

El proyecto XEEGnal: sistema para la identificación de Estados Mentales a partir de Señales Bioeléctricas

Morales Morante, Jose Alberto
Departamento de Ciencias
Computacionales
Centro Nacional de Investigación y
Desarrollo Tecnológico (CENIDET)
Cuernavaca, Morelos
jose.morales18ca@cenidet.edu.mx

Magadan Salazar, Andrea
Departamento de Ciencias
Computacionales
Centro Nacional de Investigación y
Desarrollo Tecnológico (CENIDET)
Cuernavaca, Morelos
magadan@cenidet.edu.mx

González Serna, Juan Gabriel
Departamento de Ciencias
Computacionales
Centro Nacional de Investigación y
Desarrollo Tecnológico (CENIDET)
Cuernavaca, Morelos
gabriel@cenidet.edu.mx

López Sánchez, Máximo
Departamento de Ciencias
Computacionales
Centro Nacional de Investigación y
Desarrollo Tecnológico (CENIDET)
Cuernavaca, Morelos
maximo@cenidet.edu.mx

González Franco, Nimrod
Escuela de Ingeniería y Ciencias
Instituto Tecnológico y de Estudios
Superiores de Monterrey
Departamento de Ciencias
Computacionales
Centro Nacional de Investigación y
Desarrollo Tecnológico (CENIDET)
Cuernavaca, Morelos
nimrod.gonzalez@tec.mx
nimrod@cenidet.edu.mx

Resumen— Actualmente, existen trabajos enfocados en la identificación de Estados Mentales a partir del análisis de un tipo específico de bioseñales: las Señales Bioeléctricas. Sin embargo, normalmente de consideran pocos tipos de señales bioeléctricas y/o permiten identificar un conjunto reducido de Estados Mentales, por lo que si se desea identificar algún Estado Mental no predefinido o explorar otros tipos de Señales Bioeléctricas es necesario crear un sistema adecuado a cada situación específica. En este artículo se presenta un sistema que permite trabajar con múltiples señales Bioeléctricas para crear Bases de Datos Biológicos asociados a la ocurrencia de Estados Mentales y posteriormente, aplicarles diferentes técnicas de clasificación para el reconocimiento automático de Estados Mentales en pacientes reales: K - vecinos más cercanos (KNN), redes neuronales (NN), máquinas de soporte vectorial (SVM), árboles de decisión (DT) y bosques aleatorios (RF). Además de la arquitectura del sistema y la descripción de sus componentes, el artículo incluye un caso de uso desarrollado en torno al repositorio MAHNOB con fines demostrativos.

Keywords—Estados Mentales, Técnicas de clasificación, Señales Bioeléctricas

I. INTRODUCCIÓN

Un Estado Mental (EM) es un tipo hipotético de estado o proceso que corresponde con el pensar y sentir de un sujeto, y según la literatura, posee propiedades espacio-temporales, causas y efectos distinguibles, entre los que encontramos distintas alteraciones en los sistemas fisiológicos del cuerpo humano, incluyendo aquellas que pueden detectarse mediante Señales Bioeléctricas y que actualmente permiten el reconocimiento automático de Estados Mentales.

Por ejemplo, en [1] se presenta el reconocimiento de emociones en términos de niveles de valencia-excitación utilizando sensores de electroencefalografía (EEG) y de respuesta galvánica en piel (GSR), mientras que en [8] se analizan tres estados emocionales (felicidad, tristeza y neutral,) utilizando señales de electrocardiograma (ECG) y respuesta galvánica en piel (GSR).

Además, encontramos en el estado del arte dos tendencias de trabajo, la primera obteniendo Señales Bioeléctricas usando sensores para exploraciones en sujetos reales, como en el caso de [1] donde se monitorearon 27 sujetos de prueba. Por otro lado, tenemos investigaciones, como la reportada en [2] donde las Señales Bioeléctricas son obtenidas de repositorios de terceros, siendo los más usados DEAP [3], AMIGOS [4] y MAHNOB [5].

Cuando las Señales Bioeléctricas se obtienen con sensores, es necesario aplicar un proceso de filtrado de señales, siendo los métodos más comunes filtro paso banda y elimina banda [3], [5], [10], [13].

Una vez que se tienen las Señales Bioeléctricas filtradas, se les debe someter a un proceso de extracción de características. Tal proceso puede realizarse empleando herramientas existentes, como el toolbox para Matlab presentado en [6] la cual extrae características de señales de tipo electroencefalograma, respuesta galvánica en piel y electromiograma (EMG), o la librería pyEEG reportada en [7] que permite la extracción de características de señales electroencefalográficas y de magnetoencefalografía (MEG). El tipo de características que se extraen varía de acuerdo con cada investigación, aunque en varias ocasiones se basan en el dominio de la frecuencia, siendo las más populares las basadas en la densidad espectral utilizando la transformada de fourier.

Aunque es posible considerar una gran cantidad de características, se ha encontrado que en la práctica muy pocas son verdaderamente útiles en el reconocimiento de Estados Mentales, por lo que en ocasiones los investigadores hacen una selección de las características más relevantes aplicando técnicas como el análisis de componentes principales [9].

En cuanto al proceso de clasificación, esté normalmente se realiza implementando técnicas tradicionales como Regresión Logística (LR), Máquinas de Soporte Vectorial o el algoritmo KNN, aunque en años recientes se incrementó el uso de métodos más complejos, como Algoritmos Genéticos (GA), redes neuronales profundas (DNN) y redes neuronales convolucionales (CNN), por ejemplo.

En este artículo, se presenta un sistema implementado siguiendo la arquitectura mostrada en la figura 1, el cual permite construir conjuntos de datos para entrenamiento utilizando Señales Bioeléctricas tanto de sujetos reales como de repositorios, y, además, realiza los procesos de filtrado de señales, extracción de características y clasificación de forma automática. Además de la descripción de los componentes del sistema presentada en la sección II, se incluye en la sección III un caso de uso desarrollado con fines demostrativos. Finalmente, en la sección IV presentamos las conclusiones alcanzadas.

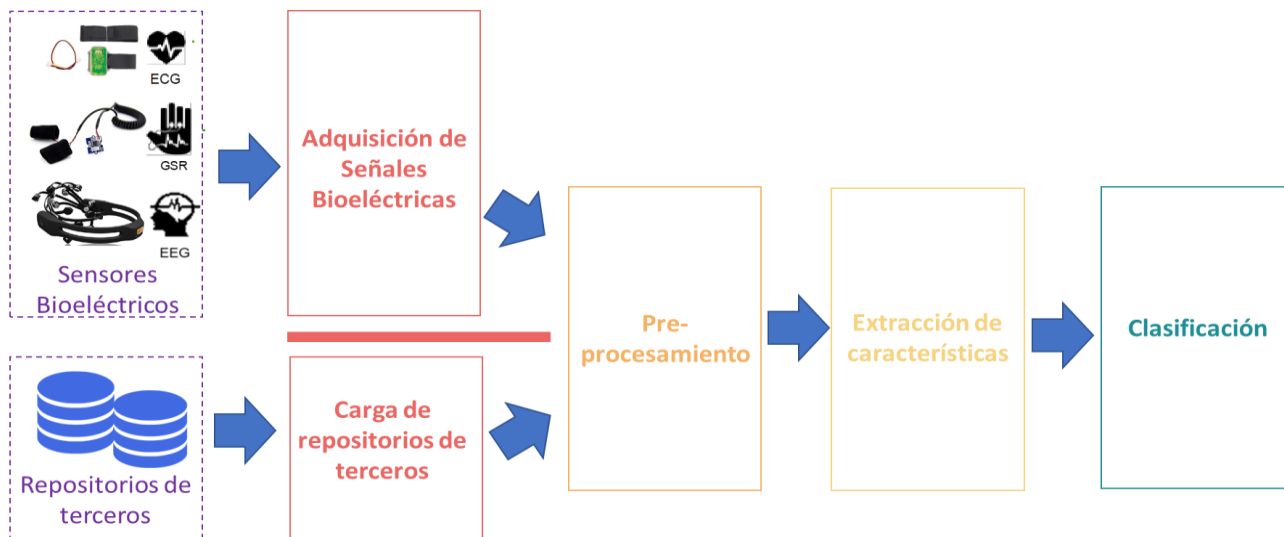


Fig. 1 Arquitectura del sistema propuesto

II. ARQUITECTURA DEL SISTEMA

XEEGnal es un proyecto en desarrollo que busca proporcionar un marco de trabajo para la inducción, caracterización e identificación de EMs. Con respecto a la identificación automática, se ha desarrollado un sistema conformado por los módulos siguientes.

Adquisición de Señales Bioeléctricas. El prototipo actual del sistema soporta el uso individual o combinado de señales extraídas mediante Electrocardiograma (ECG), Electroencefalograma (EEG), y Respuesta galvánica de la piel (GSR), además, se espera incluir a corto plazo Electrooculograma (EOG), Electromiograma (EMG) y Flujo sanguíneo.

Puesto que cada una de las Señales Bioeléctricas pueden adquirirse empleando diferentes sensores, en cada flujo de trabajo el sistema le permite al usuario especificar los dispositivos de sensado a usar, de tal modo que un determinado usuario puede crear una BDB sobre emociones usando un equipo Emotiv EPOC + para la captura de EEG, mientras que otro usuario puede usar un dispositivo Emotiv Insight para adquirir el mismo tipo de bioseñal al momento de crear una BDB sobre estados cognitivos.

Carga de repositorios de terceros. De forma independiente a la **Adquisición de Señales Bioeléctricas**, el sistema permite la creación de una BDB analizando corpus de datos contenidos en repositorios de terceros, como DEAP [3], AMIGOS [4] o MAHNOB [5].

Preprocesamiento. Debido a diferentes fuentes de ruido, siendo la más común el movimiento y la interferencia de otros dispositivos, las señales bioeléctricas siempre estarán en cierto grado, contaminadas con artefactos sin excluir las obtenidas de algún repositorio. Este ruido dificulta el análisis y puede alterar los resultados obtenidos. Con el objetivo de limpiar dicha contaminación en esta etapa se aplican técnicas de suavizado y eliminación de tendencias como son los filtros de paso banda, elimina banda y los promedios móviles.




Fig. 2 Ejemplo de adquisición: sujeto utilizando una diadema Emotiv EPOC+

Extracción de características. El sistema permite seleccionar de entre un conjunto de métricas establecidas las características con las que se desea construir un conjunto de entrenamiento. Cada señal tiene características propias basadas en diferentes análisis (mostradas en la tabla 1) y fueron seleccionadas debido a su participación en otros estudios [3], [5], [10], [11], [12], [13].

TABLA 1. CARACTERÍSTICAS SOPORTADAS POR XEEGLAB

Señal	Características
EEG	Potencia Espectral de las ondas: theta (4 - 8 Hz), alpha (8 - 12 Hz), beta (12 - 30 Hz) y gamma (30 - 45 Hz). Asimetría entre los 14 pares de electrodos en las cuatro bandas de theta, alpha, beta, y gamma.
GSR	Promedio de resistencia en piel, promedio de la primer derivada, promedio de la primer derivada para valores negativos solamente, proporción de los valores negativos con respecto a todas las muestras, número de mínimos locales, tiempo promedio de subida de la señal, densidad espectral de potencia en las bandas [0 - 2,4]Hz, tasa de cruces por cero slow (SCSR) [0 - 0,2] Hz, tasa de cruces por cero very slow (SCVSR) [0 - 0,08]Hz, promedio de magnitud de los picos de SCSR y SCVSR.
ECG/BVP	Promedio y desviación estándar, radio de energía en las bandas de [0,04 - 0,15]Hz y [0,15 - 0,5]Hz, densidad espectral de potencia en las bandas ([0,1 - 0,2]Hz, [0,2 - 0,3]Hz, [0,3 - 0,4]Hz), baja frecuencia [0,01 - 0,08]Hz, media frecuencia [0,08 - 0,15]Hz y alta frecuencia [0,15 - 0,5]Hz de los componentes del espectro del ritmo cardiaco.

Clasificación. El prototipo actual permite definir como entrada una BDB recién creada o una almacenada previamente, para luego aplicar sobre ella cualquiera de los siguientes clasificadores: K - vecinos más cercanos (KNN), redes neuronales (NN), máquinas de soporte vectorial (SVM), árboles de decisión (DT) y bosques aleatorios (RF). Además, el sistema también permite aplicar análisis de componentes principales (PCA) para descartar las características menos relevantes y análisis de componentes individuales (PCI) para descartar elementos de prueba que no sirvan en la clasificación. Finalmente, el sistema trabaja con validación cruzada y también permite dos opciones para la partición de información, 80% para entrenamiento y 20% para prueba o 70% para entrenamiento y 30% para prueba.

III. CASO SE USO

El presente caso de uso se ha realizado tomando como entrada la base de datos DEAP. DEAP tiene la característica de almacenar las señales bioeléctricas de 32 personas durante 40 pruebas utilizando estímulos basados en el esquema de valencia excitación.

Como primer paso, el usuario ingresó a la ventana de bienvenida del sistema, mostrada en la figura 2.



Fig. 4 Ventana de bienvenida del sistema

A continuación, el usuario observó las tres acciones principales del sistema. En la opción de generar dataset el usuario tiene la oportunidad de crear datasets según sus necesidades y guardarlos, mismos que pueden ser más adelante utilizados en la opción de clasificador donde servirán como entrenamiento y prueba. La opción de cargar dataset simplemente permite seleccionar un dataset anteriormente generado y con el pasar a la opción de clasificador. El usuario seleccionó la opción de generar dataset.



Fig. 3 Ejemplo de la configuración del filtrado de Señales Bioeléctricas

El **Preprocesamiento** de las Señales Bioeléctricas se lleva a cabo en dicha opción. El usuario seleccionó la carpeta donde se almacena el repositorio DEAP previamente segmentado en formato csv y selecciona las señales con las que desea trabajar, como se ilustra en la figura 4. Además, estableció los rangos en los que se aplicara el filtro paso banda y elimina banda. Una vez hecho esto seleccionó el botón siguiente.

Posteriormente, al usuario se le mostró la ventana presentada en la figura 5, la cual permite configurar la **Extracción de características**. En el caso del EEG selecciona sobre una imagen los electrodos que quiera probar y las ondas que serán extraídas de estos mediante densidad espectral. También puede seleccionar las características de asimetría, estas dependerán de los electrodos que seleccionó. En los casos de ECG y GSR es suficiente con marcar las características que quiera usar.

En esta parte el usuario decidió utilizar los análisis de componentes principales e individuales para mejorar la precisión del clasificador. Además, decidió utilizar el algoritmo SVM con una partición de 80% entrenamiento y 20% prueba. Los resultados son presentados en la parte inferior de la pantalla en forma de matriz de confusión junto con métricas como precisión y F1-score. La tabla siguiente resume los resultados del proceso seguido en el caso de uso.

TABLA 2. RESULTADOS OBTENIDOS

SVM			
Valencia		Excitación	
Precisión	F1	Precisión	F1
0.662	0.601	0.645	0.596

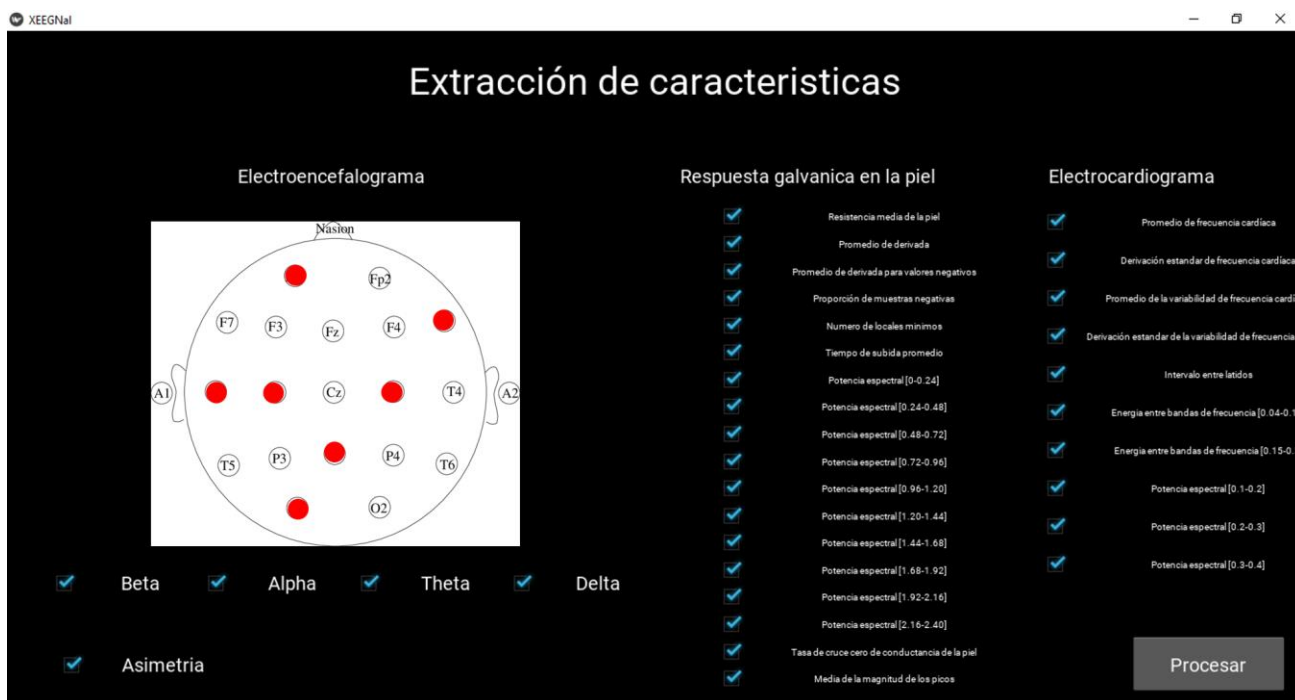


Fig. 5 Ejemplo de la Extracción de Características

Como resultado el usuario podrá seleccionar donde almacenar cada BDB (una para valencia y otra para excitación). Finalmente, el usuario accedió a la opción de clasificador donde selecciono los datasets anteriormente generados y accedió a las opciones del clasificador (ver figura 6).

IV. CONCLUSIONES

Con el sistema aquí presentado, se espera facilitar el desarrollo de futuras investigaciones sobre la identificación de Estados Mentales y sentar las bases para la construcción de un repositorio compartido de datos bioeléctricas. Además, el caso de uso realizado permite verificar que el sistema es capaz de aplicar algoritmos de clasificación comúnmente usados para la identificación de estados mentales a partir de Señales Bioeléctricas. Como trabajos futuros, se explora la incorporación de Algoritmos Genéticos (GA), redes neuronales profundas (DNN) y redes neuronales convolucionales (CNN).

AGRADECIMIENTOS

Agradecemos al Centro Nacional de Investigación y Desarrollo Tecnológico, CENIDET, por el apoyo proporcionado para la realización de esta investigación.

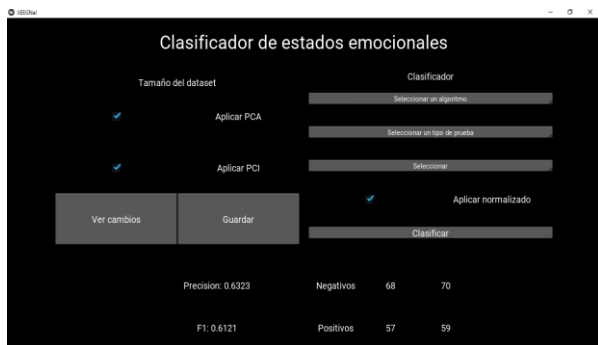


Fig. 6 Ejemplo del resultado de una Clasificación

REFERENCIAS

- [1] P. Tarnowski, M. Kołodziej, A. Majkowski and R. J. Rak, "Combined analysis of GSR and EEG signals for emotion recognition," 2018 International Interdisciplinary PhD Workshop (IIPhDW), Swinoujście, pp. 137-141, 2018.
- [2] Christelle Godin, Fabrice Prost-Boucle, Aurélie Campagne, Sylvie Charbonnier, Stéphane Bonnet, et al.. Features relevance analysis for emotion classification with physiological sensors. 2nd international conference on physiological computing, PhyCS 2015, Feb 2015, Angers, France.
- [3] S. Koelstra et al., "DEAP: A Database for Emotion Analysis ;Using Physiological Signals," in IEEE Transactions on Affective Computing, vol. 3, no. 1, pp. 18-31, Jan.-March 2012.
- [4] L. Santamaria-Granados, M. Munoz-Organero, G. Ramirez-González, E. Abdulhay and N. Arunkumar, "Using Deep Convolutional Neural Network for Emotion Detection on a Physiological Signals Dataset (AMIGOS)," in IEEE Access, vol. 7, pp. 57-67, 2019.
- [5] M. Soleymani, J. Lichtenauer, T. Pun and M. Pantic, "A Multimodal Database for Affect Recognition and Implicit Tagging," in IEEE Transactions on Affective Computing, vol. 3, no. 1, pp. 42-55, Jan.-March 2012.
- [6] Soleymani, Mohammad & Villaro-Dixon, Frank & Pun, Thierry & Chanel, Guillaume, "Toolbox for Emotional fEAture extraction from Physiological signals (TEAP)", Front. ICT 4:1, 2017.
- [7] Bao, Forrest & Liu, Xin & Zhang, Christina, "PyEEG: an open source python module for EEG/MEG feature extraction" in Computational intelligence and neuroscience, 2011.
- [8] P. Das, A. Khasnobish and D. N. Tibarewala, "Emotion recognition employing ECG and GSR signals as markers of ANS," 2016 Conference on Advances in Signal Processing (CASP), Pune, pp. 37-42, 2016.
- [9] Ahirwal, Mitul & Londhe, Narendra, "Power Spectrum Analysis of EEG Signals for Estimating Visual Attention", International Journal of Computer Applications 42, pp. 34-40, 2012.
- [10] R. Subramanian, J. Wache, M. K. Abadi, R. L. Vieriu, S. Winkler and N. Sebe, "ASCERTAIN: Emotion and Personality Recognition Using Commercial Sensors," in IEEE Transactions on Affective Computing, vol. 9, no. 2, pp. 147-160, 1 April-June 2018.
- [11] C. A. Torres, Á. A. Orozco and M. A. Álvarez, "Feature selection for multimodal emotion recognition in the arousal-valence space," 2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), Osaka, pp. 4330-4333, 2013.
- [12] S. Chen, Z. Gao and S. Wang, "Emotion recognition from peripheral physiological signals enhanced by EEG," 2016 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), Shanghai, pp. 2827-2831, 2016.
- [13] J. Kim and E. André, "Emotion recognition based on physiological changes in music listening," in IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 30, no. 12, pp. 2067-2083, Dec. 2008.