

Machine Learning y Diadema Epoc+ para eventos simultáneos en estudios de expresiones faciales

Machine Learning and Epoc+ Headband for simultaneous events in facial expression studies

Castro-López, Ángel ¹; Castañeda-Álvarez, Luis ²; Razón-González, Juan ³; Martínez-Jiménez, Leonardo ⁴; Torres-del Carmen, Felipe ⁵; Cano-Lara, Miroslava ^{1*}

¹Depto. de Mecatrónica, Tecnológico Nacional de México/ITS de Irapuato, Irapuato, Guanajuato, 36821, México.

²Depto. de Mecatrónica, Tecnológico Nacional de México/IT de Tepic, Tepic, Nayarit, 63175, México.

³Depto. de Electromecánica, Tecnológico Nacional de México/ITS de Irapuato, Irapuato, Guanajuato, 36821, México.

⁴Depto. de Estudios Multidisciplinarios, Universidad de Guanajuato, Yuriria, Guanajuato, 38944, México.

⁵Depto. de Ingeniería Mecánica, Universidad de Guanajuato, Salamanca, Guanajuato, 36800, México.

*miroslava.cl@irapuato.tecnm.mx

Resumen

En el área de reconocimiento facial las aplicaciones van en aumento, al emplear AI (Artificial Intelligence) o técnicas BCI (Brain-Computer Interface) se logra identificar la emoción facial que expresa una persona. En este trabajo se presenta la comparación de emociones del rostro mediante los algoritmos de ML (Machine Learning) en entorno de Python y la diadema Emotiv Epoc+ en su software Xavier Control Panel. Los modelos ML permiten extraer y mapear el movimiento facial en una malla de 468 nodos para EFGF (Extraction of Facial Geometric Features) y permite realizar una detección facial en cascada para extraer las características faciales en múltiples zonas simultáneamente para el algoritmo MTCNN (MultiTask Cascaded Convolutional Neural Network). La técnica BCI con la diadema Emotiv Epoc+ permite la extracción de las señales EEG (Electroencephalogram) para determinar la expresión facial. Finalmente, los modelos AI presentan la ventaja de una nula intervención física con la cabeza, en contraste de requerir tratamiento en la imagen para reducir el ruido, aumento en el tiempo de procesamiento y control de escenario de iluminación. En cambio, la técnica BCI realiza directamente la interpretación de la emoción con el software Xavier al detectar las contracciones musculares en el rostro del usuario y predecir la emoción. Las expresiones faciales logran ser aplicadas en el ámbito de la psicología, medicina, investigaciones policíacas, etc., brindan una herramienta práctica para agilizar entrevistas relacionando el reconocimiento de las emociones en el momento exacto que se requiera.

Palabras clave: Expresión facial, Aprendizaje automático, MTCNN, EFGF, Diadema Emotiv.

Abstract

The applications in facial recognition are increasing, using AI (Artificial Intelligence) or BCI (Brain-Computer Interface) techniques, we can identify the facial emotion expressed by a person. This paper presents the comparison of facial emotions using ML (Machine Learning) algorithms in a Python environment and the Emotiv Epoc+ headset in its Xavier Control Panel software. ML models allow facial motion to be extracted and mapped on a 468-node mesh for EFGF (Extraction of Facial Geometric Features) and allows cascaded face detection to extract facial features in multiple zones simultaneously for the MTCNN (MultiTask Cascaded Convolutional Neural Network) algorithm. The BCI technique with the Emotiv Epoc+ headset allows the extraction of EEG (Electroencephalogram) signals to determine facial expression. Finally, the AI models have the advantage of no physical intervention with the head, in contrast to requiring image processing to reduce noise, increased processing time and control of the illumination scenario. In contrast, the BCI technique directly performs emotion interpretation with Xavier software by detecting muscle contractions in the user's face and predicting the emotion. Facial expressions can be applied in the field of psychology, medicine, police investigations, etc., providing a practical tool to speed up interviews relating the recognition of emotions at the exact moment required.

Keywords: Facial expression, Machine Learning, MTCNN, EFGF, Emotiv Headband.

1 Introducción

El reconocimiento facial en tiempo real usando modelos AI (Artificial Intelligence) o la técnica BCI (Brain-Computer Interface) son áreas que van incrementando sus aplicaciones, en este caso particular donde se explora el reconocimiento del rostro y sus emociones. Por ejemplo, las expresiones faciales están conformadas por un patrón de contracciones musculares en el rostro de las personas que experimentan emociones y es la comunicación no verbal en una persona. Darwin relaciona las emociones, expresiones y el carácter comunicativo que poseen (Darwin, 1897). Denzin, sin embargo, cita que las emociones son un medio que ayuda a experimentar y procesar la realidad con la toma de decisiones y manejo de situaciones (Denzin, 2009). Plutchik (Pico, 2016) propuso un modelo gráfico compuesto por las ocho emociones básicas: éxtasis, admiración, terror, asombro, pena, odio, furia y vigilancia, mismas que albergan experiencias empíricas vividas previamente. Se reconoce las emociones como dimensiones en conjunto con múltiples niveles de intensidad vivida, permitiendo una comunicación no verbal visualizada en el rostro mediante las contracciones musculares y adoptando posiciones específicas para cada emoción.

La sociología ha desarrollado avances en la investigación de las expresiones como el estudio de la salud mental y de áreas pertenecientes a la psicología. Un creciente aumento ha llevado a la psicología a aplicar las expresiones en la seguridad pública en la búsqueda de métodos más eficientes de detección de mentiras (Barathi, 2016). En neurociencias, existen los avances de la interfaz cerebro-computadora BCI con la diadema Emotiv EPOC+ y Matlab para la extracción de la señal electroencefalográfica (Tang, 2020). En el mismo año se desarrolló un sistema de reconocimiento en tiempo real que realiza la extracción de los facelandmarks mediante el algoritmo Lukas-Kanade optical Flow (Lowe, 2020), la señal EEG en conjunto con el modelo MTCNN (MultiTask Cascaded Convolutional) (Bustamante, 2014) y el algoritmo EFGF (Extraction of Facial Geometric Features) con el propósito de extraer y clasificar las expresiones faciales en función a las distancias entre los puntos de referencia extraídos (Aparicio, 2022).

En el mismo momento, se propuso un método de reconocimiento de una base de datos de emociones basado en gráficos que adoptan puntos de referencia landmarks extraídos de la malla Facemesh (Akhmedov, 2022). Por otra parte, se trabajó con un algoritmo de reconocimiento de emociones con imágenes de entrada mediante una red MTCNN para la detección de rostros y la segmentación de imágenes para construir una base de datos estándar para entrenamientos (Xi'anJiaotong, 2022).

Este trabajo está estructurado en la Sección 2 con las bases teóricas relacionadas con las emociones faciales, la técnica

BCI para la diadema Emotiv EPOC+ e igualmente los modelos de IA EFGF y MTCNN. En la Sección 3, se desarrollan los estudios del rostro y sus emociones para ejemplificar cada método en conjunto a los recursos empleados de forma simultánea. Consecuentemente la Sección 4 expone los resultados del reconocimiento de emociones para neutral, alegre y sorpresa en un usuario en 3 periodos de tiempo. La última sección concluye el estudio comparativo entre los modelos IA y BCI, los cuales ofrecen agilizar tareas y practicidad en las ejecuciones para optimizar clínicos, psicológicos y policíacos al momento de una entrevista.

2 Marco teórico

Las emociones faciales son factores importantes en la comunicación humana, permitiendo a los miembros de una especie comprender las intenciones externas del resto. Los humanos tienen la capacidad de emplear múltiples expresiones para la articulación de una emoción. El rostro modifica los músculos faciales para la articulación de miles de posiciones y de esta manera transmitir las emociones que hace unas décadas se establecieron para tristeza, alegría, ira, temor, deseo, asco, interés y sorpresa (Ekman, 1984).

Entre los medios de comunicación el lenguaje de las expresiones faciales son uno de los principales métodos de comunicación interpersonal. Atrayendo la atención de la comunidad científica de la computación afectiva y las artes visuales computacionales (Abigail, 2021). Los métodos computacionales en la práctica clínica y la descripción del comportamiento en relación con las emociones faciales (Barrionuevo, 2020). Derivado de las características individuales en los rasgos faciales se requieren algoritmos con una mayor robustez que permita eliminar el error generado por la variación de la posición del rostro e iluminación. En contraparte existen los métodos de desarrollo profundo como ML, MTCNN, etc (Zhang, 2020) que han demostrado una mayor eficiencia computacional en el análisis dinámico de los rostros y su extracción automática de las características faciales sin requerir un enorme poder computacional.

2.1 Emotiv EPOC+

En la neurociencia la extracción y entendimiento del comportamiento interno del cerebro, se ve beneficiada con los sistemas BCI. Vincula la señal EEG con la actividad cerebral que se realiza al ejecutar alguna actividad de manera consciente (Pham, 2012). La diadema Emotiv EPOC+ brinda una comunicación directa y unidireccional entre el cerebro del usuario y la computadora, con una capacidad de detección en tiempo real y sin depender de actividad física como el habla o la expresión facial (EMOTIV, 2023).

En los sistemas BCI las expresiones faciales son extraídas del nervio craneal VII (EMOTIV, 2023) mediante un procesamiento previo en el software oficial Xavier Control Panel v.3.3.3.

Los patrones de activación de los músculos faciales en tiempo real aumentan la efectividad de detección comparando continuamente la posición de los músculos con respecto a la expresión neutral. De esta manera, las expresiones faciales al ser el principal medio por el cual un individuo expresa una emoción interna a un medio externo (Caballo, 2009), es posible interpretar las emociones que el usuario siente mediante los patrones faciales emitidos por el rostro.

En la Fig. 1. se muestra el posicionamiento de los electrodos y el rostro referencia neutral. En los entrenamientos, el algoritmo graba el voltaje de entrada que captan los electrodos en relación con las expresiones faciales. Un correcto entrenamiento le permite al sistema BCI identificar las expresión facial que emite el usuario, al aumentar el número de entrenamientos se reduce el error de reconocimiento en las expresiones faciales y la IA teniendo como resultado el gesto facial de la persona.



Fig. 1. Representación de los electrodos en el cerebro, estado de referencia y expresiones faciales predecibles por Xavier Control Panel.

Usando redes convolucionales como EFGF o MTCNN se puede construir detectores de rostros y emociones robustos, con un entrenamiento de imágenes del rostro del usuario para que la red aprenda a realizar tareas simultáneas.

2.2 EFGF

La Extraction of Facial Geometric Features (EFGF) es un modelo computacional determina la relación entre distancias conformadas por zonas representativas del rostro. De las diversas mallas o face mesh de hasta 468 puntos de referencia faciales, la malla densa de Mediapipe (Hassouneh, 2020) del entorno de Pipelines consta de una estructura que ofrece funciones para soluciones para la realización de estos procesamientos, siendo capaz de detectar la forma del rostro y sus puntos clave para identificar la percepción de sus expresiones en landmark facial (Lugaresi, 2019). La extracción de las distancias emplea una malla facial Facemesh de MediaPipe que asigna puntos a regiones de la cara. De esta manera se determinan las distancias para extraer rasgos de los componentes del rostro como ojos, nariz o boca. Los puntos están posicionados en proporciones del equilibrio facial que cambian según el movimiento de las regiones y por lo tanto las distancias entre ellos. Por ejemplo, de la expresión neutral hacia la expresión sorpresa se observa

un cambio en la proporción de la ceja, en cambio la expresión alegre sucede en la proporción de la boca, etc. (Sánchez, 2022).

2.3 MTCNN

La red convolucional MTCNN es un aprendizaje profundo que puede utilizarse en el área de reconocimiento facial sin restricciones. La red neuronal convolutiva multitarea detecta rostros y puntos de referencia facial de manera fina. De esta manera, MTCNN se compone de tres etapas de redes convolucionales profundas: Proposal Network (P-Net), Refine Network (R-Net) y Output Network (O-Net), que predicen la ubicación de caras y puntos de referencia (Hou, 2021). Cada una representa una etapa en la detección del rostro y sus respectivos puntos de referencia entre ojos y boca (Zhan, 2020). El modelo MTCNN en el entorno de Python 3 pre entrenado usa su configuración para crear un modelo independiente que extraiga sus configuraciones particulares del rostro (Revelo, 2021).

3 Metodología

Se trabaja con el sistema BCI que extrae las expresiones faciales de forma dinámica mediante el uso de la Diadema Emotiv Epoc+; los modelo EFGF utilizando el entorno de Python y el modelo MTCNN junto con las librerías TensorFlow y Keras. Estas últimas redes con los recursos de la Tabla 1. El desarrollo de la detección del rostro se concentro en las expresiones neutral, sorpresa y alegre con escenario controlado y las 3 etapas de análisis fueron seccionadas con 60 segundos cada bloque.

3.1 Materiales y escenario

En la Fig. 2 se observa el diseño final del escenario con un control de iluminación con dos lámparas led newer modelo nl660s ubicadas en frente del usuario. Los métodos de la diadema Emotiv Epoc+, EFGF y MTCNN trabajan con los parámetros de la Tabla 2. En la Fig. 3 se observa de manera global, la interfaz de cada método en relación con la expresión generada en ese instante. La diadema y el algoritmo EFGF (Ghofrani, 2019) presentan el resultado directo del proceso de la expresión facial predominante, en cambio el algoritmo MTCNN presenta un gráfico con el valor numérico de la detección de emoción (Revelo, 2021).

3.2 Métodos de reconocimiento de emociones

Se inicia con la diadema entrenando con las propiedades de la Tabla 1 y la Cam1 para la detección de las expresiones faciales. Se generaron 10 entrenamientos: 4 neutral, 3 sorpresa y 3 alegría de manera secuencial en dos sesiones separadas con el propósito de que el sujeto de prueba se relaje y no creó error en los entrenamientos originados por el

cansancio.

Tabla. 1. Recursos empleados en cada método.

Método	Diadema Epoc +	EFGF	MTCNN
Software	Xavier Control Panel v3.3.3 (Emotiv, 2023)	Python v3.10	Python v3.7
Entorno de programación	Xavier Control Panel v3.3.3 (Emotiv, 2023)	Visual Studio Code v2022	Conda v23.5.2
Librería	No aplica	Mediapipe OpenCv Pandas Numpy Os	Tensor Flow, Numpy, Imutils, OpenCV, Time MatplotLib
Aplicación	Detección de expresiones faciales (Chávez, 2016)	Extracción de rasgos geométricos faciales	Detección de emociones
Entrada	Señal EEG extraída del musculo facial VII en tiempo real (Roldan, 2021)	Fotogramas extraídos de un video	Fotogramas de la cámara del rostro del usuario
Salida	Visualización grafica de la emoción dominante detectada por la diadema (Emotiv, 2023)	Valor de las proporciones geométricas exportados en un archivo .csv	Gráfico en tiempo real con porcentajes de predicción de emociones



Fig. 2. Escenario para el reconocimiento facial.

Tabla. 2. Cámaras empleadas para la detección.

Cámara	Modelo	Método
Cam1	HP Wide Visión HD Camera (Laptop)	Método Diadema Emotiv
Cam3	Huawei Matebook D15	EFGF
Cam2	Stelar CW 750 (Webcam)	MTCNN

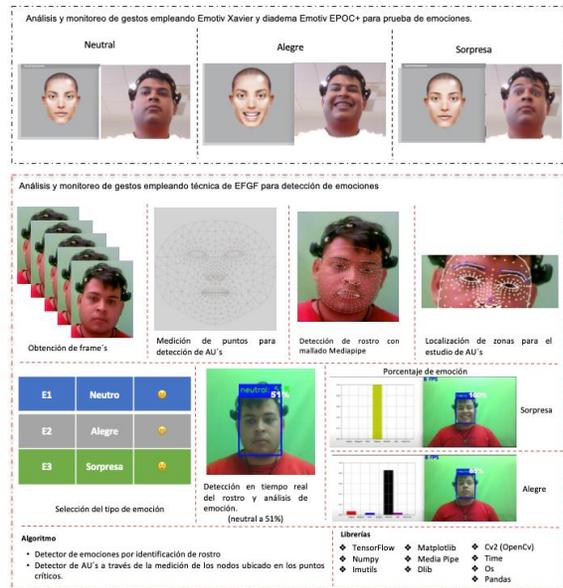


Fig. 3. Detección de emoción neutral, alegre y sorpresa por los métodos (arriba hacia abajo): Diadema Emotiv Epoc+, EFGF y MTCNN (Revelo, 2021).

En la parte superior de la Fig.3, se muestra el monitoreo de las expresiones faciales emitidas por el sistema BCI en la cabeza del usuario, el software Xavier ejemplifica la expresión con un simulador de rostro. Continuando con la parte central en la Fig. 3, el método EFGF extrae los rasgos geométricos faciales con la Cam3 en Python para las regiones nariz, puente, ceja y boca. El análisis facial depende de la posición cartesiana de puntos en el rostro donde las emociones tienen puntos asignados en la malla facial Mediapipe que caracterizan la emoción en sí. Se trabaja con el video en el algoritmo para crear archivos *.csv donde se almacenan las proporciones de cejas y boca (300 frames por cada uno) con un total de 3,600 proporciones para la base de datos; un tercio correspondiente a cada expresión facial. Por ejemplo, los puntos ubicados en la ceja tienden a estar más arriba en la expresión sorpresa que en la neutra, la emoción alegre muestra un cambio en la posición de los puntos alrededor de las comisuras en contraste con neutral y sorpresa. En la Fig. 4 se determina la relación entre 3 distancias formadas por 4 puntos en la malla del rostro: puente nasal P168, punta de la nariz P4, centro de la ceja P105, comisura externa de la boca P185 (MediaPipe, 2023). Las proporciones son extraídas a una base de datos externa y se analiza su comportamiento con respecto a su expresión facial y las distancias (Math, 2023):

$$X_n, Y_n = \text{Lista [Punto 1] [1:]} \tag{1}$$

$$X_{n+1}, Y_{n+1} = \text{Lista [Punto 2] [1:]} \tag{2}$$

$$\text{Distancia}_{a_{12}} = \text{math.hypoth}(X_{n+1} - X_n, Y_{n+1} - Y_n) \tag{3}$$

Donde (1) y (2) extraen las coordenadas (X,Y) de sus respectivos puntos de forma individual del arreglo *lista* almacenados en la variable X_n y Y_n . En (3) se determina la distancia euclidiana entre los mismos basándose en el resultado de las ecuaciones (1) y (2). De esta manera en la Fig. 4 se observan las distancias $P_4 - P_{168}$ que representa la distancia referencia, $P_4 - P_{105}$ y $P_4 - P_{185}$ son los movimientos de la Proporción Ceja (P.C) y la Proporción de la Boca (P.B) respectivamente.

$$P.C = P_4 - P_{168} / P_4 - P_{105} \quad (4)$$

$$P.B = P_4 - P_{168} / P_4 - P_{185} \quad (5)$$

Para el 3er. método, en la Fig 3. Parte inferior el modelo MTCNN de acuerdo con la Tabla 1 es pre-entrenado en relación con las emociones del usuario. Se importa valores previos de pesos de las redes neuronales en un entrenamiento de 14000 épocas (Revelo, 2021). En tiempo real se generan imágenes de entrada en la red con la Cam2 y la librería OpenCv captura y almacena temporalmente los frames extraídos del video. Se convierte a un arreglo Numpy y se ajusta la matriz en el formato de entrada (NONE, 224, 224, 1). La predicción de las emociones es clasificada y almacenada en variables independientes, a su vez se visualiza la predicción de las emociones mediante un gráfico de barras de 0 a 1, logrando identificar el nivel de emoción que presenta el usuario.

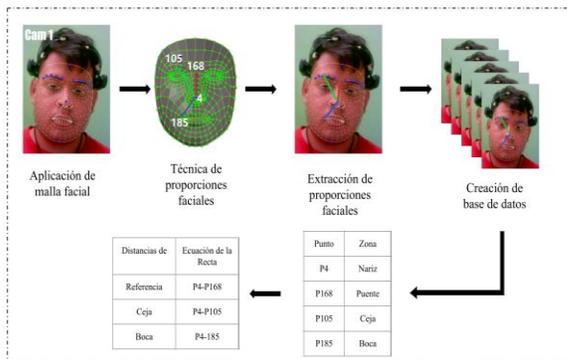


Fig. 4. Extracción de proporciones faciales por distancias geométricas en puntos nariz, puente, ceja y boca.

4 Resultados

En los estudios de las emociones neutral, alegre y sorpresa, las imágenes son extraídas de los frames del video como se observa en la Fig. 5 cada 60 s., de arriba hacia abajo se observan los 3 métodos iniciando con BCI para diadema Emotiv Epoc+, ML para EFGF y MTCNN. El estudio está representado por 3 etapas que se desarrollan respecto al tiempo, teniendo un periodo de 60 seg. por cada emoción. Se inicia con la emoción neutra, seguida de alegre y terminando con sorpresa. Si bien, (en la parte superior de la Fig. 5) para la técnica BCI se detectan todas las expresiones faciales, se

requiere un entrenamiento completo para obtener una exactitud adecuada al momento del estudio. Es posible se presente un aumento de falsos positivos debido a la cantidad limitada de entrenamientos entre expresiones. Sin embargo, se logra identificar la emoción en Xavier en la secuencia de las etapas, teniendo presencia de error en la emoción sorpresa. Esto es debido a una base de datos limitada que debe ser ampliada con más pruebas para mejorar el entrenamiento.

En los mismos lapsos de tiempo, para el método EFGF se extrae la base de datos. Se exportan y trabajan en para extraer los rasgos geométricos faciales y determinar que emoción expresa en relación a las distancias en los puntos representativos del rostro. La Tabla 3 muestra la comparación entre las distancias PC y PB para las emociones neutral, alegre y sorpresa. Para el caso de la proporción de ceja para la emoción alegre al aplicar la Ec. 4 se presenta una ligera diferencia. De esta manera, es requerido realizar un ajuste de amplitud en las proporciones para aumentar el umbral de detección entre la proporción neutral y la ejercida. Por otro lado, en la Fig. 5. se observa el proceso de extracción para las emociones de estudio. Dichos valores son empleados como entrada del algoritmo de clasificación que realiza una comparación entre los umbrales de detección asociados a una emoción y el valor obtenido en código previos.

En cambio, el modelo de red MTCNN presentó una variación en el porcentaje de error en la expresión neutral y sorpresa, ya que la red neuronal muestra confusión en los nodos particulares de la malla. En la primera etapa de la Fig. 5 parte inferior detecta la emoción neutral con un 41%, no obstante, a diferencia del método BCI, el algoritmo MTCNN no requiere de un dispositivo electrónico de intervención directa, captando la emoción sin perturbaciones causadas por la incomodidad generada por el uso de la diadema. Para una mayor efectividad se requiere continuar con entrenamientos del modelo con una mayor base de datos para aumentar la precisión de la emoción.

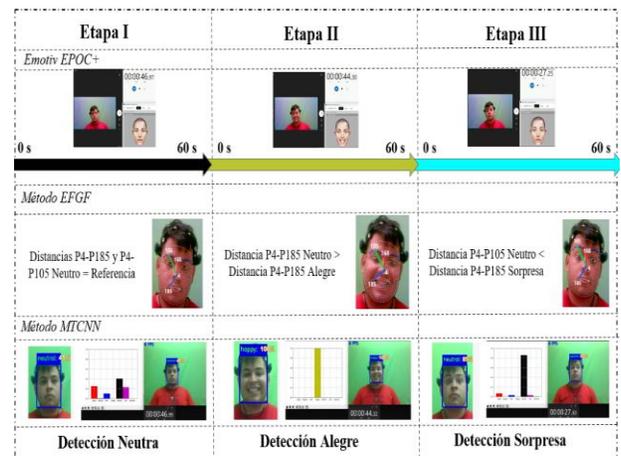


Fig. 5. Comparación de las 3 etapas respecto al tiempo para el método Emotiv, EFGF y el modelo MTCNN.

Tabla. 3. Proporciones de grupos de frames con respecto a una expresión facial.

Detección	Proporción de cejas (PC) u. a	Proporción de boca (PB) u. a.
neutral (173)	0.522595	0.74372
alegre 1 (131)	0.523548	0.81838
alegre 2 (132)	0.523548	0.81837
alegre 3 (133)	0.523546	0.81838
sorpresa 1 (182)	0.489928	0.740311
sorpresa 2 (183)	0.502109	0.715891
sorpresa 3 (184)	0.474564	0.676618

En la Fig. 6 se observan los 3 tipos de emociones, donde la Fig. 6a es neutra, Fig. 6b alegre y la Fig. 6c sorpresa. En las 3 etapas en su mayoría para los métodos son efectivos en la emoción alegre con un 100% de efectividad. Para la técnica BCI se presentan la predicción del gesto en relación con la tensión de los músculos del rostro, la diadema y el software Xavier ofrece el cambio simultáneo al momento de intercambia la posición muscular del rostro, efectuando ligeros errores en relación con generar un entrenamiento más profundo.

Para el método EFGF, las distancia que se extraen de las coordenadas (X,Y) determinan que las proporciones PC y PB de la expresión facial disminuye en alegre y aumenta en sorpresa; es decir, el cambio observado está directamente relacionado con los movimientos locales en el rostro para la ceja y boca en relación con la referencia neutra.

En cambio, para el método MTCNN se observa que la emoción sorpresa es confundida con el neutral teniendo un porcentaje mayoritario del 85%.

En cuanto al modo neutral se detecta un error de detección con las emociones miedo, ira y tristeza, teniéndose a la expresión neutral con tan solo un 41%, un valor de certeza menor en comparación al 85% emitido cuando se ejercía la emoción sorpresa (Revelo, 2021).

Conclusiones

Una aplicación específica como detectar la emoción de una persona con métodos BCI o Machine Learning pueden apoyar con tareas en psicología, medicina, empresas, educación o seguridad. En este sentido los métodos EFGF y MTCNN presentan una arquitectura de aprendizaje automático con un enfoque en el reconocimiento de la expresión y emoción del usuario. En conjunto se trabaja con la capacidad de corregir a sí mismo el modelo con el aumento de los entrenamientos de las redes neuronales y pruebas. El método EFGF requiere robustecer la clasificación del sistema aumentando los puntos de referencia de la malla, así como las distancias de proporciones. En cuanto al método MTCNN se requiere ajustar la emoción neutra para que el algoritmo reconozca adecuadamente el rostro. Así pues, la diadema Epoc+ presentó irregularidades en la detección de la emoción neutra, confundiendo con la emoción sorpresa. Esto es debido a que requiere una intervención directa con el usuario, entrenar el modelo para la persona y mejorar la exactitud con una serie de entrenamientos.

Para concluir se determinó que los modelos IA son más efectivos para reconocer la emoción debido al cómputo interno y el análisis computacional. La base de datos, clasificación y reconocimiento en tiempo real dependen en su totalidad de las mallas, los face landmarks y las distancias entre los puntos de referencia del rostro. Dicho de otra manera, los métodos de detección de expresiones faciales recolectan información necesaria como su emoción, edad aparente o su estado emocional en el momento de una entrevista, etc. de una manera extraordinaria.

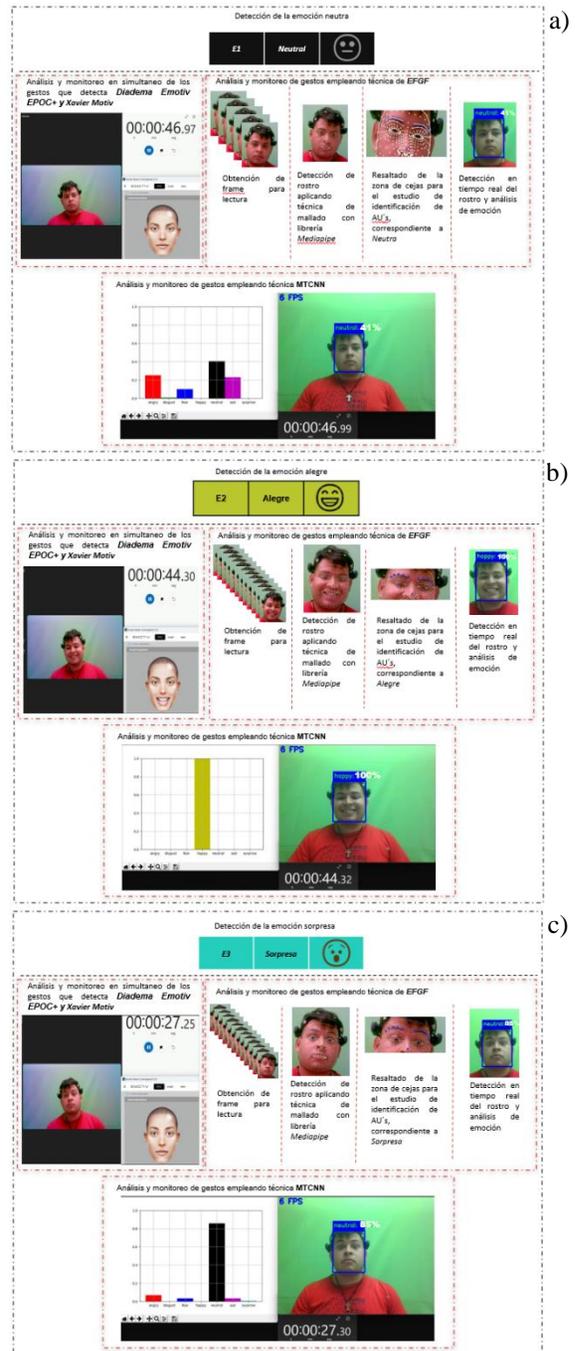


Fig. 6. Detección simultánea en los tres métodos.

Agradecimientos

Se agradece a Johan F. Llamas Becerra por su participación en el desarrollo del proyecto.

Referencias

- Akhmedov, F., Abdusalomov, A. B., Mukhiddinov, M., & Cho, Y. I., 2022. Development of Real-Time Landmark-Based Emotion Recognition CNN for masked faces. *Sensors*, 22(22), 8704. <https://doi.org/10.3390/s22228704>
- Arroyo, A. & Anai, A., 2022. Método de extracción de rasgos faciales para la autenticación de personas. Tesis Doctorado. BUAP. México. <https://hdl.handle.net/20.500.12371/16797>
- Barrionuevo, C., Ierache, J. S., & Sattolo, I. I., 2020. Reconocimiento de emociones a través de expresiones faciales con el empleo de aprendizaje supervisado aplicando regresión logística. CACIC <http://sedici.unlp.edu.ar/handle/10915/113243>
- Bustamante, S., 2014. Algoritmos de procesamiento de imagen aplicados a la detección de figuras geométricas y sus propiedades espaciales. Pontificia Universidad Católica de Valparaíso.
- Caballo, V., 2009. Manual de evaluación de entrenamiento de las habilidades sociales. Siglo XXI.
- Chávez-Sáenz, V., Torres-Ramírez, D., Herrera-Ogaz, J., & Hernández-Rodríguez, A., 2016. Adquisición y análisis de señales electroencefalográficas utilizando el dispositivo Emotiv EPOC. *Revista de Tecnología e Innovación*, 107.
- Chávez-Sáenz, 2016, Velia, Jimenez-González, Fernando, Torres-Ramírez, Dulce y Perezklapez, Christian. Estudio de las señales EEG generadas a partir de expresiones faciales. *Revista de Investigación y Desarrollo* 2016, 2-6: 115-124
- Denzin NK, 2009, On Understanding Emotion. New Brunswick, NJ: Transaction Publishers
- Ekman, P., 1984. Expression and the nature of emotion. In K. R. Scherer y P. Ekman (Eds.), *Approaches to Emotions*. Hillsdale: Erlbaum
- Emotiv, 2023 Guía BCI <https://www.emotiv.com/bci-guide/>
- Emotiv, 2023 Guía EEG <https://www.emotiv.com/eeg-guide/>
- Ghofrani A., Toroghi, R. M., & Ghanbari, S., 2019. Realtime face-detection and emotion recognition using mtcnn and minishufflenet v2. In 2019 5th Conference on Knowledge Based Engineering and Innovation (KBEI) (pp. 817-821). IEEE.
- Roldan González, E., et al, 2021. Diseño de un sistema de captura de movimiento facial para la cuantificación de gestos faciales. *Revista Virtual Universitaria*, 16(2), 84–88. Recuperado a partir de <https://revistas.fumc.edu.co/index.php/rvu/article/view/102>
- Google., 2023. GitHub - Google/MediaPipe: cross-platform, customizable ML solutions for live and streaming media. GitHub. <https://github.com/google/mediapipe>
- Python, 2023, math — Funciones matemáticas — documentación Python <https://docs.python.org/es/3.10/library/math.html>
- Hassouneh, A., Mutawa, A. M., & Murugappan, M., 2020. Development of a Real-Time Emotion Recognition system using facial expressions and EEG based on machine learning and deep neural network methods. *Informatics in Medicine Unlocked*, 20, 100372. <https://doi.org/10.1016/j.imu.2020.100372>
- Hou, X., Wang, Y., Wang, X., Zhao, J., Zhu, X., & Su, J., 2021. A markerless 2d video, facial feature recognition-based, artificial intelligence model to assist with screening for parkinson disease: development and usability study. *Journal of Medical Internet Research*, 23(11), e29554. <https://doi.org/10.2196/29554>
- Lowe, J., 2020. Ocular Motion Classification for Mobile Device Presentation Attack Detection. University of Missouri-Kansas City.
- Lugaresi, C., Tang, J., Nash, H., McClanahan, C., Uboweja, E., Hays, M., ... & Grundmann, M., 2019. Mediapipe: A framework for perceiving and processing reality. In *Third workshop on computer vision for AR/VR at IEEE computer vision and pattern recognition (CVPR) (Vol. 2019)*.
- Pham, T. D., & Tran, D., 2012. Emotion Recognition Using the Emotiv EPOC Device. *Lecture Notes in Computer Science*, 394–399. doi:10.1007/978-3-642-34500-5_47
- Abigail, P. M. Q. 2021. Detección automatizada de emociones a través del rostro, una revisión del estado del arte. Retrieved from <https://ri.uaemex.mx/handle/20.500.11799/112586>
- Revelo. L., 2021. GitHub – DavidReveloLuna /Face_Emotion. GitHub. https://github.com/DavidReveloLuna/Face_Emotion
- Sánchez-Ruiz, M., Flores-Monroy, J., Escamilla-Hernández, E., Nakano-Miyatake, M., & Perez-Meana, H., 2022. Detección de estados de ánimo en ambientes no restringidos. *Pädi Boletín Científico de Ciencias Básicas e Ingenierías del ICBI*, 10 (Especial4), 110-115.
- Tang, J., Xu, M., Han, J., Liu, M., Dai, T., Chen, S., & Ming, D., 2020. Optimizing SSVEP-based BCI system towards practical high-speed spelling. *Sensors*, 20(15), 4186.
- Zhang, N., Luo, J., & Gao, W., 2020. Research on Face Detection Technology Based on MTCNN. IEEE. <https://doi.org/10.1109/iccnea50255.2020.00040>

Recibido: 10 de noviembre de 2023

Aceptado: 20 de marzo de 2024

Castro-López, Ángel: Estudiante de Ingeniería en Mecatrónica en el Tecnológico Nacional de México Campus Irapuato.

Correo electrónico: LIS20110070@irapuato.tecnm.mx

 <https://orcid.org/0009-0004-8726-9850>

Razón-González, Juan: Mechanical Engineering at the Instituto Tecnológico de Celaya, Mexico. Master of Science in Mechanical Engineering at Universidad Autónoma de Nayarit, Mexico. Research professor of Department of electromechanics of TecNM/Irapuato.

Correo electrónico: juan.rg@irapuato.tecnm.mx

 <https://orcid.org/0000-0002-9457-5029>

Martínez-Jiménez, Leonardo: Eng. in Communications and Electronics, M.E in Electrical Engineering and Ph.D. in Electrical Engineering of University of Guanajuato, México.

Correo electrónico: leonardomj@ugto.mx

 <https://orcid.org/0000-0002-7062-7154>

Torres-del Carmen, Felipe: Dr. of Science in Electronic Engineering. National Center for Research and Technological Development, Morelos, Mexico. Research professor of Department of Mechanical, DICIS, UG. Correo electrónico: fdj.torres@ugto.mx

 <https://orcid.org/0000-0001-5792-2098>

Cano-Lara, Miroslava: Eng. in Communications and Electronics and the M.E in Electrical Engineering degree, both University of Guanajuato, Mexico. Ph.D. in Optics Science at CICESE, B.C, México and Postdoctoral at DICIS, University of Guanajuato. Research professor of Department of Mechatronic of TecNM/Irapuato.

 <https://orcid.org/0000-0002-3335-2710>