

Estimación de la carga mental de trabajo mediante minería de redes electroencefalográficas



Colaboración

Alejandro Del Rey Torres Rodríguez, María Luisa Córdoba Tlaxcalteco, Leslie Imelda Callejas Dorantes, Pamela Stephanie Rivera Pérez, Arnulfo Gamaliel Hernández González, Tecnológico Nacional de México / Campus Misantla

RESUMEN: La evaluación de los estados mentales de los usuarios de productos y servicios, es una aplicación de la Neurociencia a disciplinas como el Neuromarketing. Recientemente esta evaluación se basa en datos biométricos, buscando garantizar un principio de objetividad en el análisis. En trabajos previos se ha mostrado asociación entre la carga mental de trabajo, un estado cognitivo relacionado con el nivel de interés y concentración, y características espectrales de las señales electroencefalográficas (EEG). En este artículo exploramos el uso de una técnica de Minería de datos, llamada Análisis Longitudinal de Redes (ALR), como herramienta para estimar la carga mental de trabajo en individuos que realizan operaciones aritméticas. El objetivo es doble. Por un lado, mostrar que existen diferencias significativas entre las estructuras de redes EEG, cuando los sujetos se encuentran en reposo y cuando se encuentran realizando operaciones aritméticas. El segundo objetivo de este trabajo es identificar cuáles son los aspectos de las redes EEG que están relacionados con la eficiencia de los sujetos para procesar la información. Los resultados, aunque no concluyentes, son prometedores. Y representan un parteaguas en la evaluación de la carga mental de trabajo, ya que es la primera aplicación del ARL en este asunto.

PALABRAS CLAVE: Análisis de Redes, Electroencefalografía, Carga mental de trabajo, Neurociencias, Minería de Redes.

ABSTRACT: The assessment of mental states of users of products and services is an application from Neuroscience to subjects like Neuromarketing. This evaluation is recently based on biometric data, seeking to guarantee a principle of objectivity in the analysis. Some previous works have shown an association between mental workload, a cognitive state related to the level of interest and concentration, and spectral characteristics of electroencephalographic (EEG) signals. This work explores the use of a data mining technique, called Longitudinal Network Analysis (ALR), as a tool for estimating mental workload in individuals who perform arithmetic operations. The objective is twofold. On one hand, to show that there are significant differences between the structures of EEG networks, when the subjects are at rest, and when they are performing arithmetic operations. The second objective is to identify which are the aspects of the EEG networks that are related to the efficiency of subjects to process the information. Our results, although not conclusive, are promising. And they represent a critic point in the assessment of mental workload, since this is the first application of the ARL on the subject.

KEYWORDS: Network analysis, Electroencephalography, Mental Workload, Neurosciences, Network mining.

INTRODUCCIÓN

En lo que sigue se presentarán los elementos del estudio de caso. Se utilizan los datos de una base de datos publicada en Internet. El concepto de carga mental de trabajo puede encontrarse en [2, 3]. La descripción del ALR se encuentra en [4, 5]

MATERIAL Y MÉTODOS

Descripción de los datos y su preprocesamiento

Los datos utilizados se encuentran publicados en [1], y están contenidos en un archivo con formato EDF. Los datos se registraron de 4 sujetos sanos voluntarios de igual edad, todos los cuales son estudiantes del Centro Educativo y Científico "Instituto de Biología y Medicina", Universidad Nacional Taras Shevchenko de Kiev (Ucrania); las grabaciones están disponibles a través de la plataforma Physiobank. Corresponden a los registros de un electroencefalograma de 21 ca-

nales, con montaje del tipo "10-20". Los electrodos son FP1, FP2, F3, F4, C3, C4, P3, P4, O1, O2, F7, F8, T3, T4, T5, T6, A1, A2, Fz, Cz y Pz. Cada grabación incluye segmentos de EEG libres de artefactos separados de 180 s para el estado de reposo y 60 s para conteo mental. El conjunto de datos se recopiló para investigar la correlación del EEG de la actividad mental, durante una tarea cognitiva intensa (tarea aritmética mental: resta en serie).

Para cada electrodo, está registrada una señal que consta de 1,179,000 registros, con frecuencia de muestreo de 500 muestras por segundo. En cada canal se utiliza la componente alfa (8-12 Hz). En este trabajo se analizaron los 3 minutos de reposo del registro, divididos en 10 ventanas de tiempo, y con una superposición entre ventanas del 25%. De manera similar, se analizó el primer minuto del periodo de cálculo aritmético, dividido en 10 ventanas de tiempo, con un traslape entre ellas del 25%.

Descripción del ALR

El AR que se aplica en este trabajo está inspirado en [6]. Primero se estima la matriz llamada Magnitude Square Coherence (MSC) como una medida de conectividad multicanal. Para explicarla, se considera que dada una frecuencia f , y dos canales x , y , la coherencia MSC entre los canales x y y se define por:

$$MSC_{xy}(f) = \frac{|P_{xy}(f)|^2}{P_{xx}(f)P_{yy}(f)} \quad \text{Ec. (1)}$$

Donde $P_{xx}(f)$ y $P_{yy}(f)$ son las densidades espectrales de la función de autocorrelación de los respectivos canales, y $P_{xy}(f)$ es la densidad espectral de la autocorrelación cruzada entre canales. Para el cálculo de las densidades espectrales se hace uso del método de Welch [7], donde la densidad espectral se calcula por:

$$P(f) = \frac{1}{f_s L_s U} \int_{-f_s/2}^{f_s/2} D_{xx}(\rho) |W(f - \rho)|^2 d\rho \quad \text{Ec. (2)}$$

D_{xx} es la Transformada Discreta de Fourier de la función de autocorrelación de la señal, f_s es la frecuencia de muestreo, L_s es la longitud del segmento y U es una constante de corrección que hace a $P(f)$ un estimador insesgado de la densidad espectral de la función de autocorrelación. Finalmente, $W(f - \rho)$ es la ventana de Hamming centrada en la frecuencia f . La matriz MSC se calcula para la banda de frecuencia alfa (8-12 Hz). Como resultado de estos conceptos, la matriz MSC resultante es de 22 filas y 22 columnas. El uso de medidas espectrales lleva implícito el supuesto de que los canales son señales estadísticamente estacionarias. Por lo tanto, se realiza la división de las señales multicanal en ventanas de tiempo, con 25% de superposición. Como se utilizan 20 ventanas (10 en reposo, y 10 en actividad aritmética), en cada sujeto se obtienen 20 matrices MSC, con las dimensiones mencionadas previamente. Los parámetros a comparar entre sujetos son el coeficiente de agregación ponderado (C_w) y el promedio ponderado de la longitud de ruta (L_w). Para el canal i , el coeficiente ponderado de agrupamiento se define por:

$$C_i = \frac{\sum_{k \neq i} \sum_{l \neq i, l \neq k} w_{ik} w_{il} w_{kl}}{\sum_{k \neq i} \sum_{l \neq i, l \neq k} w_{ik} w_{il}} \quad \text{Ec. (3)}$$

con $0 \leq w_{ij} \leq 1$, la entrada en la fila i , columna j , de la matriz MSC. La medida global de conectividad de la red es el coeficiente de agrupamiento medio, que se define como:

$$C_w = \frac{1}{N} \sum_{i=1}^N C_i \quad \text{Ec. (4)}$$

Con N el número total de canales. Para el canal i y el canal j , la longitud ponderada de la trayectoria entre i y j (denotada por L_{ij}) se define como la inversa de la entrada en la fila i , columna j de la matriz MSC. Esto es $L_{ij} = 1/w_{ij}$ si $w_{ij} \neq 0$, y $L_{ij} = \infty$ si $w_{ij} = 0$. El promedio de las longitudes ponderadas de todo el gráfico se calcula como:

$$L_w = \left(\frac{1}{N(N-1)} \sum_{i=1}^N \sum_{j \neq i, j=1}^N \frac{1}{L_{ij}} \right)^{-1} \quad \text{Ec. (5)}$$

De esta forma, por cada ventana temporal se calcula la pareja (C_w, L_w), dando como resultado 20 parejas de parámetros de conectividad, ordenados en forma temporal. Los elementos básicos del análisis lineal estadístico, descritos por [8] son:

- Una variable de intervalo, con espacio de valores en toda la recta real, que cambia sistemáticamente a través del tiempo.
- La variable es medida en cada sujeto, en tres o más instantes del tiempo.
- Una unidad de tiempo relevante al fenómeno que se estudia, tomando en cuenta su cadencia y velocidad de cambio.
- El objetivo es describir estadísticamente la forma en que la población de sujetos cambia a través del tiempo, reflejado este cambio por la dinámica de la variable. En lo que se refiere al primer aspecto, la variable de intervalo es el logito de C_w , definido por [9]:

$$\text{logito}(C_w) = \log \left(\frac{C_w}{1 - C_w} \right) \quad \text{Ec. (6)}$$

O bien el logaritmo de L_w . Ambas transformaciones tienen la finalidad de obtener variables-respuesta en toda la recta real. Por lo que se refiere al segundo punto, la unidad de tiempo elegida es el logaritmo del número de ventana, que son 10 en cada periodo (reposo - actividad). De manera preliminar (aunque esto no es una limitante), se utiliza un modelo lineal como sigue. Sea Y la variable-respuesta, y X el instante del tiempo. El modelo lineal elegido es

$$Y = \beta_0 + \beta_1 X + \epsilon \quad \text{Ec. (7)}$$

Donde ϵ es una variable aleatoria normal con media cero y varianza desconocida. Los parámetros (β_0, β_1) son el intercepto y la inclinación, respectivamente. La hipótesis sobre ϵ es verificada mediante el histograma de los residuales estandarizados. El carácter jerárquico del análisis reside en la suposición de que las parejas de estimadores de máxima verosimilitud de (β_0, β_1), son observaciones de una distribución normal bivariada. Este último aspecto será analizado en un informe futuro. El procesamiento de los

datos fue desarrollado en una interfaz elaborada específicamente para el ALR, en el entorno de programación Python.

RESULTADOS

Las siguientes gráficas muestran algunos de los resultados obtenidos. Por ejemplo, en estas gráficas se muestran las redes obtenidas en un participante considerado poco eficiente en el cálculo aritmético. Se muestran 9 de las 10 ventanas de tiempo, durante el periodo de estado basal (figura 1), y durante la actividad aritmética (figura 2), para el mismo individuo. El cambio en las conexiones de las gráficas señala cambios en la conectividad topográfica de los electrodos.

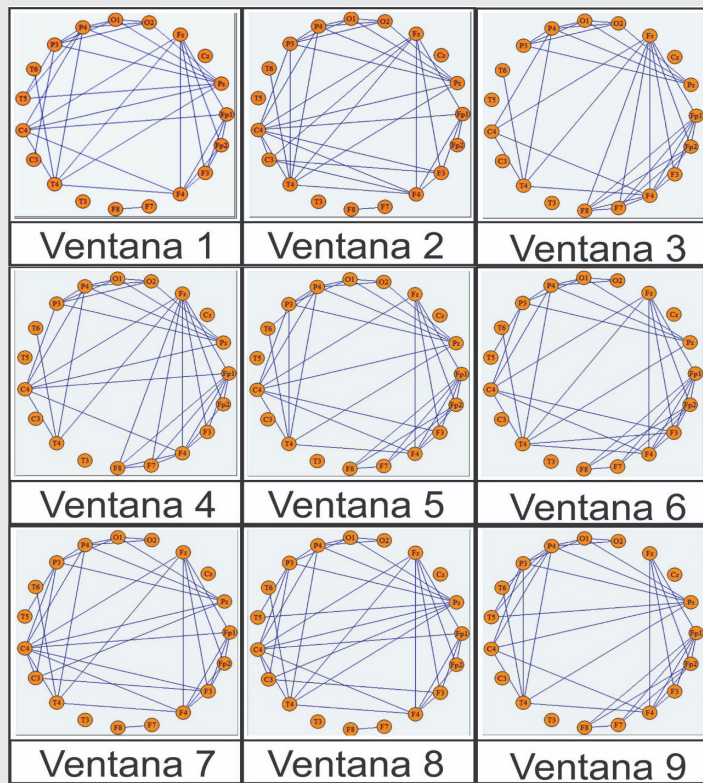


Figura 1. Gráficas de redes circulares con los datos EEG de un participante, durante el periodo de reposo.

Fuente: Elaboración propia.

Los gráficos longitudinales del Coeficiente de agrupamiento C_w se presentan a continuación. En la figura 3 se muestra el logito de C_w , ecuaciones 4 y 6, en el periodo de reposo. Se aprecia el carácter casi estacionario de las 4 series de logitos. En la figura 4 se muestran estos valores, para el periodo de actividad aritmética. Se aprecia un incremento en los valores con respecto del estado basal, lo que se interpreta como una mayor conectividad de las redes, cuando la carga de trabajo es mayor. Esto es consistente con lo mostrado en las figuras 1 y 2.

A continuación, se muestran los gráficos del logaritmo de la distancia promedio ponderada L_w , ecuación 5. En la figura 5 se muestran los valores en el periodo de reposo,

y en la ecuación 6 los valores en el periodo de actividad aritmética. El contraste es nuevamente el carácter casi estacionario en el reposo, mientras que las actividades aritméticas introducen mayores variaciones en las distancias promedio entre canales o electrodos.

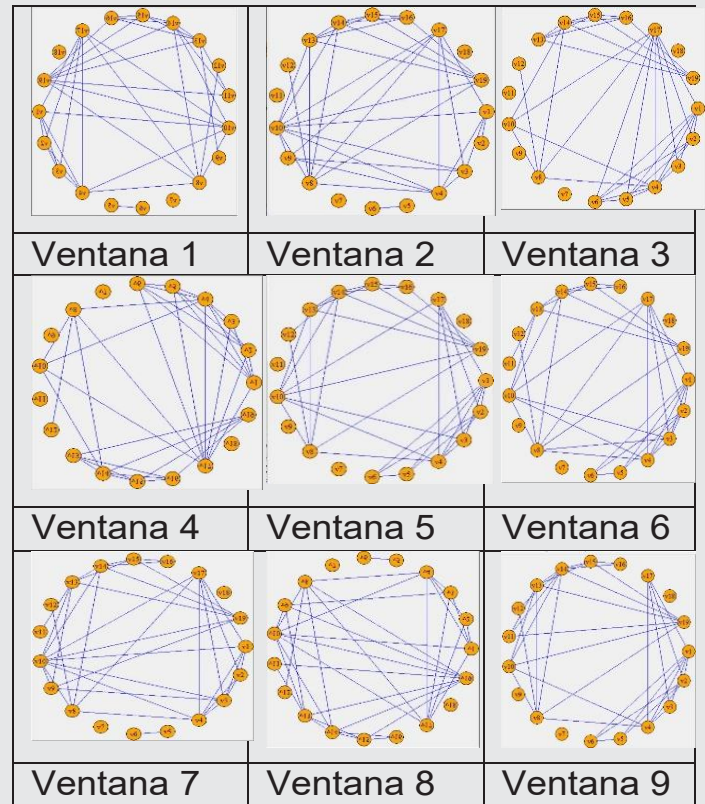


Figura 2. Gráficas de redes circulares con los datos EEG de un participante, durante el periodo de actividad aritmética.

Fuente: Elaboración propia.

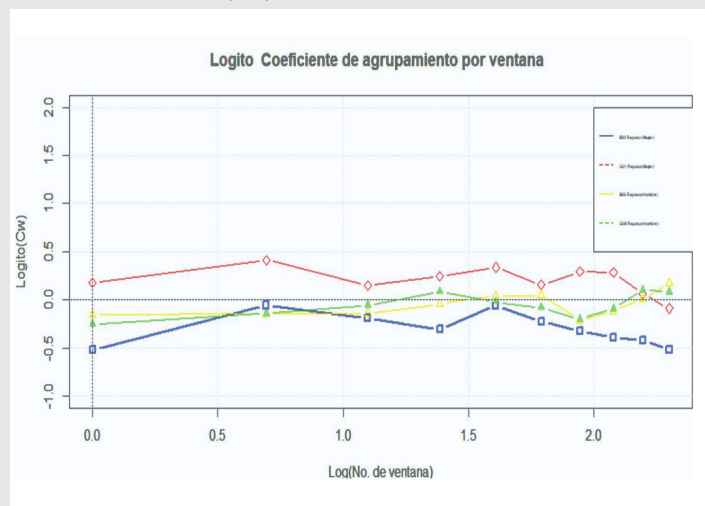


Figura 3. Logito de C_w , durante el periodo de reposo. La serie es casi estacionaria, en los 4 individuos.

Fuente: Elaboración propia.

Los resultados del ajuste del modelo de regresión, ecuación 7, se muestran en la Tabla 1. La letra B, por ejemplo B00, indica que el sujeto es catalogado como inhábil en Aritmética. Por el contrario, la letra G indica que el sujeto

es catalogado como hábil en Aritmética. Los resultados mostrados señalan que no hay diferencia apreciable en la conectividad de las redes EEG, entre los sujetos hábiles y los inhábiles.

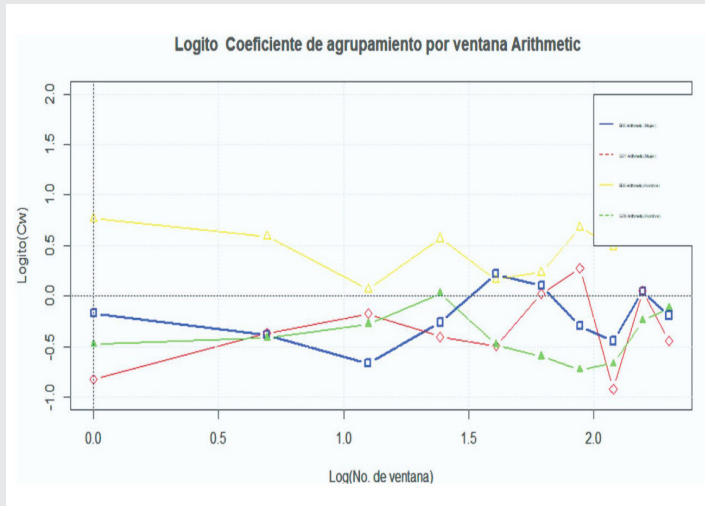


Figura 4. Logito de C_w , durante el periodo de actividad aritmética, en los 4 individuos. Fuente: Elaboración propia



Figura 5. Logaritmo de L_w , durante el periodo de reposo, en los 4 individuos. Las series son casi estacionarias Fuente: Elaboración propia

Tabla 1. Datos comparativos del modelo de regresión ajustado. No se aprecia diferencia significativa entre los hábiles e inhábiles en Aritmética.

Sujeto	Logito(C_w)		Log(L_w)	
	β_0	β_1	β_0	β_1
B00 (mujer)	0.920	0.004	-0.499	0.498
G01 (mujer)	0.470	0.173	-0.298	0.177
B06 (hombre)	0.523	0.040	-0.507	0.796
G08 (hombre)	0.578	0.090	0.5167	0.834

Fuente: Elaboración propia.




Figura 6. Logaritmo de L_w , durante el periodo de actividad aritmética, en los 4 individuos. La fluctuación es mayor, con respecto del periodo basal. Fuente: Elaboración propia.

Finalmente, los supuestos estadísticos de los modelos de regresión son evaluados en las siguientes 2 figuras. Se aprecia que el caso de C_w , los supuestos del modelo de regresión son consistentes con los datos, no así en el caso de L_w , donde se aprecia una distribución de probabilidad no simétrica.

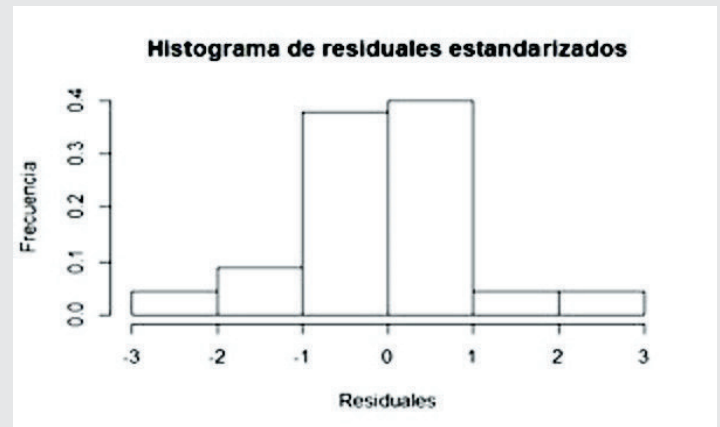
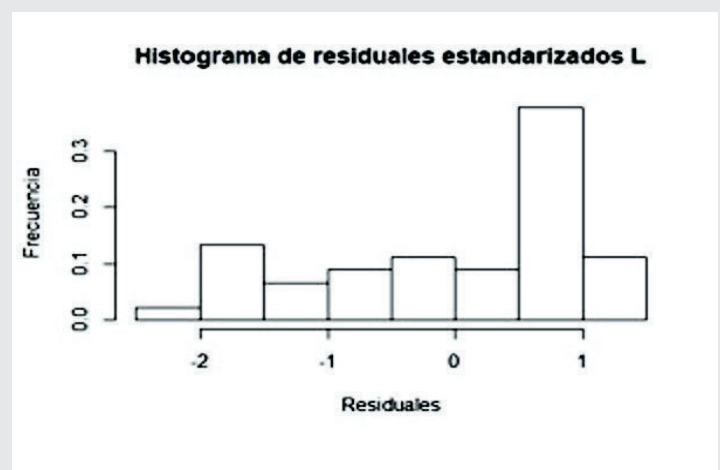


Figura 7. Histograma de residuos estandarizados en el modelo de regresión de C_w . Los supuestos del modelo son consistentes con los datos. Fuente: Elaboración propia.



regresión de L_w . Los supuestos del modelo no son consistentes con los datos. Elaboración propia.

CONCLUSIONES

Del análisis de los datos, se aprecia que los parámetros básicos de las redes EEG son diferentes en el reposo, y en la actividad aritmética. Esto sugiere que el uso del ALR para medir la carga mental de trabajo es una línea de trabajo para desarrollar en el futuro. Por otra parte, los resultados del modelo de regresión lineal no muestran que los individuos catalogados como hábiles (1 mujer y 1 hombre), sean diferentes de manera significativa a los obtenidos con los sujetos catalogados como inhábiles (1 mujer y 1 hombre). Desde el punto de vista de la evaluación de la concentración o nivel de dificultad de las tareas, esto es más bien oportuno, dado que la actividad de las redes no parece depender del nivel de adecuación individual, sino más bien corresponde completamente a la tarea.

BIBLIOGRAFÍA

[1] Zyma, I., Tukaev, S., Seleznov, I., Kiyono, K., Popov, A., Chernykh, M., & Shpenkov, O. (2019). *Electroencephalograms during mental arithmetic task performance*. *Data*, 4(1), 14.

[2] Ghani, U., Signal, N., Niazi, I., & Taylor, D. (2020). *ERP based measures of cognitive workload: A Review*. *Neuroscience & Biobehavioral Reviews*.

[3] Iqbal, M. U., Srinivasan, B., & Srinivasan, R. (2020). *Dynamic assessment of control room operator's cognitive workload using Electroencephalography (EEG)*. *Computers & Chemical Engineering*, 141, 106726.

[4] Miers, A. C., Weeda, W. D., Blöte, A. W., Cramer, A. O., Borsboom, D., & Westenberg, P. M. (2020). *A cross-sectional and longitudinal network analysis approach to understanding connections among social anxiety components in youth*. *Journal of Abnormal Psychology*, 129(1), 82.

[5] Stone, J., Developers, N. T., Eargle, J., Sethi, A., Li, L., & Luthey-Schulten, Z. (2012). *Dynamical Network Analysis*.

[6] Alducin Castillo, J., Yáñez Suárez, O., & Brust Carmona, H. (2016). *Análisis electroencefalográfico de la conectividad funcional en habituación por teoría de gráficas*. *Revista mexicana de ingeniería biomédica*, 37(3), 181-200.

[7] Parhi, K. K., & Ayinala, M. (2013). *Low-complexity Welch power spectral density computation*. *IEEE Transactions on Circuits and Systems I: Regular Papers*, 61(1), 172-182.

[8] Raudenbush, S. W., & Bryk, A. S. (2002). *Hierarchical linear models: Applications and data analysis methods (Vol. 1)*.

[9] Ashton, W. D. (1972). *logit transformation with special reference to its uses in bioassay*.