

Interfaz cerebro-computadora para la codificación de clave morse mediante señales cerebrales

Brain-computer interface for morse code interpretation through brain signals

J. A. Garza-Abdala ^a, E. Escamilla-Hernandez ^a, L. E. Ramos-Velasco ^b, E. Garcia-Rios ^c,
O. V. Kravchenko ^d

^a Sección de Estudios de Posgrado e Investigación, ESIME Culhuacan, Av Santa Ana 1000, Edif 2 Piso 3, San Francisco Culhuacan, Culhuacan CTM V, Coyoacan, 04440, Ciudad de México, Mex.

^b Universidad Politécnica Metropolitana de Hidalgo, Maestría en Ingeniería Aeroespacial, Ex Hacienda San Javier, Tolcayuca 1009, 43860, Tolcayuca, Hgo.

^c Instituto Tecnológico Superior del Occidente del Estado de Hidalgo 7ma Demarcación, 42700, Mixquiahuala, Hgo.

^d Universidad Técnica Estatal de Bauman de Moscú, Instituto de Investigación de Ingeniería Mecánica de RAS, 2-Ya Baumanskaya Utilisa, 105005, Moscú, Rusia.

Resumen

La necesidad de poder ofrecer a personas con discapacidad del habla un sistema de comunicación de una manera mucho más efectiva nos lleva a realizar el presente trabajo donde se presenta un decodificador de parpadeos en código Morse. Para lograr la meta deseada se obtienen señales cerebrales utilizando el casco EMOTIV Insight. Los canales utilizados son: AF3, AF4, ya que, cuando se observan un electroencefalograma (EEG), éstos muestran la mayor perturbación comparada con otros canales. Posteriormente, se realiza el filtrado de los canales con un filtro FIR, el cual es diseñado utilizando diferentes funciones de ventana tanto clásicas como algunas simétricas y asimétricas basadas en la teoría de Funciones Atómicas (AF), con el fin de hacer una comparación de los resultados al usar diferentes funciones de ventana. Los resultados muestran una mejor clasificación del tipo de parpadeos debido a una mejor respuesta en frecuencia del filtro FIR al usar funciones de ventana basadas en la teoría de AF.

Palabras Clave: BCI, EMOTIV Insight, ventana asimétrica, EEG, clave morse.

Abstract

The necessity to offer a much effective communication way to people with speech disabilities leads us to do the do work where a Morse code blink-decoder is presented. To achieve the desired goal, brain signals were obtained using the brainwear EMOTIV Insight. The used channels are AF3 and AF4 since those are the channels where the wave perturbation is greater than other channels when observed in an electroencephalogram (EEG). Afterwards, the channels are filtered with a FIR filter, which is designed using different window functions such as classic, symmetric, and asymmetric functions based on the Anatomic Functions (AF) theory, with the objective to make a comparison of the results using different window functions. The results show a better classification of the blink type due to a better frequency response of the FIR filter using the AF as window.

Keywords: BCI, EMOTIV Insight, asymmetric window, EEG signals, morse code.

1. Introducción

El cerebro es el órgano más complejo del cuerpo, ya que es el encargado de diversas funciones, tales como el movimiento, el habla, el procesamiento de emociones, entre muchas otras. Una forma no invasiva para estudiarlo es emplear una interfaz cerebro-computadora (BCI). La principal función de una BCI

es poder convertir el comportamiento consciente del paciente en datos para su manipulación y, eventualmente, transformarlo en comandos. El primer paso es extraer la señal mediante un método de examinación neurológica llamado electroencefalografía (EEG), el cual consta de medir el potencial eléctrico. La señal cerebral es adquirida por diversos electrodos colocados en la cabeza, generalmente utilizando el

*Autor para la correspondencia: jgarzaa2000@alumno.ipn.mx

Correo electrónico: jgarzaa2000@alumno.ipn.mx (Jorge Alberto Garza-Abdala), eescamillah@ipn.mx (Enrique Escamilla-Hernandez), lramos@upmh.edu.mx (Luis Enrique Ramos-Velasco), egarcia@itsoeh.edu.mx (Elizabeth Garcia-Rios), olekravchenko@gmail.com (Oleg Victorovich Kravchenko).

Sistema Internacional 10/20 (Atif Hassan and Mehdi Rizvi, 2008), (Koudelková and Strmiska, 2018), (Xie and Oniga, 2020).

La frecuencia de las ondas cerebrales es el criterio más importante para la evaluación del EEG puesto que en ellas se aprecian los patrones, así como cualquier anomalía que pueda existir (*5 Types Of Brain Waves Frequencies: Gamma, Beta, Alpha, Theta, Delta - Mental Health Daily*, 2014). La Tabla 1 muestra estas ondas con su rango correspondiente.

Tabla 1: Ondas cerebrales con su rango correspondiente.

Onda	Rango [Hz]
Delta	0 – 4
Theta	4 – 8
Alpha	8 – 12
Beta	12 – 40
Gamma	40 – 100

1.1. Filtrado de EEG

El siguiente paso es filtrar la señal para eliminar las frecuencias no deseadas en el estudio, o bien, extraer solamente las componentes necesarias. Los tipos de filtro más comunes son los pasa-baja, pasa-alta, pasa-banda, dependiendo de las frecuencias de análisis deseadas. Generalmente el filtrado digital se realiza con un filtro de respuesta finita (FIR), cuya salida se calcula con (1). Donde el valor de N es el orden del filtro, los valores de C_k $C_{k,n}$ los coeficientes del filtro, mientras que X_j y Y_j son los j -ésimos términos de entrada y salida, respectivamente (Bansal et al., 2018):

$$Y_j = \sum_{k=0}^{k \leq N} C_k X_{j-k} \quad (1)$$

Los coeficientes C_k , son determinados por la frecuencia de muestreo y una función de suavidad llamadas comúnmente función de ventana, tales como la de Hamming, Hanning o Blackman, para su funcionamiento adecuado. Estas ventanas son un tipo de función que establecen que, si se elige un intervalo, la ventana regresará un valor finito y diferente de cero dentro de ese intervalo y cero fuera de éste.

Una ventana clásica llamada de Hamming es definida como:

$$w(n) = \alpha - \beta \cos\left(\frac{2\pi n}{N-1}\right), -\frac{N-1}{2} \leq n \leq \frac{N-1}{2} \quad (2)$$

Con $\alpha = 0.54$ y $\beta = 0.46$ (Podder et al., 2014).

No obstante, el análisis armónico eficiente requiere encontrar funciones de ventana con el lóbulo principal lo más plano posible y con una atenuación máxima de los lóbulos laterales (Harris, 1978), (Nuttall, 1981).

Asimismo, un tema de investigación son las Funciones Atómicas (AF's) las cuales comenzaron a ser estudiadas en 1963. Éstas funciones presentan una gran variedad de aplicaciones como se muestran en (Brysina et al., 2018), (Budunova and Kravchenko, 2021), (Hernandez-Matamoros et al., 2020), (Kravchenko et al., 2009, 2020), (Perez-Daniel et al., 2013), (Ponomarev et al., 2009).

La AF utilizada en el presente trabajo, llamada $up(x)$, se genera por medio de la convolución infinita de impulsos rectangulares y está definida cómo:

$$up(x) = \frac{1}{2\pi} \int_{-\infty}^{\infty} e^{j\omega x} \prod_{k=1}^{\infty} \frac{\text{sen}(\omega \cdot 2^{-k})}{\omega \cdot 2^{-k}} d\omega \quad (3)$$

Sin embargo, para eficientizar la obtención de los coeficientes del filtro, (3) se puede expresar como:

$$up(x) = 0.5 + \sum_{k=1}^{\infty} up(\pi k) \cos(\pi(2k-1)x) \quad (4)$$

Algunas propiedades de esta función de ventana son

- i. $up(x) = up(-x)$ (5)
- ii. $\int_{-1}^1 up(x) dx = 1$ (6)
- iii. $up(x) = 1 - up(1-x)$ (7)
- iv. $up'(x) = 2 \cdot up(x)(2x+1) - 2 \cdot up(2x-1)$ (8)

Donde $up'(x)$ indica la derivada de $up(x)$ con respecto al tiempo. Adicionalmente, otra propiedad de suma importancia de las ventanas es la constante de incertidumbre, la cual sirve para tener una mejor localización tiempo-frecuencia (Kravchenko & Churikov, 2011). Ésta se calcula con:

$$\Delta_f = \frac{1}{\|f(t)\|} \sqrt{\int_{-\infty}^{\infty} (t-t^*)^2 |f(t)|^2 dt} \quad (9)$$

$$t^* = \frac{1}{\|f(t)\|^2} \int_{-\infty}^{\infty} t |f(t)|^2 dt \quad (10)$$

La Figura 1 muestra las funciones de ventana $up(x)$ y Hamming junto con su espectro de frecuencia, así como una comparativa la ventana rectangular (sin añadirle una ventana extra al filtro). La amplitud máxima de los lóbulos laterales de $up(x)$ es de 23.2 dB por debajo del lóbulo principal un parámetro importante de estas funciones de ventana es la razón de decrecimiento asintótico de lóbulos laterales de menos infinito. Asimismo, la Tabla 2 muestra una comparación de estas dos ventanas.

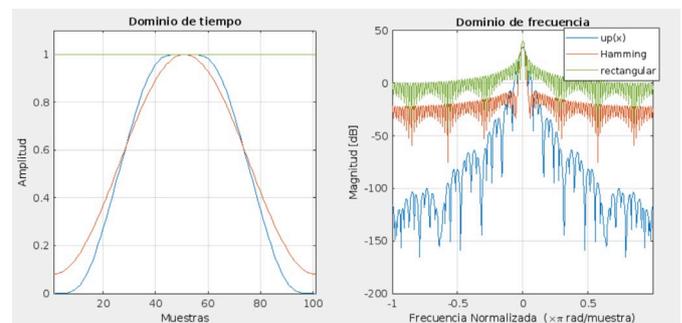


Figura 1: Comparación de ventanas: Hamming y $up(x)$.

Tabla 2: Comparación de propiedades de Hamming y $up(x)$.

Propiedad	Hamming	$up(x)$	Unidades
Amplificación coherente	0.54	0.5	
Amplitud máxima de lóbulos laterales	-43.24	-23.9	dB
Ancho de banda (-3 dB)	1.33	1.54	Bins
Razón de decrecimiento de lóbulos laterales	-6	-infinito	dB/oct
Constante de incertidumbre	0.2829	0.2714	

1.2. Selección de características

Después de haber filtrado la señal, se deben elegir las características. Para lograr esto existen varios métodos entre tales como: la densidad espectral de potencia (PSD), análisis de componentes principales (PCA), análisis de componentes independientes (ICA), la transformada rápida de Fourier (FFT) o la transformada wavelet (WT) (Xie and Oniga, 2020).

1.3. Clasificadores

Finalmente, dependiendo de las características seleccionadas, existen diferentes tipos de clasificadores. La Tabla 3 muestra un compilado de éstos con sus ventajas y desventajas.

Tabla 3: Tipos de clasificadores más comunes con sus ventajas y desventajas (Xie & Oniga, 2020).

Clasificador	Ventajas	Desventajas
Red neuronal artificial (ANN) y Deep learning	Alta precisión Estructura flexible.	Los resultados dependen del número de neuronas en la capa oculta
K-ésimo vecino más cercano (K-NN)	Fácil de entender. Sencillo de implementar.	Sensible a características irrelevantes y redundantes.
Análisis de discriminante lineal (LDA)	Fácil de usar	Requiere modelo lineal
Máquina de soporte vectorial (SVM)	Mejores resultados comparados con otros clasificadores lineares	Baja flexibilidad computacional
Naive Bayes (NB)	Fácil de entender	Variables independientes

1.4. Clave Morse

La clave Morse es un sistema de comunicación binario que consta de arreglos de puntos y guiones, con duración de 1 y 3

unidades de tiempo, respectivamente (*Morse Code Timing | Morse Code World*, n.d.). La combinación de éstos da como resultado un abecedario análogo al tradicional. Éste se puede ver en la Figura 2. Pese a que generalmente la clave Morse es utilizada en ámbito militar, esta también puede llegar a tener usos en BCI (Andriantsilavo et al., 202) and (Young et al., 2020).

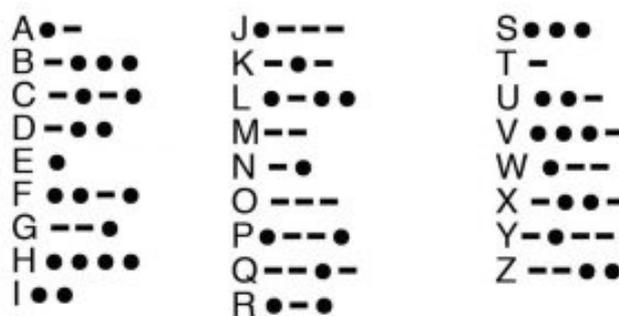


Figura 2: Abecedario en clave Morse (Vigo, 2020)

2. Modelo Propuesto

Para la elaboración de este experimento, se utilizó el casco EMOTIV Insight 2.0, es un sistema que cuenta con 5 sensores para señales cerebrales (AF3, AF4, TZ, T8 y Pz), así como dos referencias (CMS y DRL) y es capaz de detectar comandos mentales, métricas de desempeño y expresiones faciales. Para la investigación presente se utilizaron los primeros dos debido a que en ellos la onda cerebral muestra mayor perturbación a la hora de parpadear (EMOTIV Insight 2.0 - 5 Channel Mobile Brainwear® - EMOTIV, n.d.), (Wang et al., 2021). La Figura 3 muestra la comparación de los electrodos disponibles contra los utilizados.

2.1. Experimentación

El estudio se realizó en dos mujeres: una de 51 años (persona A) y otra de 22 (persona B). La persona B tiene diagnóstico de trastorno de déficit de atención e hiperactividad (TDAH), por lo que se buscaba comparar la respuesta entre ambas.

Para cada persona, se capturaron 30 muestras de parpadeos largos (PL) y 30 de parpadeos cortos (PC), ambas con el software del mismo proveedor: EMOTIVPRO. Cada tipo de parpadeo representó un símbolo de clave morse: guion y punto, respectivamente. Sin embargo, se utilizaron solamente 20 de cada una para el entrenamiento de los clasificadores y el resto para realizar las pruebas.

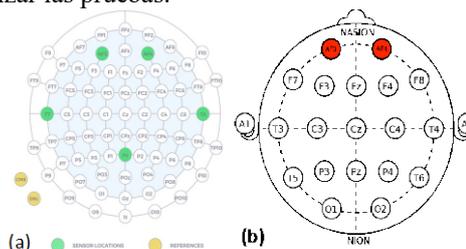


Figura 3: Comparación de esquema de electrodos: (a) Esquema de electrodos del EMOTIV Insight; (b) electrodos (EMOTIV Insight 2.0 - 5 Channel Mobile Brainwear® - EMOTIV, n.d.).

Las muestras constaron de aproximadamente entre 5 y 7 segundos. En el caso de PL (Figura 5), se empezaba a grabar y al segundo uno se cerraba el ojo, se dejaba cerrado durante tres segundos y se volvía a abrir en el segundo cuatro. Por su parte, PC (Figura 6) se empezaba a grabar y de igual forma se cerraba el ojo en el segundo uno; no obstante, éste se dejaba cerrado durante un segundo y se daba la indicación de abrirlo en el segundo dos. De tal forma que los tiempos fueran los más exactos posibles para así poder respetar la relación 3:1 que hay entre los guiones y puntos (*Morse Code Timing | Morse Code World*, n.d.).

La Figura 4 muestra PC en los canales AF3 y AF4. El aumento tan drástico que se da aproximadamente en el segundo y medio fue cuando se cerró el ojo, mientras que el cambio de pendiente que hay alrededor del segundo y medio es cuando se volvió a abrir.

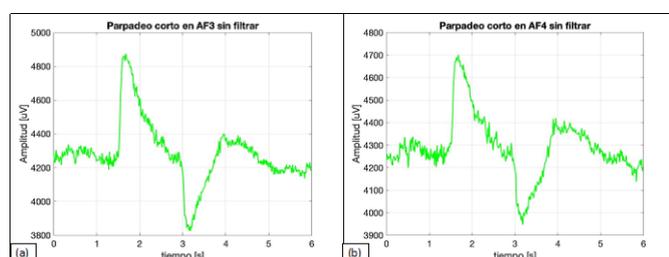


Figura 4: Ejemplo de PC sin filtrar: (a) PC en AF3; (b) PC en AF4.

De igual forma, se capturaron PL en los mismos canales, tal como lo muestra la Figura 5. En este caso, el pico de la señal que se da alrededor del segundo uno es cuando se le indicó a la persona que cerrara el ojo. Por el otro lado, cuando la persona abría de nuevo el ojo, aproximadamente en el segundo 4, era cuando llegaba a su mínimo.

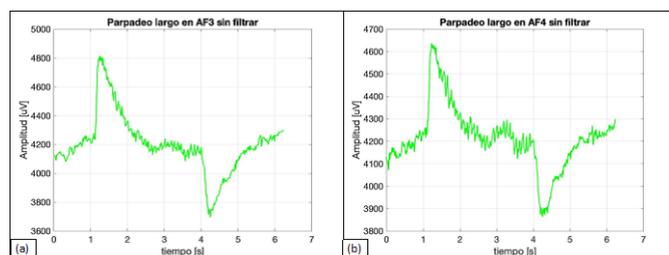


Figura 5: Ejemplo de PL sin filtrar: (a) PL en AF3; (b) PL en AF4.

Posteriormente, se aislaron los canales necesarios (AF3 y AF4) para poder tener mejor control de las muestras. Acto seguido, se utilizó el software MATLAB R2021a para poder interactuar con la señal. Primeramente, se utilizó un filtro FIR de orden 100 y, utilizando una ventana de Hamming calculada fuera de línea, y una frecuencia de corte normalizada de 0.1 Hz. La creación de la ventana y el filtrado de la señal se realizaron con las funciones *fir1()* y *filter()* propias de MATLAB. Acto seguido, se eliminaron los primeros 100 valores de la señal, ya que, al haber utilizado un filtro digital, éste genera un retraso en la señal de su mismo orden. Posteriormente, se obtuvieron las primeras dos características: voltaje máximo y mínimo. Adicionalmente, se calcularon los máximos y mínimos de la señal y se determinó que era necesario restarle un valor de 3700 para poder eliminar el offset del sistema y así normalizarlas

Luego se calculó tanto el voltaje promedio como área bajo la curva (usando el método de Riemann), teniendo así el dataset completo para el clasificador. Acto seguido, se utilizó la aplicación Classification Learner dentro de MATLAB para poder elegir el clasificador adecuado para el dataset de cada persona. Se entrenaron cuatro clasificadores para cada persona, dos utilizando el dataset directo, y otros dos aplicando PCA.

Finalmente, se repitió este mismo procedimiento, pero en lugar de usar la ventana de Hamming en el filtrado, se utilizó la ventana $up(x)$. Al no ser un filtro adaptivo, los coeficientes de la ventana se calcularon fuera de línea y se integraron al sistema. La Figura 6 presenta una comparación de la misma señal utilizando ambos filtros; la mayor diferencia que muestran es en los mínimos. En el caso de AF3, el mínimo absoluto se encuentra cuando se filtra la señal con la ventana $up(x)$, mientras que esto se invierte en AF4 donde el mínimo absoluto lo tiene la ventana de Hamming.

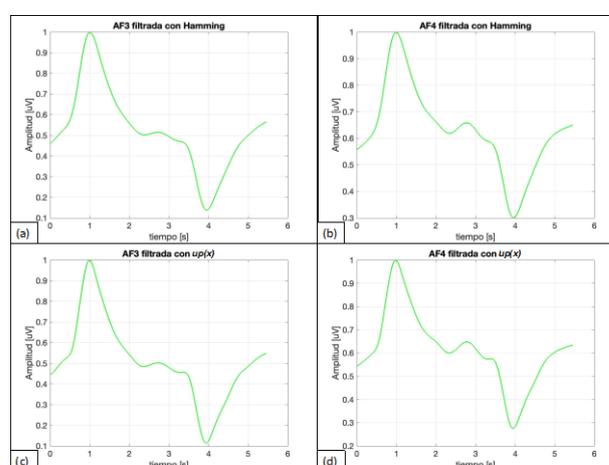


Figura 6: Comparación de filtros: (a) PL en AF3 y filtrado con Hamming; (b) PL en AF4 y filtrado con Hamming; (c) PL en AF3 y filtrado con $up(x)$ (d) PL en AF4 y filtrado con $up(x)$.

3. Resultados

Se entrenaron un total de ocho clasificadores para cada persona, cuatro con ventana de Hamming y cuatro con ventana $up(x)$. En el caso de la persona A, para los primeros clasificadores, hubo una media de aciertos del 68.12%, teniendo como máximo 77.5% con una SVM y como mínimo 55% utilizando un Discriminante Cuadrático (QD), tal como lo muestra la Tabla 4.

Tabla 4: Resultados de los clasificadores de la persona A y ventana de Hamming.

Número	Tipo clasificador	de Aciertos	Porcentaje de aciertos	PCA
1	SVM	31	77.5%	No
2	QD	22	55%	No
3	SVM	29	72.5%	Sí
4	NB	27	67.5%	Sí

De igual forma, los clasificadores tuvieron tendencia a detectar mejor PL, tal como lo muestran las matrices de confusión en la Figura 7.

Figura 7. Matrices de confusión para persona A y Hamming: (a) Matriz de confusión del clasificador 1; (b) Matriz de confusión del clasificador 2; (c) Matriz de confusión del clasificador 3; (d) Matriz de confusión del clasificador 4.

Figura 8. Matrices de confusión para persona A y $up(x)$: (a) Matriz de confusión del clasificador 1; (b) Matriz de confusión del clasificador 2; (c) Matriz de confusión del clasificador 3; (d) Matriz de confusión del clasificador 4.

Adicionalmente, la Tabla 5 muestra la precisión, sensibilidad y F1 Score de cada uno de los clasificadores.

Tabla 5. Precisión, sensibilidad y F1 score de los clasificadores para la persona A y ventana de Hamming.

Número	Precisión	Sensibilidad	F1 score
1	0.65	0.8667	0.7429
2	0.95	0.5278	0.6786
3	0.6	0.8	0.6857
4	0.6	0.7059	0.6486

Por el otro lado, cuando se utilizó la ventana $up(x)$, se consiguió incrementar el promedio de aciertos hasta un 75%. De igual forma, el máximo siguió siendo 77.5% usando un QD, mientras que el mínimo incrementó a 67.5% con NB Gaussiano. La Tabla 6 muestra los clasificadores entrenados.

Tabla 6: Resultados de los clasificadores en persona A y ventana $up(x)$.

Número	Tipo de clasificador	de Aciertos	Porcentaje de aciertos	PCA
1	QD	31	77.5%	No
2	QD	31	77.5%	No
3	NB Gaussiano	27	67.5%	Sí
4	QD	31	77.5%	Sí

Asimismo, se calcularon las matrices de confusión se calcularon las matrices de confusión y la tendencia a detectar mejor PL se mantuvo, como se puede apreciar en la Figura 8.

Finalmente, se realizaron los cálculos de la precisión, sensibilidad y F1 score, así como se aprecia en la Tabla 7.

Tabla 7: Precisión, sensibilidad y F1 score de los clasificadores para la persona A y ventana $up(x)$.

Número	Precisión	Sensibilidad	F1 score
1	0.55	1	0.7097
2	0.55	1	0.7097
3	0.6	0.7059	0.6886
4	0.55	1	0.7097

Igualmente se entrenaron ocho clasificadores para la persona B, cuatro utilizando la ventana de Hamming y cuatro la ventana $up(x)$. Para los primeros, se obtuvo un promedio de aciertos del 53.75%. De igual forma, el máximo se dio utilizando un NB, llegando a 60% de aciertos; mientras que el mínimo fue con una ANN y 47.5% de aciertos. La Tabla 8 muestra más a detalle los datos.

Tabla 8: Resultados de los clasificadores de la persona B y ventana de Hamming.

Número	Tipo de clasificador	de Aciertos	Porcentaje de aciertos	PCA
1	ANN	21	52.5%	No
2	ANN	22	55%	No
3	ANN	19	47.5%	Sí
4	NB	24	60%	Sí

En general, los clasificadores detectaban mejor PC, no obstante, la diferencia entre la detección de cortos y largos era muy poca, así como se ve en la Figura 9.

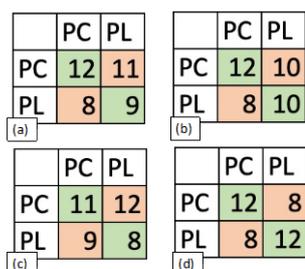


Figura 9: Matrices de confusión para persona B y Hamming: (a) Matriz de confusión del clasificador 1; (b) Matriz de confusión del clasificador 2; (c) Matriz de confusión del clasificador 3; (d) Matriz de confusión del clasificador 4.

Se repitieron los cálculos de precisión, sensibilidad y F1 score, tal como se ve en la Tabla 9.

Tabla 9: Precisión, sensibilidad y F1 score de los clasificadores para la persona B y ventana de Hamming

Número	Precisión	Sensibilidad	F1 score
1	0.6	0.5217	0.2625
2	0.6	0.5714	0.275
3	0.55	0.4782	0.5116
4	0.6	0.6	0.6

Se pudo observar un aumento de porcentaje de aciertos al usar AF $up(x)$, ya que el máximo llegó hasta el 70% mientras que el mínimo fue de 62.55%. De igual forma se destaca que el promedio de aciertos en los cuatro clasificadores fue de 63.75%. La Tabla 10 describe esta información.

Tabla 10: Resultados de los clasificadores de la persona B y ventana $up(x)$.

Número	Tipo de clasificador	de Aciertos	Porcentaje de aciertos	PCA
1	ANN	27	67.5%	No
2	Regresión logística	28	70%	No
3	K-NN	25	62.5%	Sí
4	ANN Bicapa	27	67.5%	Sí

Comparando las detecciones que había con la ventana de Hamming, este segundo conjunto de clasificadores tenía una ligera tendencia a poder detectar mejor PC, como se puede observar en la Figura 10.

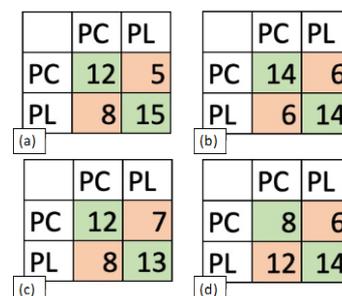


Figura 10: Matrices de confusión para persona B y $up(x)$: (a) Matriz de confusión del clasificador 1; (b) Matriz de confusión del clasificador 2; (c) Matriz de confusión del clasificador 3; (d) Matriz de confusión del clasificador 4.

Finalmente, se calculó la precisión, sensibilidad y F1 score de cada uno de los clasificadores y los resultados se pueden apreciar en la Tabla 11.

Tabla 11: Precisión, sensibilidad y F1 score de los clasificadores para la persona B y ventana de $up(x)$.

Número	Precisión	Sensibilidad	F1 score
1	0.6	0.7059	0.6486
2	0.7	0.7	0.7
3	0.6	0.6316	0.6154
4	0.4	0.5714	0.4706

4. Discusión

Al cambiar la ventana de Hamming por AF $up(x)$, al diseñar los filtros FIR, los clasificadores de la persona A tuvieron mejor respuesta en conjunto ya que, a pesar de no haber aumentado el porcentaje máximo de reconocimiento (77.5%), sí pudo replicarse más veces este valor. Adicionalmente, se aumentó el porcentaje mínimo ya que este pasó de 55% a 67.5%. Esto también supuso un incremento del promedio total de aciertos; pasó de 68.125% a 75%. De igual forma se pudo observar un aumento en la precisión, sensibilidad y F1 score de cada uno de los clasificadores entrenados.

Por el otro lado, los clasificadores de la persona B también tuvieron un mejor desempeño, esta vez tanto individual como colectivo. El porcentaje máximo de reconocimiento pasó de 60% a 70%, mientras que el mínimo aumentó de 47.5% a 55%. Con estos incrementos de aciertos, el promedio de los clasificadores pasó de 53.75% a 63.75%. En esta ocasión, 3 de las 4 precisiones calculadas aumentaron, siendo la última la que disminuyó. Este mismo patrón continuó en la sensibilidad, es decir, los primeros tres aumentaron su valor y el último lo disminuyó. Por consecuencia a esto cambios, el F1 score se vio modificada de la misma manera.

Observando las señales EEG de la persona A, se pudo apreciar que las ondas seguían un patrón bien definido. Ya sea en PC o en PL, en ambos se podía ver eso, tal como se puede

observar en la Figura 11. Adicionalmente, la persona A reportó haber tenido dolor de cabeza durante la toma de PC, así como haberse encontrado relajada durante la toma de todas sus muestras.

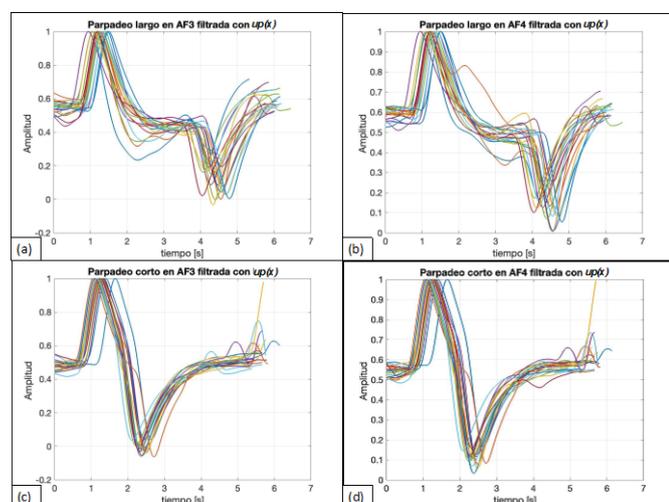


Figura 11: Señales EEG para persona A filtradas con $up(x)$, sin offset y normalizadas: (a) Señal de PL en AF3; (b) Señal de PL en AF4; (c) Señal de PC en AF3; (d) Señal de PC en AF4.

Por el otro lado, la persona B mostró señales EEG mucho más diversas (Figura 12). En este caso, para PL sí se podía ver un patrón más definido de onda. En cambio, en PL es notorio el nulo patrón. Durante la toma de PC, la persona B reportó dolor de cabeza y, al igual que la persona A, mencionó que durante la toma de todas las muestras se encontraba relajada.

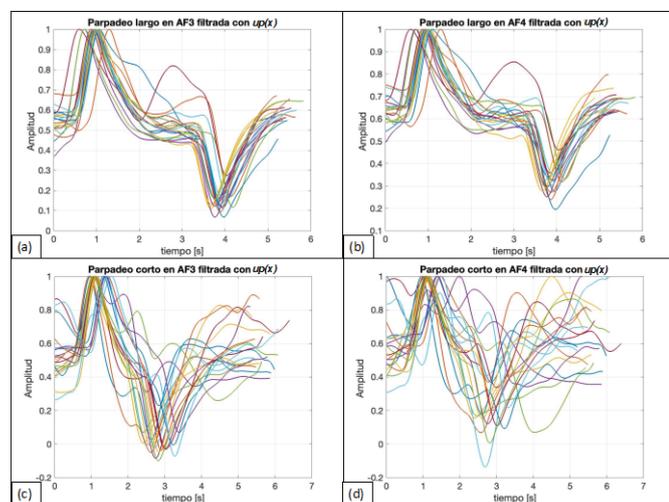


Figura 12: Señales EEG para persona B filtradas con $up(x)$, sin offset y normalizadas: (a) Señal de PL en AF3; (b) Señal de PL en AF4; (c) Señal de PC en AF3; (d) Señal de PC en AF4.

5. Conclusiones y trabajo a futuro

El primer punto que destacar es el hecho de haber cambiado de ventana clásica de Hamming por una ventana $up(x)$ basada en AF, significó un aumento del 10% en el porcentaje de aciertos en la persona B. Ésto se logra gracias a una mayor atenuación de las frecuencias no deseadas en el filtro digital al cambiar el tipo de ventana. Adicionalmente, el cambio no

genera un mayor coste computacional, ya que los coeficientes se obtienen fuera de línea.

Todas las muestras utilizadas en la presente investigación fueron tomadas en igualdad de condiciones: una sola sesión de aproximadamente una hora. Recordando que la persona B está diagnosticada con TDAH, se cree que al haber estado tanto tiempo concentrada en una sola actividad, se ocasionó aburrimiento, y por consecuencia distracción, a la hora de recolectar PC. Esta distracción pudo haber sido ocasionada por cualquier estímulo externo, como alguna mosca en la habitación o algún ruido, o bien interno, tales pensamientos constantes en cosas no relacionadas al experimento.

Adicionalmente, si se compara el 77.5% de aciertos obtenido en los clasificadores de la persona A con (Michelli et al., 2019; Zgallai et al., 2019), la metodología utilizada es lo suficientemente fiable. No obstante, comparándola con (Jiménez & Mauledoux, 2018; Vega et al., 2018), se puede ver que todavía se puede mejorar la aplicación.

Se continuará en esta área de investigación para aumentar el porcentaje de aciertos en ambos casos. De igual forma, se buscará ampliar el data set tanto de personas como de muestras.

Asimismo, en futuras experimentaciones se estandarizarán las tomas de muestras, es decir, se les preguntará a los participantes si cuentan con alguna condición que pueda alterar los resultados, además de reducir los tiempos de las sesiones de recolección de muestras y realizarlas en el lugar más tranquilo posible. Se cree que al hacer esto se puede evitar molestias para los participantes. Finalmente, se buscará desarrollar la interfaz para realizar la identificación en tiempo real.

Referencias

- 5 Types Of Brain Waves Frequencies: Gamma, Beta, Alpha, Theta, Delta - Mental Health Daily. (2014). Retrieved April 30, 2022, from <https://mentalhealthdaily.com/2014/04/15/5-types-of-brain-waves-frequencies-gamma-beta-alpha-theta-delta/>
- Andriantsilavo, H. S., Razafindrakoto, N. R., & Ratsimbazafy, A. (2021). Temporal Classification of EEG Signals for BCI Using Morse Code (LIS Case). 03(02), 18–21.
- Atif Hassan, M., & Mehdi Rizvi, Q. (2008). Computer vs human brain: an analytical approach and overview. Certified Journal | Page, 9001.
- Bansal, B. N., Singh, A., & Bhullar, J. S. (2018). A review of FIR filter designs. In Lecture Notes on Data Engineering and Communications Technologies (Vol. 3, pp. 125–140). Springer Science and Business Media Deutschland GmbH. https://doi.org/10.1007/978-981-10-4585-1_11
- Brysina, I., Brysina, I. V., & Makarichev, V. O. (2018). Generalized atomic wavelets. Radioelectronic and computer systems, 0(1), 23–31. <https://doi.org/10.32620/reks.2018.1.03>
- Budunova, K. A., & Kravchenko, V. F. (2021). New Digital Infinite Impulse Response Filters on Atomic Function $ha(x)$. Progress in Electromagnetics Research Symposium, 2021–November, 270–279. <https://doi.org/10.1109/PIERS53385.2021.9694722>
- EMOTIV Insight 2.0 - 5 Channel Mobile Brainwear® - EMOTIV. (n.d.). Retrieved May 12, 2022, from <https://www.emotiv.com/product/emotiv-insight-5-channel-mobile-brainwear/>
- Harris, F. J. (1978). On the Use of Windows for Harmonic Analysis with the Discrete Fourier Transform. Proceedings of the IEEE, 66(1), 51–83. <https://doi.org/10.1109/PROC.1978.10837>
- Hernandez-Matamoros, A., Fujita, H., Escamilla-Hernandez, E., Perez-Meana, H., & Nakano-Miyatake, M. (2020). Recognition of ECG signals using wavelet based on atomic functions. Biocybernetics and Biomedical Engineering, 40(2), 803–814. <https://doi.org/10.1016/j.bbe.2020.02.007>

- Jiménez, R., & Mauledoux, M. (2018). Electroencefalogram (EEG) Sensor for Teleoperation of Domotics Applications via Virtual Environments. 13(14), 11577–11581.
- Koudelková, Z., & Strmiska, M. (2018). Introduction to the identification of brain waves based on their frequency. MATEC Web of Conferences, 210. <https://doi.org/10.1051/mateconf/201821005012>
- Kravchenko, V. F. al, Perez-Meana, H. M., & Ponomaryov, V. I. (2009). Adaptive digital processing of multidimensional signals with applications. Fizmatlit.
- Kravchenko, V. F., & Churikov, D. V. (2011). Analytical Kravchenko-Kotelnikov and Kravchenko-Levitan wavelets in the digital UWB signal processing. Telecommunications and Radio Engineering (English Translation of *Elektrosvyaz and Radiotekhnika*), 70(9), 759–786. <https://doi.org/10.1615/TELECOMRADENG.V70.I9.20>
- Kravchenko, V. F., Kravchenko, O. V., Kononov, Y. Y., & Budunova, K. A. (2020). Atomic Functions Theory: History and Modern Results: Pioneer of Atomic Functions Theory V.L. Rvachev Invited Paper. 2020 IEEE Ukrainian Microwave Week, UkrMW 2020 - Proceedings, 619–623. <https://doi.org/10.1109/UKRMW49653.2020.9252684>
- Michelli, A. G., González, N., Pose, F., Geria, J. M., & Martínez, N. (2019). Utilización de una Interfaz Cerebro- Computadora en Domótica. July. Morse Code Timing | Morse Code World. (n.d.). Retrieved April 30, 2022, from <https://morsecode.world/international/timing.html>
- Nuttall, A. H. (1981). Some Windows with Very Good Sidelobe Behavior. IEEE Transactions on Acoustics, Speech, and Signal Processing, 29(1), 84–91. <https://doi.org/10.1109/TASSP.1981.1163506>
- Parker, R. O. (1988). Introduction To Digital Signal Processing. J Eng Comput Appl, 2(3), 6–10. <https://doi.org/10.1201/9781439817391-5>
- Perez-Daniel, K., Escamilla-Hernandez, E., Nakano-Miyatake, M., & Perez-Meana, H. (2013). An Atomic function-based approach of Harris Affine detector. SoMeT 2013 - 12th IEEE International Conference on Intelligent Software Methodologies, Tools and Techniques, Proceedings, 2, 185–189. <https://doi.org/10.1109/SoMeT.2013.6645678>
- Podder, P., Zaman Khan, T., Haque Khan, M., & Muktedir Rahman, M. (2014). Comparative Performance Analysis of Hamming, Hanning and Blackman Window. In International Journal of Computer Applications (Vol. 96, Issue 18).
- Ponomarev, V. I., Kravchenko, V. F., & Gomeztagle, F. (2009). Super-resolution method based on wavelet atomic functions in images and video sequences. Telecommunications and Radio Engineering (English Translation of *Elektrosvyaz and Radiotekhnika*), 68(9), 747–761. <https://doi.org/10.1615/TELECOMRADENG.V68.I9.10>
- Proakis, J. G., & Monolakis, D. G. (1996). Digital signal processing: principles, algorithms, and applications. Pentice Hall, 1–42.
- Rvachev, V. A. (1983). About some classes of infinitely differentiable functions. Math. Methods of Dynamical Systems Analysis, Kharkov, 7(3–5).
- Rvachev, V. A. (1990). Compactly supported solutions of functional-differential equations and their applications. Russian Mathematical Surveys, 45(1), 87–120. <https://doi.org/10.1070/RM1990V045N01ABEH002324>
- Vega, A. G., Aguilar, C. R., Barrientos, A., & Villalta, R. (2018). Desarrollo de Aplicaciones para personas con discapacidad motora utilizando Emotiv Epos. CICIC 2018 - Octava Conferencia Iberoamericana de Complejidad, Informatica y Cibernetica, Memorias, 1, 120–125.
- Vigo, L. H. (2020). Ese alfabeto compuesto por puntos y rayas llamado Código Morse. Universidad Central “Marta Abreu” de Las Villas. <https://www.uclv.edu.cu/ese-alfabeto-compuesto-por-puntos-y-rayas-llamado-codigo-morse/>
- Wang, J., Cao, J., Hu, D., Jiang, T., & Gao, F. (2021). Eye Blink Artifact Detection with Novel Optimized Multi-Dimensional Electroencefalogram Features. IEEE Transactions on Neural Systems and Rehabilitation Engineering, 29, 1494–1503. <https://doi.org/10.1109/TNSRE.2021.3099232>
- Xie, Y., & Oniga, S. (2020). A Review of Processing Methods and Classification Algorithm for EEG Signal. Carpathian Journal of Electronic and Computer Engineering, 13(1), 23–29. <https://doi.org/10.2478/cjece-2020-0004>
- Young, C., Miles, G., Adams, B., & Edgerton, M. (2020). Morse Code Encoded Eye Blinking as a Source of Biometric Authentication via EEG EEG Recording for “ B ” EEG Electrode Data Morse Code OpenBCI Acknowledgments. <https://doi.org/10.1088/1741-2552>
- Zgallai, W., Brown, J. T., Ibrahim, A., Mahmood, F., Mohammad, K., Khalfan, M., Mohammed, M., Salem, M., & Hamood, N. (2019). Deep Learning AI Application to an EEG driven BCI Smart Wheelchair. 2019 Advances in Science and Engineering Technology International Conferences, ASET 2019, 1–5. <https://doi.org/10.1109/ICASET.2019.8714373>