banda dado por:

$$RP(f_1, f_2) = \frac{P(f_1, f_2)}{P(a, b)} 100\% \quad (7)$$

donde $P(.)$ indica el poder, $RP(.)$ el poder relativo y f_1, f_2 indican la frecuencia baja y alta respectivamente [1].

2.4 Normalización de los datos.

En necesario normalizar nuestros datos, con la finalidad de obtener un mejor rendimiento en nuestro modelo de clasificación, en este trabajo se implementó la normalización de máximo y mínimo, que viene dado por la siguiente ecuación.

$$X_{scaled} = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (8)$$

donde x representa nuestro conjunto de datos.



2.5 Regresión Logística.

El modelo de Regresión Logística usamos la función logística que viene dada por la siguiente ecuación: [3].

$$p(X) = \frac{e^{\beta_0 + \beta_1 X}}{1 + e^{\beta_0 + \beta_1 X}} \quad (9)$$

Múltiple Regresión Logística. En este trabajo se pretende hacer una clasificación binaria usando predicciones múltiples, tomando esto en cuenta, se puede definir una regresión múltiple, como se muestra en la ecuación 10 [3].

$$\log\left(\frac{p(X)}{1 - p(X)}\right) = \beta_0 + \beta_1 X_1 + \dots + \beta_p X_p \quad (10)$$

donde $X = (X_1, \dots, X_p)$ son predicciones p , entonces la ecuación anterior se puede definir

$$p(X) = \frac{e^{\beta_0 + \beta_1 X_1 + \dots + \beta_p X_p}}{1 + e^{\beta_0 + \beta_1 X_1 + \dots + \beta_p X_p}} \quad (11)$$

2.6 Máxima verosimilitud

El enfoque para el análisis de los datos se plantea partiendo de la media de la distribución que se representa en la ecuación 12, que es la forma estándar de la distribución Gaussiana [17].

$$P(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad (12)$$

Donde $P(x)$ es la la probabilidad de ocurrencia de la variable n , σ es la Desviación estándar, σ^2 es la Varianza, μ es la Media. El método se basa en el postulado de que los valores de los parámetros desconocidos son aquellos que producen una probabilidad máxima de observar los datos medidos. Suponiendo que las mediciones son independientes entre sí, como se observa en el algoritmo 1 [17].

Algoritmo 1: Máxima verosimilitud.

Input: train-test Data

Output: Probabilidad de ocurrencia

```

1  Maxima_verosimilitud ← function(train, test){
2      x ← train
3      y ← test
4      n ← length(x)
5       $\mu \leftarrow \frac{1}{N} \sum_{i=1}^n x_i$ 
6       $\sigma \leftarrow \sqrt{\sum_{i=1}^n (x_i - m)/n}$ 
7       $p(y_i) \leftarrow \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{y_i - \mu^2}{2\sigma^2}}$ 

```



$$\begin{aligned} & 8 \} \\ & \underline{9 \quad prob_{oc} \leftarrow \text{Maxima}_{verosimilitud}(\text{train}, \text{test})} \end{aligned}$$

2.7 Validación del modelo.

Para la validación del modelo se implementaron varias métricas, estas dependen principalmente de falsos positivos (fp por sus siglas en inglés false positives), falsos negativos (fn por sus siglas en inglés false negatives), verdaderos positivos (tp por sus siglas en inglés true positives) y finalmente verdaderos negativos (tn por sus siglas en inglés true negatives), la Exactitud es definida en (13).

$$Exd = \frac{tp + tn}{tp + tn + fp + fn} \quad (13)$$

La siguiente métrica es la Precisión, definida en (14).

$$Prn = \frac{tp}{tp + fp} \quad (14)$$

La Sensibilidad viene dada por (15)

$$Sds = \frac{tp}{tp + fn} \quad (15)$$

ahora podemos obtener F1 que es definido en (16)

$$F1 = 2 \frac{(Prn)(Sds)}{Prn + Sds} \quad (16)$$

3. Resultados y discusiones.

El modelo implementado en esta investigación se validó usando las métricas mencionadas anteriormente, el conjunto de datos se separó de manera aleatoria en 70% para el entrenamiento y 30% para la validación del mismo, ambos algoritmos se ejecutaron un número determinado de veces, el mejor resultado es el que se presenta en la tabla 2, además es importante mencionar que en ambos se utilizaron las características mencionadas anteriormente, todas pertenecientes a la onda β , donde buscamos encontrar un nivel de concentración en el sujeto de prueba, podemos observar un mejor desempeño en el algoritmo de Máxima Verosimilitud, esto en las diferentes métricas implementadas.

Tabla 2. Métricas Regresión Logística - Máxima Verosimilitud.

Modelos	Precisión	Sensibilidad	F1	Exactitud
Regresión Logística	0.7169	0.7755	0.7450	0.8030
Máxima Verosimilitud	0.8230	0.9190	0.8680	0.8440

En la figura 5, se observa los resultados obtenidos, podemos observar una comparativa entre falsos negativos, falsos positivos, verdaderos negativos y verdaderos positivos, entre la clase real y la predicción de los modelos implementados.




Figura 5. a) Matriz de confusión del modelo Regresión Logística. b) Matriz de confusión del modelo Máxima Verosimilitud.

En la figura 6 se muestra la distribución de los datos pertenecientes a las características de Entropía y Poder Absoluto, es importante mencionar la diferencia entre los dos grupos (TDAH-Control). Podemos observar que ambas características comparten un área significativa en la distribución de sus datos, pero también se observa una diferencia entre estos grupos y es esta la que nos permite obtener los resultados mostrados en la tabla 2, es decir que, esta diferencia que se observa es suficiente para obtener valores de exactitud aceptable.

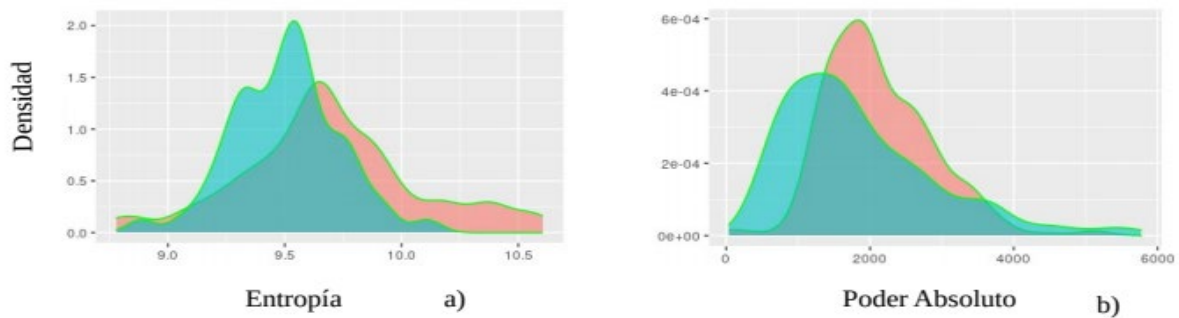


Figura 6. a) Distribución de densidad de la Entropía. b) Distribución de densidad del Poder Absoluto.

En la figura 7 se observa la comparación de las diferentes métricas usadas como métodos de evaluación para los dos modelos implementados en este trabajo de investigación, se observa en el eje x, dos grupos, que son: 0 y 1, donde 0 pertenece al modelo de Máxima Verosimilitud y el 1 pertenece al modelo Regresión Logística, se observa una tendencia de valores mayores en el modelo de Máxima Verosimilitud.

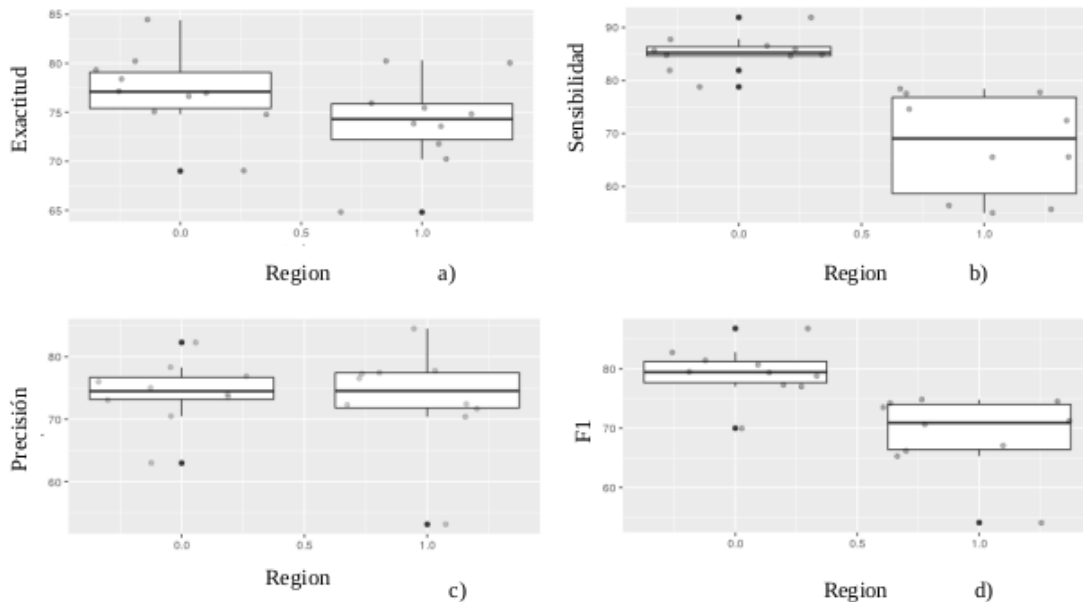


Figura 7. a) Exactitud de los modelos Máxima Verosimilitud y Regresión Logística. b) Precisión de los modelos Máxima Verosimilitud y Regresión Logística. c) Sensibilidad de los modelos Máxima Verosimilitud y Regresión Logística. d) F1 de los modelos Máxima Verosimilitud y Regresión Logística.

4. Conclusiones

Lo que se busca en esta investigación es extraer información suficiente de las señales de electroencefalograma de un sujeto diagnosticado con Trastorno de Déficit de Atención e Hiperactividad que nos permitan hacer una clasificación entre los grupos TDAH y Control.

En esta investigación nos enfocamos en 5 características de las señales de electroencefalograma, como lo son: La Desviación Estándar, la Varianza, la Entropía, el Poder Absoluto y Relativo de la banda β .

Observando la distribución de los datos de las diferentes características, se destaca que estos comparten una cantidad considerable de similitud en la distribución en sus datos y por consiguiente una parte que existe un grupo, pero no en el otro, esta diferencia en la distribución de los datos nos permite obtener un promedio de probabilidad de ocurrencia mayor en un grupo que en el otro para cada valor dado, siendo este el principio de funcionamiento del modelo de Máxima Verosimilitud, el cual logra obtener una exactitud considerable como se muestra en la tabla 2. Como parte del trabajo futuro se propone la investigación de un grupo mayor de características, que permita obtener resultados más precisos.

Referencias

- [1]. Z. Bian, Q. Li, L. Wang, C. Lu, S. Yin, and X. Li, "Relative power and coherence of eeg series are related to amnesic mild cognitive impairment in diabetes," *Frontiers in aging neuroscience*, vol. 6, p. 11, 02 2014.
- [2]. M. H. Hayes, *Statistical digital signal processing and modeling*. John Wiley & Sons, Inc, 1996.



- [3]. J. Gareth, W. Daniela, H. Trevor, and T. Robert, *An introduction to Statistical Learning*. Springer New York Heidelberg Dordrecht London, 2014.
- [4]. A. M. N. A. A. M. S. M. R. Mohammadi, "Eeg data for adhd / control children," 2020
- [5]. R. Yaghoobi Karimui and S. Azadi, "Diagnosing the adhd using a mixture of expert fuzzy models," *International Journal of Fuzzy Systems*, vol. 20, 01 2017.
- [6]. R. Yaghoobi Karimui, S. Azadi, and P. Keshavarzi, "The adhd effect on the high-dimensional phase space trajectories of eeg signals," *Chaos Solitons Fractals*, vol. 121, pp. 39–49, 02 2019.
- [7]. B. Russell A., M. Kevin R., and F. Mariellen, *ADHD in adults what the science says*. The Guilford Press, 2008.
- [8]. C. A. Magee, A. R. Clarke, R. J. Barry, R. McCarthy, and M. Selikowitz, "Examining the diagnostic utility of eeg power measures in children with attention deficit/hyperactivity disorder," *Clinical Neurophysiology*, vol. 116, no. 5, pp. 1033– 1040, 2005.
- [9]. B. Abibullaev and J. An, "Decision support algorithm for diagnosis of adhd using electroencephalograms," *Journal of medical systems*, vol. 36, pp. 2675–88, 06 2011.
- [10]. A. Tenev, S. Markovska-Simoska, L. Kocarev, J. Pop-Jordanov, A. Mueller, and G. Candrian, "Machine learning approach for classification of adhd adults.," *International journal of psychophysiology : official journal of the International Organization of Psychophysiology*, vol. 93, 01 2013.
- [11]. G. Ogrim, J. Kropotov, and K. Hestad, "The quantitative eeg theta/beta ratio in attention deficit/hyperactivity disorder and normal controls: Sensitivity, specificity, and behavioral correlates," *Psychiatry Research*, vol. 198, no. 3, pp. 482 – 488, 2012.
- [12]. S. M. Snyder, H. Quintana, S. B. Sexson, P. Knott, A. Haque, and D. A. Reynolds, "Blinded, multi-center validation of eeg and rating scales in identifying adhd within a clinical sample," *Psychiatry Research*, vol. 159, no. 3, pp. 346 – 358, 2008.
- [13]. V. Monastra, J. Lubar, and M. Linden, "The development of a quantitative electroencephalographic scanning process for attention deficit-hyperactivity disorder: Reliability and validity studies," *Neuropsychology*, vol. 15, pp. 136–44, 02 2001.
- [14]. M. Ahmadlou, R. Rostami, and V. Sadeghi, "Which attention-deficit/hyperactivity disorder children will be improved through neuro- feedback therapy? a graph theoretical approach to neocortex neuronal network of adhd," *Neuroscience Letters*, vol. 516, no. 1, pp. 156 – 160, 2012.
- [15]. K. Sadatnezhad, R. Boostani, and A. Ghanizadeh, "Classification of bmd and adhd patients using their eeg signals," *Expert Systems with Applications*, vol. 38, no. 3, pp. 1956 – 1963, 2011.
- [16]. M. R. Mohammadi, "Eeg classification of adhd and normal children using non-linear features and neural network," *Biomedical Engineering Letters*, 2016
- [17]. M. Bonamente, *Statistics and Analysis of Scientific Data*. Springer Science+Business Media New York 2013, 2013.
- [18]. Z. Z. Li Hu, *EEG Signal Processing and Feature Extraction*. Springer Nature Singapore Pte Ltd., 2019.
- [19]. H. Helgadóttir, O. Gudmundsson, G. Baldursson, P. Magnusson, and Blin, "Electroencephalography as a clinical tool for diagnosing and monitoring attention deficit hyperactivity disorder: A cross-sectional study," *BMJ Open*, vol. 5, p. e005500, 01 2015.
- [20]. Y. Z. Siuly Siuly, Yan Li, *EEG Signal Analysis and Classification*. Springer International Publishing., 2016.

Biografía de Autores

Iván Alejandro García Amaya. Obtuvo su grado en Ingeniería Mecatrónica por el Instituto Tecnológico de Durango en México, desde el 2019 es estudiante de la Universidad Autónoma de Querétaro en la Maestría en Ciencias en Inteligencia Artificial. Su investigación es relacionada al análisis de señales de electroencefalograma por medio de técnicas de Aprendizaje Maquina y Aprendizaje Profundo.

Marco Antonio Aceves Fernández. Obtuvo su grado en Ingeniería en Telemática por la Universidad de Colima en México. El obtuvo su Maestría y Doctorado por la Universidad de Liverpool en Inglaterra,



en Sistemas Inteligentes. Él es profesor de tiempo completo de la Facultad de Ingeniería en la Universidad de Querétaro México. Él es miembro del Sistema Nacional de Investigadores (SNI) desde 2009. El es presidente de la Asociación de Sistemas Embebidos (AMESE). Sus tópicos de investigación incluyen Sistemas Embebidos Inteligentes.

Saúl Tovar Arriaga. Obtuvo su grado en Ingeniería electrónica por el Instituto Tecnológico de Querétaro en México. Su grado en Maestro de Ciencias en Mecatrónica lo obtuvo por la Universidad de Siegen y su Doctorado por la Universidad de Erlangen Nuremberg, ambos en Alemania. Él es maestro de tiempo completo en la facultad de Ingeniería en la Universidad Autónoma de Querétaro y Coordinador de la Maestría en Ciencias en Inteligencia Artificial. El es miembro del sistema Nacional de Investigadores (SNI) desde el 2013. El es miembro de la Sociedad de Computación Inteligente IEEE de Querétaro. Sus tópicos de Investigación incluyen detección automática de enfermedades, cirugía robótica y aplicaciones de Aprendizaje Máquina.

Juan Manuel Ramos Arreguin. Obtuvo su grado en Ingeniería en Comunicaciones y Electrónica por la Universidad de Guanajuato. El obtuvo su grado en Maestría en Ingeniería eléctrica con opción en Instrumentación y Sistemas Digitales en la Universidad de Guanajuato y su grado de Doctor en Ciencias y Tecnología con especial en Mecatrónica por el Centro de Ingeniería y Desarrollo Industrial. Pertenece al Sistema Nacional de Investigadores (SNI). Es miembro de tiempo completo de la facultad de Ingeniería de la Universidad Autónoma de Querétaro. Sus tópicos de Investigación son Sistemas Inteligentes e Inteligencia Artificial.