

Análisis y clasificación de potenciales evocados en respuesta a caras familiares y desconocidas.

Sergio Antonio Sanchez Hernandez

Trabajo de grado para optar al título de:

**Magister en Ingeniería con
Énfasis en Eléctrica y Electrónica**

Directora: Sonia Contreras,PhD.

**Universidad Tecnológica de Bolívar
Facultad de Ingeniería
Cartagena**

Abril 18 de 2018

Análisis y clasificación de potenciales evocados en respuesta a caras familiares y desconocidas.

Sergio Antonio Sanchez Hernandez

Directora: Sonia Contreras, PhD.

**Universidad Tecnológica de Bolívar
Facultad de Ingeniería
Maestría en Ingeniería con Énfasis en Eléctrica y Electrónica
Cartagena**

Abril 19 de 2018

UNIVERSIDAD TECNOLÓGICA DE BOLÍVAR
FACULTAD DE INGENIERÍA

Título: Análisis y clasificación de potenciales evocados en respuesta a caras familiares y desconocidas.

Autor: Sergio Antonio Sanchez Hernandez

Jurado

Jurado

Director:

Cartagena, Abril 19 de 2018

Resumen

La percepción y el reconocimiento de caras se ha estudiado con el fin de analizar la actividad cerebral en respuesta a este tipo de estímulos. Esta información es importante para el desarrollo de las interfaces cerebro-computadora y el estudio de los trastornos neurológicos. En este trabajo, se analizaron potenciales evocados como indicadores neurofisiológicos y desarrollamos un modelo basado en técnicas de procesamiento de señales y aprendizaje automático para encontrar patrones descriptivos que permitan la diferenciación de rostros familiares y no familiares. Consideramos componentes de onda como P1, N170, N250, P300 y N400 para describir los eventos. El análisis morfológico y la transformada wavelet se utilizaron para la etapa de extracción de características, y las máquinas de vectores de soporte y la regresión logística binomial se evaluaron para la etapa de clasificación. Los mejores resultados de clasificación se obtuvieron con las características morfológicas, donde la mayor precisión de clasificación fue del 80 % en promedio.

Abstract

Perception and recognition of faces have been studied by researchers to analyze brain activity in response to this type of stimuli. This information is important for the development of brain-computer interfaces and the study of neurological disorders. In this paper, we analyzed evoked potentials as neurophysiological indicators and developed a model based on signal processing techniques and machine learning to find descriptive patterns that allow the differentiation of familiar and unfamiliar faces. We considered wave components such as P1, N170, N250, P300, and N400 to describe the events. Morphological analysis and wavelet transform were used for the feature extraction stage, and support vector machines and binomial logistic regression were evaluated for the classification stage. The best classification results were obtained with the morphological characteristics, where the highest classification accuracy was

Agradecimientos

En primer lugar agradezco a Dios por permitirme alcanzar esta nueva meta en mi vida profesional, de igual manera a mi familia en especial a mi madre por el apoyo incondicional en todas las aventuras que emprendo.

A La Universidad Tecnológica de Bolívar por darme la oportunidad de ser parte de su comunidad estudiantil y haber puesto en mi camino personas con una calidad humana admirable.

A mi directora de tesis y profesora Dra. Sonia Contreras quien con su conocimiento, experiencia, motivación, pero sobretodo paciencia fue pieza clave para la culminación de esta nueva etapa con éxito.

Índice general

1. Introducción	13
1.1. Planteamiento del Problema	15
1.2. Justificación	16
1.3. Estado del Arte	17
1.3.1. Trabajos Relacionados	17
1.4. Objetivos	19
1.4.1. Objetivo General	19
1.4.2. Objetivos Específicos	19
1.5. Nuestra Contribución	20
2. Marco Teórico	21
2.1. Preliminares Fisiológicos y Clínicos	21
2.2. Biopotenciales	21
2.3. Lóbulos del cerebro y sus funciones	22
2.4. Onda cerebral	23
2.5. Definición y clasificación de los Potenciales evocados	24

2.6. Clasificación de los potenciales evocados	24
2.7. Preliminares de los algoritmos de clasificación	27
3. Marco Metodologico	29
3.1. Protocolo experimental	29
3.2. Preprocesamiento y extracción de Características	31
3.2.1. Filtrado	31
3.3. Transformada Wavelet Discreta	31
3.3.1. Análisis de potenciales evocados	33
3.4. Etapa de clasificación	34
3.5. Regresión logística binaria	35
3.6. Máquinas de vectores de soporte	36
4. Resultados y Discusión	39
5. Conclusiones	47
6. Bibliografía	49

Lista de Figuras

2.1. Posición de los lóbulos cerebrales y sus funciones, adaptado del trabajo del autor Triglia [11]	23
3.1. Diagrama de bloque del sistema	30
3.2. Descomposición Wavelet	32
3.3. Forma de onda del potencial evocado	33
3.4. Reconocimiento e identificación de rostros (adaptado de la tesis doctoral de Mera Ana 2013) [33].	34
3.5. Matriz de confusión.	37
4.1. Potencial relacionado con eventos sin filtrado	40
4.2. Potencial relacionado con eventos con filtrado	40
4.3. Comparación de los Potenciales relacionado a eventos de rostros famosos y desconocidos.	42
4.4. Predicción del algoritmo regresión logística binaria con características morfológicas.	43

4.5. Predicción del algoritmo regresión logística binaria con características wavelet.	43
4.6. Matriz de confusión para el algoritmo SVM con características morfológicas.	44
4.7. Matriz de confusión para el algoritmo SVM con características Wavelet.	45

Lista de Tablas

2.1. Posición de los lóbulos cerebrales y sus funciones, adaptado del autor Betha [12]	23
3.1. Selección de la Wavelet madre	32
4.1. Coeficientes de energía Wavelet rostros famosos	41
4.2. Coeficientes de energía Wavelet rostros desconocidos	41
4.3. Terminología y derivaciones de la matriz de confusión para el algoritmo SVM con características morfológicas	44
4.4. Terminología y derivaciones de la matriz de confusión para el algoritmo SVM con características wavelet	45
4.5. Rendimiento de los clasificadores	46

Capítulo 1.

Introducción

La cara es uno de los primeros estímulos que recibimos en el momento del nacimiento y desde el punto de vista biológico, psicológico y social es el objeto visual de mayor importancia para los humanos [1]. El reconocimiento de rostros humanos es un proceso que siempre está presente en cualquier ser humano y nos permite reconocer la identidad de una persona. Se han desarrollado varios modelos para describir el procesamiento facial teniendo en cuenta los procesos perceptivos y cognitivos involucrados. Dos de estos modelos son el Modelo funcional para el procesamiento de rostros propuesto por Bruce y Young (1986) y el Modelo de distribución neuronal para la percepción de rostros de Haxby, Hoffman y Gobbini (2000) [2].

La actividad cerebral durante la percepción facial se ha estudiado con técnicas neurofisiológicas no invasivas, como Electroencefalografía (EEG) para el análisis de potenciales relacionados con eventos (ERP). Los ERP son registros de la actividad eléctrica del cerebro que se producen como respuesta a un estímulo que puede ser visual, auditivo o somatosensorial. Generalmente se presentan en diferentes ensayos de señales electroencefalográficas (EEG) y se describen en cantidades máximas, mínimas

y duración relativa con respecto a la estimulación (latencia).

El análisis y la clasificación de los ERP generados durante la percepción facial se han estudiado para varias aplicaciones, como la investigación de interfaces cerebro-computadora (BCI), y algunos trabajos previos se mencionan a continuación. Olivares y Saavedra analizaron el procesamiento inicial de las caras, que está relacionado con respuestas electrofisiológicas tempranas como la onda occipital P120, la onda N170 relacionada con el reconocimiento visual de identidad y las ondas N250 y N400 que reflejan los procesos de acceso y recuperación de información relativa a caras familiares en la memoria a largo plazo [3]. Ozbeyaz y Arica utilizaron medidas estadísticas sobre ERP de cuatro canales y máquinas de vectores de soporte (SVM) para la clasificación. La mayor precisión de clasificación se estimó en un 72.67% [4].

Finalmente, Li y Zhongze utilizaron un patrón espacial común, análisis de componentes principales, transformada wavelet y características de intervalo, y obtuvieron una precisión promedio de clasificación de hasta 94.2% [5]. En este trabajo, analizamos los ERP para extraer los componentes morfológicos (P1, N170, N250, P300 y N400) y los coeficientes de transformada wavelet que se utilizaron como entradas para los clasificadores.

1.1. Planteamiento del Problema

El reconocimiento facial es posiblemente una de las habilidades perceptivas más evolucionadas del ser humano, el sistema cerebral implicado en su correcto desempeño refleja la complejidad de este tipo de percepción. El sistema nervioso humano dispone de componentes especializados para percibir y discriminar aspectos faciales. Por tanto, la presente investigación pretende analizar los datos existentes sobre actividad eléctrica cerebral que pueden suministrar indicadores descriptivos de los potenciales evocados visuales teniendo en cuenta los avances metodológicos actuales que permite el estudio de la actividad neural enfocada en la percepción y el reconocimiento de rostros conocidos y desconocidos. Los avances tecnológicos alcanzados han permitido mejorar los resultados obtenidos, se evidenció que no existe una región específica relacionada con el reconocimiento facial, solo relaciones de zonas. Siendo una materia de estudio generar nuevas investigaciones que optimicen los resultados encontrados hasta el momento.

1.2. Justificación

El reconocimiento de rostros es un proceso de indiscutible importancia psicobiológica, hoy en día existen diferentes aspectos relevantes que definen el procesamiento de caras y el reconocimiento de un individuo. La importancia de esta investigación se une al esfuerzo que la comunidad neurocientífica está realizando con el fin de analizar cómo los potenciales evocados pueden generar marcadores neurofisiológicos para diferenciar caras conocidas de caras desconocidas. A partir de estudios realizados por décadas todavía se encuentran muchos aspectos que se deben investigar y profundizar más, debido a la complejidad de la actividad cerebral. Hoy en día se utilizan diferentes técnicas neurales para el estudio de actividad cerebral, las cuales han supuesto una fuente constante de datos nuevos y complementarios de los estudios clínicos referentes al comportamiento del cerebro. Este estudio también busca identificar las zonas del cerebro en las cuales se presenta mayor actividad durante los procesos de percepción y reconocimiento de caras.

1.3. Estado del Arte

1.3.1. Trabajos Relacionados

Con el propósito de determinar un método de extracción de características, y un algoritmo de clasificación que brinde la información más relevante, necesaria y suficiente para obtener parámetros ocultos dentro de las señales de electroencefalografía (EEG), de forma que sea posible discriminar patrones característicos sobre el comportamiento de señales cerebrales relacionadas con la visualización de rostros de caras familiares y desconocidas, se validaron los estudios que se presentan a continuación:

El autor Henson en su trabajo titulado “A parametric empirical Bayesian framework for the EEG/MEG inverse problem: generative models for multi-subject and multi-modal integration”, evaluó 18 sujetos, centrándose en la energía inducida por la percepción facial dentro de una ventana de frecuencia de tiempo de 100-220 ms, 8-18 Hz [6]. Los resultados encontrados respaldan que la componente M170 y N170 contienen patrones morfológicos discriminantes que permiten distinguir señales cerebrales relacionadas a la percepción de rostros conocidos y desconocidos.

Por otro lado los autores Olivares & Savedra revisan los datos existentes sobre potenciales evocados y procesamiento de caras. Discuten la significación funcional de cada una de las respuestas psicofisiológicas analizadas en relación con las diferentes etapas o módulos descritos en los modelos cognitivos y neurales sobre el procesamiento de rostros familiares y desconocidos, donde afirman: que el procesamiento inicial de las

caras está relacionado con respuestas electrofisiológicas muy tempranas como la onda occipital P120, asociada a la detección de aspectos estructurales primarios sugerentes, la onda temporal posterior N170 es más sensible a la configuración facial mientras que la latencia más tardía como la temporal anterior N250r y la topográficamente más distribuida N400 son las que reflejan, respectivamente, los procesos de acceso y recuperación de información relativa a las caras conocidas en la memoria a largo plazo [7].

Por último, también se tomó como referencia la investigación realizada en el año 2016 por el autor Zheng; donde investigaron un conjunto de características de EEG basadas en frecuencia de tiempo, donde los sujetos estaban expuestos a estímulos visuales de imágenes familiares y desconocidos en un período de tiempo fijo, durante un paradigma experimental establecido. Los resultados muestran que la combinación de características tales como valores de potencia de las ondas cerebrales, picos de señal, actividad y movilidad de la señal proporcionó una precisión promedio del 70,71 % al clasificar entre imágenes familiares y no familiares entre 7 sujetos. Como trabajo futuro el autor propone realizar más investigaciones para mejorar el rendimiento de clasificación y para reducir los efectos de la variabilidad intersubjetiva e intraindividual de las señales de EEG durante la extracción de características [8].

1.4. Objetivos

1.4.1. Objetivo General

- Implementar un modelo basado en técnicas de procesamiento digital de señales e inteligencia artificial a partir del análisis de registros de potenciales evocados para la percepción y el reconocimiento de caras.

1.4.2. Objetivos Específicos

- Identificar patrones característicos que contengan información temporal, espectral y morfológica de las señales de registros de potenciales evocados.
- Seleccionar técnicas de extracción de características de señales EEG para el reconocimiento de caras.
- Evaluar diferentes técnicas de clasificación supervisada y no supervisada a partir de información proveniente de señales EEG y mediciones neuropsicológicas.

1.5. Nuestra Contribución

La contribución principal del presente trabajo investigativo se fundamenta en el procesamiento digital de señales relacionadas a potenciales evocados visuales, exactamente en las componentes P1, N170, N250, P300 y N400. Estas componentes se utilizaron para extraer características relevantes a través del análisis morfológico de las ERP y la técnica de descomposición Wavelet con el objetivo de describir eventos relacionados con la visualización de imágenes de caras familiares y desconocidas. Por último se implementaron algoritmos de clasificación con el propósito de discriminar patrones característicos de señales cerebrales basadas en el método de regresión logística binaria y la técnica máquina de soporte de vector (SVM). Todavía quedan muchos retos pendientes en el estudio de las señales cerebrales, los cuales cada día con la persistencia de los científicos e investigadores irán descifrando la complejidad del cerebro humano.

Capítulo 2.

Marco Teórico

2.1. Preliminares Fisiológicos y Clínicos

2.2. Biopotenciales

Son pequeños impulsos eléctricos mediante los cuales se llevan a cabo funciones importantes del organismo, por ejemplo: los latidos del corazón, movimiento ocular, contracción de los músculos, entre otros.

Desde un punto de vista fisiológico, las funciones realizadas por el cuerpo humano son llevadas a cabo a través de impulsos eléctricos, que a su vez son el resultado de la acción electroquímica de ciertos tipos de células, dichas células generan la diferencia de potencial mediante partículas ionizadas tales como iones de sodio y potasio. Muchos de estos intercambios de potenciales tienen lugar en el cerebro, el cual envía la orden en forma de impulsos eléctricos los cuales son transportados a otra parte del cuerpo a través del sistema nervioso mediante las neuronas. Estas no son más que células especializadas en recibir y transmitir impulsos eléctricos a los que se les denomina potenciales de acción. Dichas descargas eléctricas viajan a través de

la membrana celular y es el principal medio de comunicación entre tejidos y células dentro del cuerpo humano [9].

2.3. Lóbulos del cerebro y sus funciones

El cerebro humano puede dividirse en dos partes más o menos simétricas denominadas hemisferios. Cada hemisferio puede dividirse en 4 lóbulos diferentes [10]:

1. *Lóbulo Occipital:* Interpreta la visión

2. *Lóbulo Parietal:* Interpreta las sensaciones que recibe el resto del cuerpo y controla el movimiento corporal.

3. *Lóbulo Temporal:* La memoria y las emociones dependen de los lóbulos temporales, que permiten la identificación de personas y objetos, procesan y recuerdan sucesos pasados e inician la comunicación o las acciones.

4. *Lóbulo Frontal:* Controla la actividad motora aprendida, como la articulación del lenguaje, el estado de ánimo, el pensamiento y la planificación del futuro. En la mayoría de las personas, el lóbulo frontal izquierdo controla el centro del lenguaje.

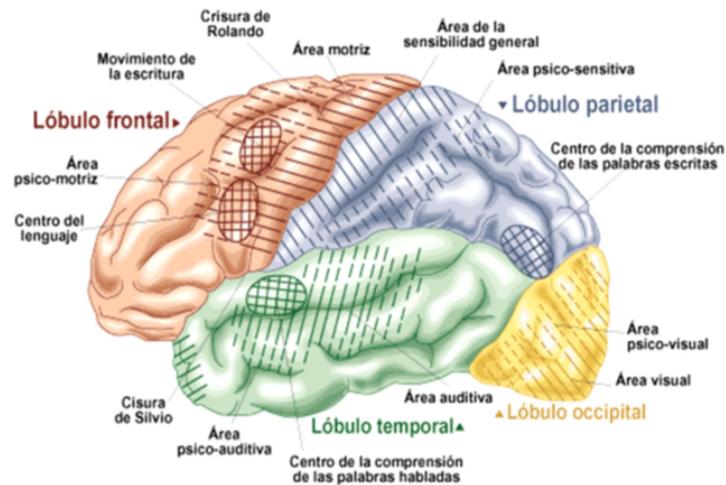


Figura 2.1: Posición de los lóbulos cerebrales y sus funciones, adaptado del trabajo del autor Triglia [11]

2.4. Onda cerebral

Es la actividad eléctrica producida por el cerebro. Estas ondas pueden ser detectadas mediante el electroencefalógrafo y se clasifican en:

Tipo de onda y voltajes	Frecuencia	Situaciones relativas a la que corresponde
Delta	0.2 a 3.5 Hz	Estado hipnótico, sueño profundo
Theta	3.5 a 7.5 Hz	Estado de vigilia
Alfa	7.5 a 13 Hz	Estado de relax, meditación, creatividad.
Beta	13 a 28 Hz	Ritmo normal cuando estamos alertas
Ram-Alta	+ de 28 Hz	Situación de confusión y estrés.

Cuadro 2.1: Posición de los lóbulos cerebrales y sus funciones, adaptado del autor Betha [12]

2.5. Definición y clasificación de los Potenciales evocados

Los potenciales evocados son una prueba no invasiva que estudia la actividad eléctrica neuronal, para examinar si el sistema nervioso funciona de manera correcta ante estímulos externos visuales, táctiles o auditivos. Cada uno de estos estímulos se recauda por un órgano sensorial diferente, donde se traducen a impulsos eléctricos que viajan a través de las neuronas hasta llegar a áreas específicas del cerebro, donde son interpretados. Estas señales son captadas por dispositivos llamados electrodos, los cuales se ubican en la corteza cerebral con el fin de captar los impulsos eléctricos.

2.6. Clasificación de los potenciales evocados

Existen muchas maneras de clasificar los EP, las de mayor aporte se evidencia en los siguientes enunciados: Según su naturaleza, los EPs pueden subdividirse en [14]:

1. EPs exógenos: Son potenciales de latencia corta, determinado por las características físicas del estímulo (luminosidad, intensidad, entre otros).

2. EPs endógenos: Potenciales de latencia tardía, relacionados con el proceso cognitivo que realiza el individuo de la información contenida en un estímulo.

En relación con el órgano sensorial estimulado se puede obtener [15]:

1. Potenciales evocados auditivos: Respuesta eléctrica en la corteza cerebral causada por estimulación acústica o estimulación de las vías auditivas.

2. Potenciales evocados visuales: Respuesta eléctrica evocada en la corteza cerebral por la estimulación visual o estimulación de las vías visuales.

3. Potenciales evocados somatosensoriales: Respuesta eléctrica evocada en la corteza cerebral por la estimulación de vías aferentes de los nervios periféricos al cerebro.

4. Potenciales evocados motores: Respuesta eléctrica evocada en un músculo o nervio motor a una estimulación eléctrica o magnética. los métodos comunes de estimulación son la estimulación transcranial eléctrica y la estimulación magnética transcraneal. Frecuentemente se utiliza como control durante la neurocirugía.

Características generales de los potenciales evocados [16]:

1. Latencia: tiempo en milisegundos desde la presentación del estímulo hasta la aparición del pico o el valle.

2. Intervalos: tiempo en milisegundos entre dos ondas.

3. Amplitud: tamaño de la onda en microvoltios.

4. Polaridad: La polaridad puede ser negativa o positiva, N o negativa aquellas componentes representados por encima de la línea de base o isoelectrica. P son las componentes positivas, que se representan por debajo de esta línea.

Componentes de los potenciales evocados cognitivos [17]:

Onda P100 y N100: Estas componentes presentan una polaridad positiva y nega-

tiva, respectivamente. Se dan al inicio del proceso y registran la atención del sujeto ante un estímulo visual externo, reflejando dicha habilidad respecto al estímulo.

Onda P200 y N200: Estas componentes presentan una polaridad positiva y negativa, respectivamente. Surgen cuando los estímulos comunes y raros se presentan en forma secuencial. Se piensa que esta onda es una señal del proceso de categorización del estímulo.

Onda P300: Un componente de aparición tardía del potencial relacionado con el evento. P300 significa deflexión positiva en el potencial de voltaje relacionado con el evento a 300 milisegundos post-estímulo. Su amplitud aumenta con estímulos impredecibles, improbables o altamente significativos y, por lo tanto, constituye un índice de actividad mental.

Onda N400: Esta componente ha despertado un especial interés en diferentes áreas de investigación debido los signos de procesamiento del lenguaje que muestra. En [18], [19], Kutas y Hillyard describen una deflexión negativa que se presenta entre los 300 y los 500 ms después de la estimulación (haciendo referencia a la N400), la cual está correlacionada con la aparición de palabras semánticamente anómalas en oraciones con sentido contrario. Lo anterior refleja la memoria semántica, es decir, la previsibilidad de una palabra basada en el contenido semántico de la oración anterior.

2.7. Preliminares de los algoritmos de clasificación

Aprendizaje supervisado

Este algoritmo genera una función que forma una correspondencia entre las entradas y las salidas deseadas del sistema, como ejemplos de algoritmos de aprendizaje supervisado tenemos las regresiones y la máquina de vector de soporte (SVM) [20].

Aprendizaje no supervisado

Todo el proceso de modelado se lleva a cabo sobre un conjunto de ejemplos formado tan sólo por entradas al sistema. No se tiene información sobre las categorías de esos ejemplos. Por lo tanto, en este caso, el sistema tiene que ser capaz de reconocer patrones para poder etiquetar las nuevas entradas [21].

Librería scikit-learn

Scikit-learn (anteriormente scikits.learn) es un librería libre de machine learning para lenguaje de programación Python. Cuenta con varios algoritmos de clasificación, regresión y de agrupación. Esta librería está diseñada para interactuar con las bibliotecas de Python NumPy y SciPy [22].

Validación cruzada o cross-validation

Es un modelo de selección de la librería scikit-learn utilizado para evaluar los resultados de un análisis estadístico y garantizar que son independientes de la partición entre datos de entrenamiento y prueba. Los pasos habituales para hallar los k-fold

en la validación cruzada son los siguientes:

- Partición del conjunto de datos en k subconjuntos diferentes.
- Crear k modelos diferentes para entrenar en subconjunto $k-1$ y probar el subconjunto restante.
- Medir el rendimiento en cada uno de los k modelos y tomar el promedio medido.

Función Kernel

Es una alternativa simple para realizar la separación de datos mediante una línea recta, a través de un plano recto o un hiperplano N -dimensional. Los universos a estudiar no se suelen presentar en casos ideales de dos dimensiones, sino que un algoritmo SVM debe tratar con: a) más de dos variables predictoras, b) curvas no lineales de separación, c) casos donde los conjuntos de datos no pueden ser completamente separados, d) clasificaciones en más de dos categorías. Esta estrategia proyecta la información a un espacio de características de mayor dimensión, el cual aumenta la capacidad computacional de las máquinas de aprendizaje lineal [23].

Matriz de confusión

En el ámbito de la inteligencia artificial la matriz de confusión es una técnica que permite la visualización del desempeño de un algoritmo que se utiliza en aprendizaje supervisado. Cada columna de la matriz representa el número de predicciones de cada clase, mientras que cada fila representa a las instancias [24].

Capítulo 3.

Marco Metodológico

3.1. Protocolo experimental

En este trabajo se emplea una base de datos de señales EEG, MEG, resonancia magnética funcional y datos estructurales de resonancia magnética de 16 sujetos, que realizaron múltiples ejecuciones de una tarea donde debían visualizar una cantidad fija de rostros de personas famosas y desconocidas. La base de datos fue conformada por miembros y colaboradores del Laboratorio de Imágenes Funcionales (FIL), del Centro Wellcome Trust for NeuroImaging (WTCN), en el Instituto de Neurología de la University College London (UCL), Reino Unido [25]. Este conjunto de datos contiene información de EEG, MEG y fMRI dentro del mismo paradigma. Se usó para examinar cómo se relacionan diversas medidas de la percepción facial, como el ERP "N170" (EEG), el ERF "M170" (MEG) y la activación fusiforme (fMRI). Por ejemplo, la localización de los generadores del N170 y / o M170 puede verse limitada por las activaciones de fMRI. También incluye una imagen de MRI anatómica de alta resolución (aMRI) para la construcción de un modelo de cabeza para los

datos de EEG y MEG, junto con datos de un digitalizador Polhemus que se puede utilizar para registrar los datos de EEG y MEG con aMRI. Toda esta información se encuentra cargada en un software libre llamado Statistical Parametric Mapping (SPM) , análisis estadístico creado por Karl Friston para examinar las diferencias en la actividad cerebral registradas durante los experimentos de neuroimagen funcional utilizando diferentes tipos de métodos [26]. El protocolo utilizado para la adquisición de los registros, se implementó de la siguiente manera; se tomaron 181 muestras durante 0.905 s, donde cada sujeto observó en una pantalla diferentes tipos de rostros conocidos (famosos) y desconocidos, se utilizaron 74 canales EEG distribuido según los parámetros definidos por el Sistema Internacional 10-20 en los puntos Fz, Cz, Tz y Pz, con referencia a los procesos mastoideos. En este trabajo se usaron los registros de la región parietal-occipital específicamente los electrodos P9, P10, PO7, PO8, P7 y P8. Algunos estudios concluyen que las diferencias más marcadas se encuentran en las regiones parietales [27], [28]. La tasa de muestreo se estableció en 200 Hz, todas las señales obtenidas en cada electrodo según el paradigma fueron promediadas.

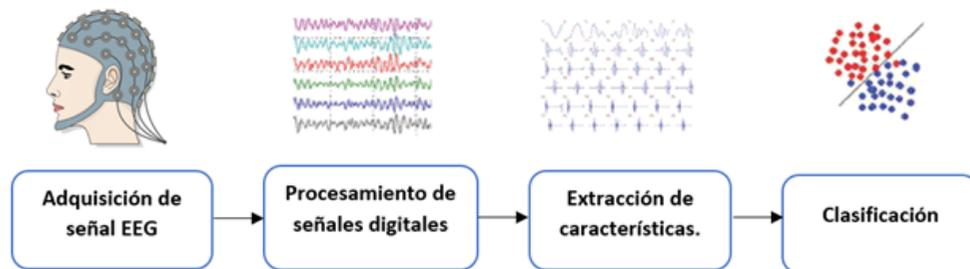


Figura 3.1: Diagrama de bloque del sistema

3.2. Preprocesamiento y extracción de Características

3.2.1. Filtrado

Las señales EEG son no estacionarias y ruidosas, por lo que es importante usar filtros apropiados para reducir el ruido sin eliminar información relevante. Aplicamos un filtro rechaza banda digital de 50 Hz para eliminar la interferencia de la fuente de alimentación y un filtro FIR pasa banda digital, de orden 60, fase cero y frecuencias de corte de 0,5 Hz y 30 Hz para preservar las ondas delta (0,5 - 4 Hz), theta (4-8 Hz), alfa (8-13 Hz) y beta (13-30 Hz).

3.3. Transformada Wavelet Discreta

El análisis de wavelets discretas multirresolución permite la descomposición de una señal en varios niveles para obtener coeficientes de aproximación (CA) y coeficientes de detalle (CD). En cada nivel, los coeficientes de aproximación se descomponen de nuevo en una aproximación y detalles [29].

Los registros de EEG se descompusieron en 6 niveles para obtener rangos de frecuencia más cercanos a los ritmos cerebrales delta (0.5 a 4 Hz), theta (4-8 Hz), Alpha (8-13 Hz) y beta (13 a 30 Hz). La descomposición de Wavelet se muestra en la Figura 2. Los coeficientes de interés son A6, D6, D5 y D4. El resto de los coeficientes se pusieron a cero en el momento de la reconstrucción de la señal. Para la selección de la wavelet madre se estimó la covarianza cruzada de la señal EEG con varias wavelets,

donde la wavelet madre bior 3.5 fue la que tuvo menor valor de covarianza cruzada, debido a su similitud con la señal ERP. En la Tabla I se evidencia los resultados.

Wavelet Madre	Db1	Db2	Db3	Db4	Db45
Covarianza	1.88	0.99	0.87	0.84	0.83
Wavelet Madre	Bior1.3	Bior2.2	Bior3.5	Bior4.4	Bior5.5
Covarianza	1.88	0.76	0.62	0.81	0.94

Cuadro 3.1: Selección de la Wavelet madre

Los siguientes parámetros estadísticos se calcularon a partir de los coeficientes wavelet: rango intercuartílico (IQR, que mide la extensión de un conjunto de datos), valor máximo, valor mínimo, varianza y potencia de la señal [30].

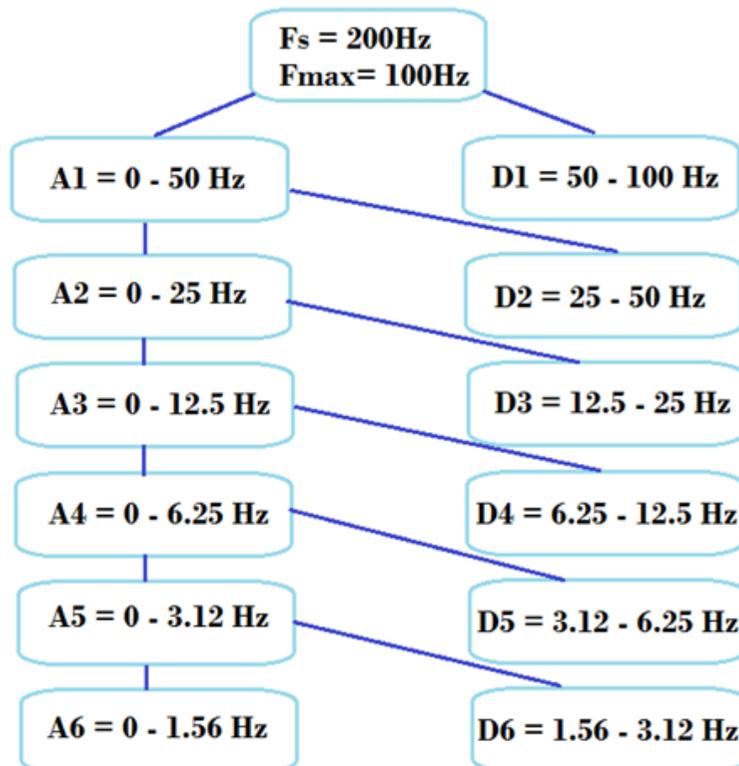


Figura 3.2: Descomposición Wavelet

3.3.1. Análisis de potenciales evocados

Para el análisis de los ERP, se utilizaron promedios de conjunto de respuestas individuales, a partir de repeticiones del mismo experimento para reducir el ruido introducido por EEG, EMG e interferencia de la fuente de alimentación. Los componentes de la forma de onda ERP están asociados con operaciones de cognición humana. La Figura 3 muestra componentes de potenciales evocados [31]. En este trabajo, se analizaron 6 componentes: P1, N170, P2, N250, P3 y N400. La latencia P1 se encontró en el intervalo (80-170 ms) en los electrodos Oz, O1 y O2; N170 en el intervalo (150-200 ms) en los electrodos P9 y P10, PO7 PO8; P2 entre (200-300 ms); P3 (300-400ms) y finalmente N400 entre (400-550 ms).

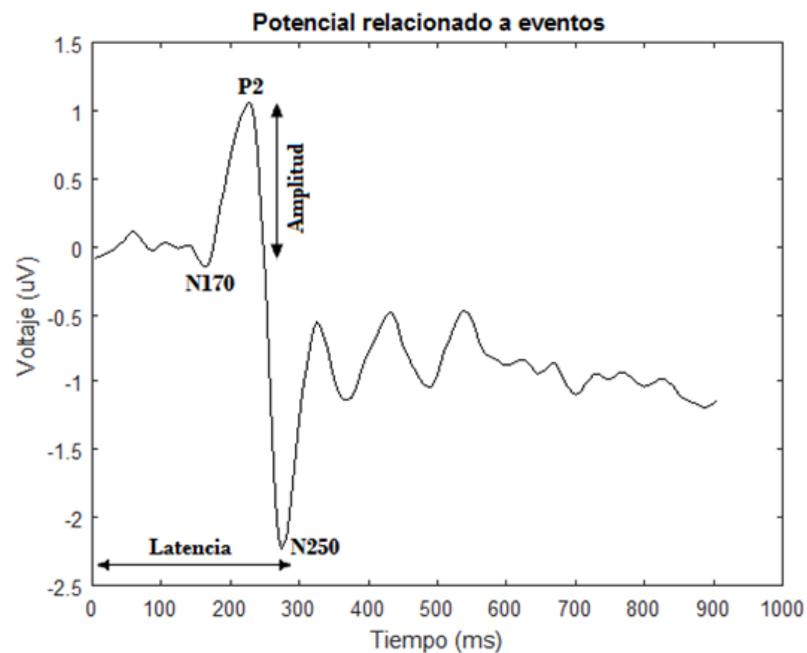


Figura 3.3: Forma de onda del potencial evocado

Estos componentes se analizaron para obtener amplitud y latencia. La Figura 3.4 muestra la ubicación de los componentes de acuerdo con la posición cerebral [32].

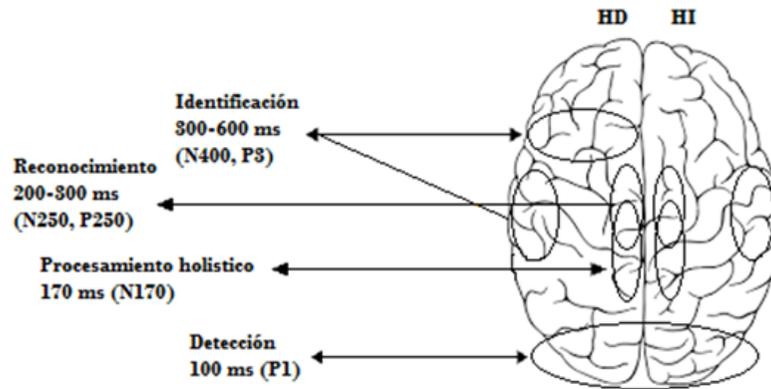


Figura 3.4: Reconocimiento e identificación de rostros (adaptado de la tesis doctoral de Mera Ana 2013) [33].

3.4. Etapa de clasificación

Para la etapa de clasificación, se utiliza una SVM con validación cruzada en Python y regresión logística binomial en Matlab. Para la evaluación de los modelos utilizar los mismos datos para el entrenamiento no es útil, debido a que el clasificador memoriza y no generaliza. La estrategia que se utilizó consiste en tomar todos los datos etiquetados y dividirlos en subconjuntos de entrenamiento y evaluación, normalmente con una proporción del 70 al 80 % para entrenamiento y un 20 al 30 % para evaluación. Para este caso, el mejor desempeño se encontró cuando el conjunto de datos se dividió en un 70 % para el entrenamiento y un 30 % para prueba.

3.5. Regresión logística binaria

Los modelos de regresión logística se utilizan para determinar la relación entre una variable dependiente dicotómica (regresión logística binaria) y una o más variables independientes explicativas. Las variables que se utilizaron para este clasificador lineal se centraron en las características morfológicas (amplitud y latencia) y para el análisis wavelet en los coeficientes de energía y estadísticos simples (IQR, máximo, mínimo, varianza, potencia) de los coeficientes de aproximación y detalle.

Para resolver el problema de clasificación se planteó la condición inicial o Hipótesis en relación con la amplitud y latencia de las componentes cerebrales según el protocolo de visualización de imágenes de rostros conocidos (famosos) y desconocidos. Se usó el bit 1 cuando los sujetos observaron imágenes conocidas y el bit 0 para imágenes desconocidas.

$$y = \begin{cases} \text{Características generadas con imágenes conocidas} & 1 \\ \text{Características generadas con imágenes desconocidas} & 0 \end{cases} \quad (3.1)$$

Para obtener el modelo que pronostique la probabilidad de ocurrencia de una variable, se le debe agregar el logaritmo neperiano dentro de la ecuación de la regresión lineal garantizando así la linealidad del modelo en el plano logarítmico (Ecuación 3.3).

$$Y = \theta_0 + \theta_1 x_1 + \theta_2 x_2 \quad \text{Regresión Lineal} \quad (3.2)$$

$$\ln \left\{ \frac{p}{1-p} \right\} = \theta_0 + \theta_1 x_1 + \theta_2 x_2 \quad \text{Regresión Logística} \quad (3.3)$$

Para efectos prácticos se realiza el reemplazo $Y^* = \ln(p/(1-p))$ en la ecuación(3.3) obteniendo $Y^* = \theta_0 + \theta_1 x_1 + \theta_2 x_2$, despejando las ecuaciones se observará que el modelo de regresión logística parte de la hipótesis de que los datos siguen el siguiente modelo [34]:

$$p = \frac{e^{Y^*}}{1 + e^{Y^*}} \quad (3.4)$$

3.6. Máquinas de vectores de soporte

Los clasificadores SVM son técnicas lineales que maximizan el margen de separación entre dos clases, bajo el supuesto de una mejor capacidad de generalización del clasificador. En el aprendizaje automático, la generalización es la capacidad de clasificar correctamente los datos de validación, lo que nos indica que el clasificador tendrá un buen comportamiento con datos diferentes a los de entrenamiento.

Para la implementación de este clasificador, inicialmente se normalizaron los datos, luego se sometieron a la técnica validación cruzada como estrategia para garantizar la independencia de los datos, posteriormente se seleccionó un kernel lineal para

mejorar la clasificación y finalmente para validar el desempeño del clasificador se usó la herramienta de visualización matriz de confusión. Esta herramienta estaba soportada bajo la librería scikit-learn en el software Python, donde se trabajaron análisis estadísticos con las siguientes funciones; precisión, recall, and F1-score (or f-measure), como estrategia para validar el rendimiento del algoritmo.

	P' (Predicted)	N' (Predicted)
P (Actual)	True Positive	False Negative
N (Actual)	False Positive	True Negative

Figura 3.5: Matriz de confusión.

Capítulo 4.

Resultados y Discusión

Para todos los experimentos realizados, se validó que las señales (EEG) relacionadas a eventos visuales contienen un alto índice de ruido. Inicialmente se procedió a implementar una fase de pre-procesamiento, donde los mejores resultados se encontraron cuando se implementó un filtro FIR rechaza banda con frecuencia de corte de 50 hz, y un filtro FIR de orden 60 con frecuencia de corte comprendida entre 0.5 y 30 hz en cascada, en la figura 4.1 y 4.2 se evidencia lo mencionado anteriormente.

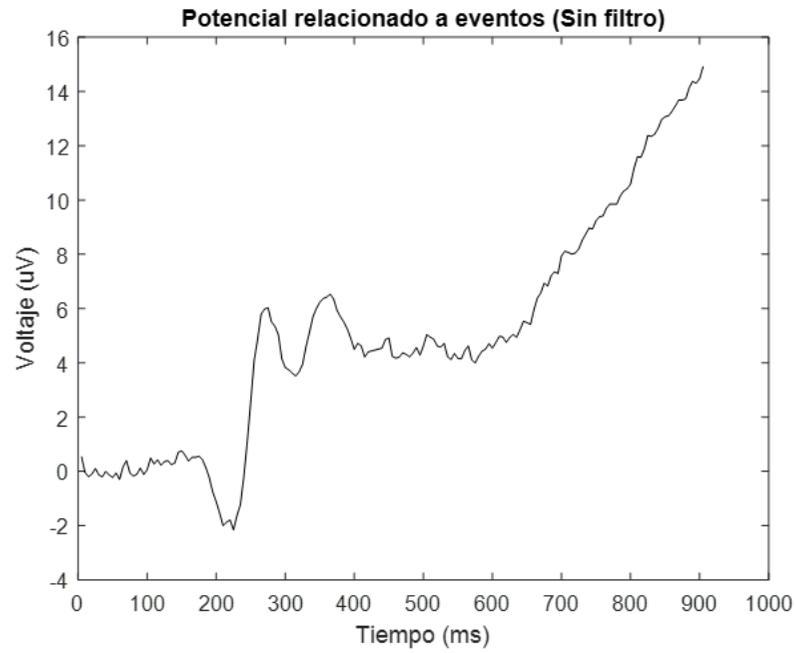


Figura 4.1: Potencial relacionado con eventos sin filtrado

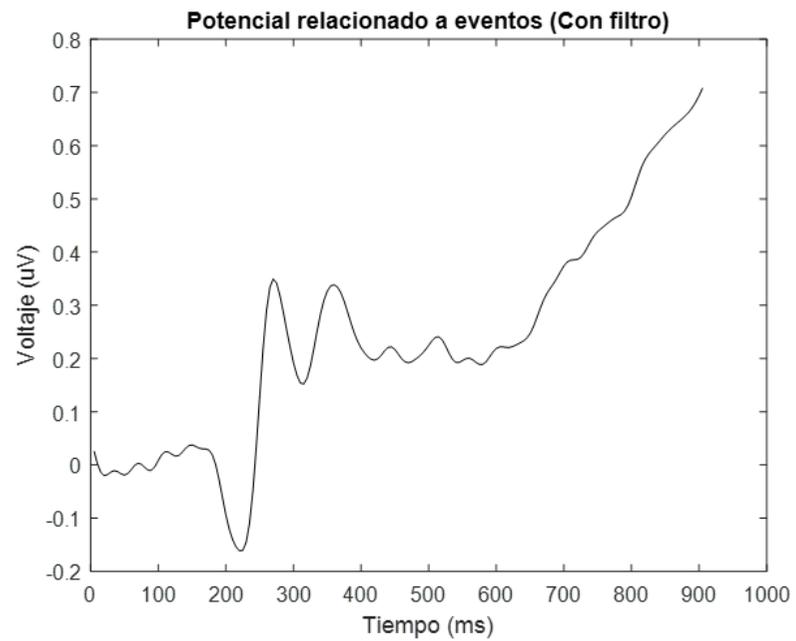


Figura 4.2: Potencial relacionado con eventos con filtrado

Luego se procedió a trabajar con algunos algoritmos para extraer características, puntualmente con la transformada Wavelet y luego con el análisis morfológico de la señal. Con la técnica Wavelet se evidencia un aumento de los coeficientes de energía Ed3 y Ed2 y una disminución en los coeficientes Ea1, Ed6, Ed5 y Ed4 y Ed1 para los electrodos Fp1, Fpz, Fp2, AF7, AF3, AFz, AF4, AF8, Fc5, C4, Oz, P9, P10, PO7, PO8, P7 y P8; cuando el sujeto observa imágenes de rostros famosos.

Ea1	Ed6	Ed5	Ed4	Ed3	Ed2	Ed1
2.7577E-05	0.0017	0.0723	0.238	0.523	0.4370	98.727

Cuadro 4.1: Coeficientes de energía Wavelet rostros famosos

Ea1	Ed6	Ed5	Ed4	Ed3	Ed2	Ed1
2.3988E-05	0.0023	0.0776	0.2805	0.4831	0.3728	98.783

Cuadro 4.2: Coeficientes de energía Wavelet rostros desconocidos

Para el análisis morfológico, se tuvieron en cuenta parámetros como la amplitud (valor pico a pico de la señal) y latencia (lapso de tiempo desde la aparición del estímulo). Se identificó que los electrodos Fp1, Fpz, AFz, AF4, AF8, Fc5, Fc3, Fcz y Fc4 presentan una mayor amplitud en las componentes P2 y N250 para sujetos que han observado imágenes de caras desconocidas y manifiestan una mayor amplitud en las componentes N170, P3 y N350 para rostros conocidos (famosos). Comparando con el estado del arte y los aportes de los expertos de la salud, destacamos la investigación de los autores Olivares y Saavedra [35] donde afirman que el procesamiento y reconocimiento de las caras tienen relación con los potenciales relacionados

a eventos. Plantean que el procesamiento inicial de las caras está relacionado con respuestas electrofisiológicas muy tempranas como la onda occipital P120, la onda N170 la relacionan con el reconocimiento visual de la identidad y las ondas N250 y N400 son las que reflejan los procesos de acceso y recuperación de información relativa a las caras conocidas en la memoria a largo plazo. En la figura 4.3 se evidencia lo detallado anteriormente.

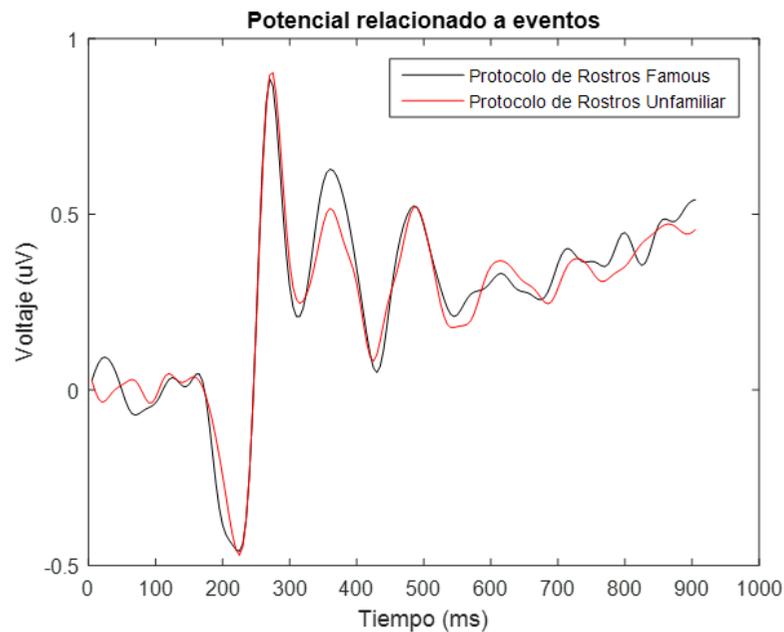


Figura 4.3: Comparación de los Potenciales relacionado a eventos de rostros famosos y desconocidos.

Para la etapa de clasificación se implementaron los algoritmos SVM y regresión logística binaria. El mejor desempeño se encontró en el último algoritmo predictor, exactamente con los parámetros amplitud y latencia en las componentes N170, P2 y N250 con una precisión del 80 %. Los resultados de la clasificación se muestran a continuación.

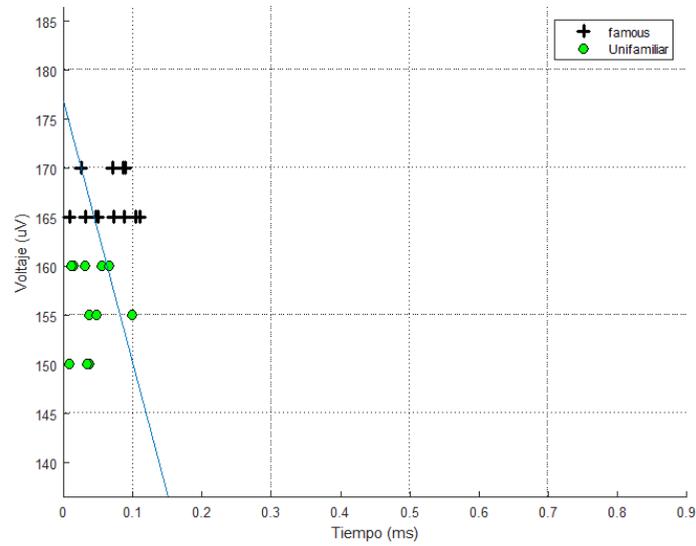


Figura 4.4: Predicción del algoritmo regresión logística binaria con características morfológicas.

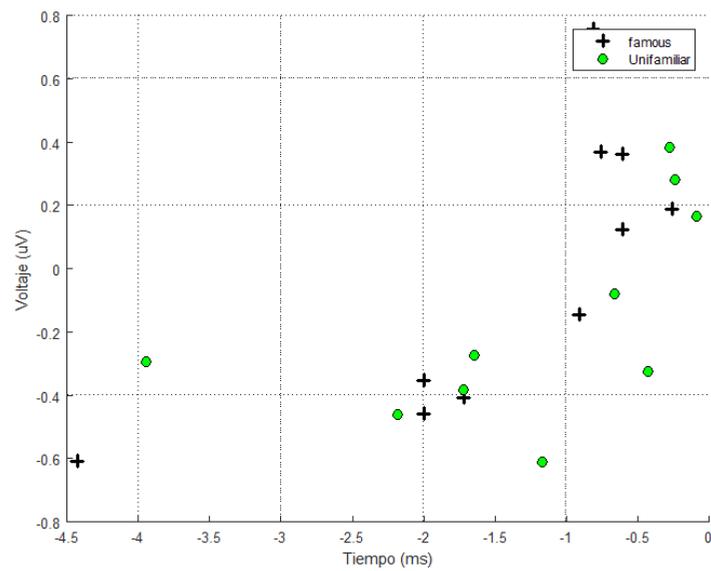


Figura 4.5: Predicción del algoritmo regresión logística binaria con características wavelet.

SVM	Valor
R^2	0.73
Cross-Validation score	0.73
Eout	0.72
Best # Neurons	13
Precision Score	0.7
Recall Score	0.79
Specifity Score	0.77
F1 Score	0.76

Cuadro 4.3: Terminología y derivaciones de la matriz de confusión para el algoritmo SVM con características morfológicas

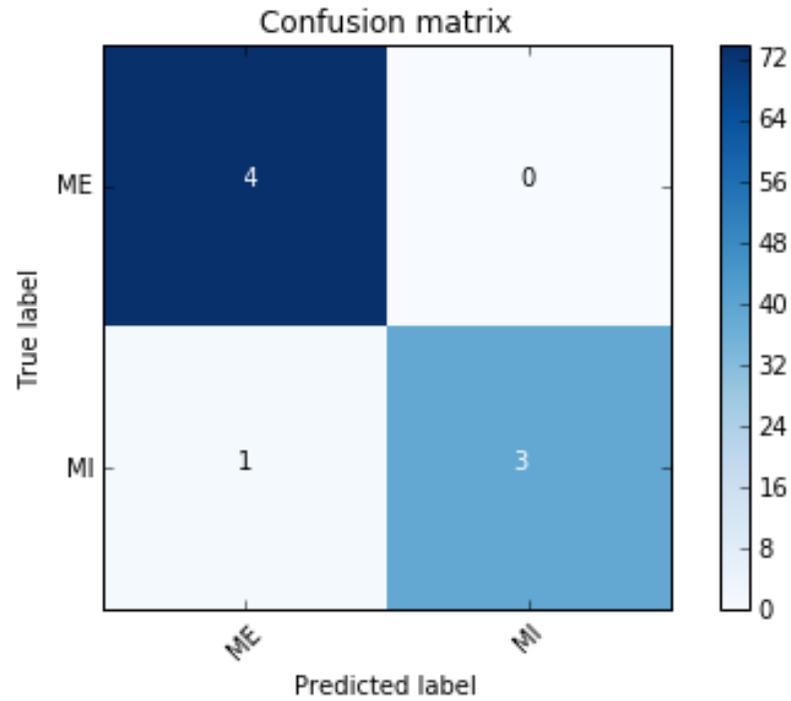


Figura 4.6: Matriz de confusión para el algoritmo SVM con características morfológicas.

SVM	Valor
R^2	0.6
Cross-Validation score	0.62
Eout	0.62
Best # Neurons	10
Precision Score	0.6
Recall Score	0.59
Specifity Score	0.68
F1 Score	0.65

Cuadro 4.4: Terminología y derivaciones de la matriz de confusión para el algoritmo SVM con características wavelet

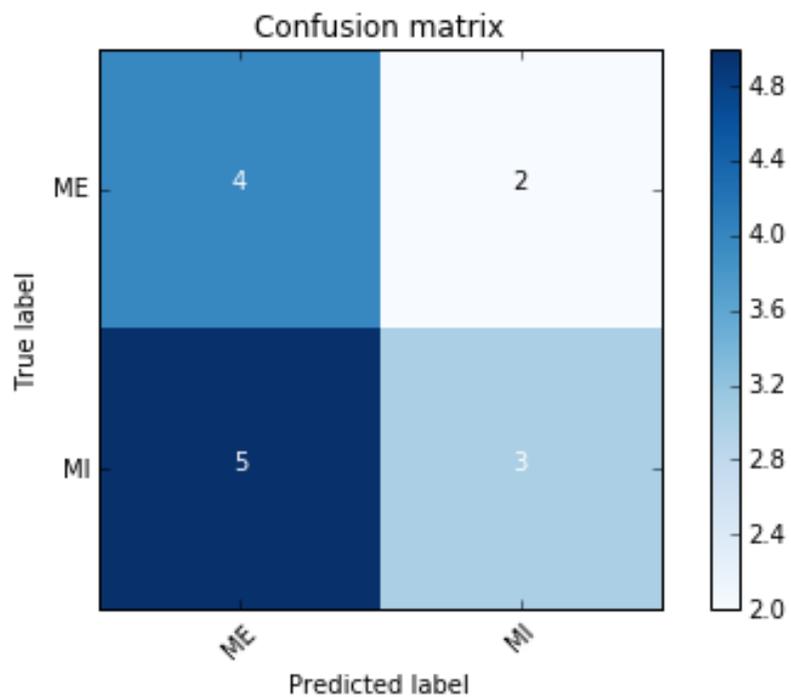


Figura 4.7: Matriz de confusión para el algoritmo SVM con características Wavelet.

Tipo de Características	Metodos de Clasificacion	Exactitud de Clasificación
Morfologicas	Regresion logistica binaria	80 %
Wavelet	Regresion logistica binaria	69 %
Morfologicas	SVM	70 %
Wavelet	SVM	68 %

Cuadro 4.5: Rendimiento de los clasificadores

Para los experimentos se compararon técnicas de extracción y selección de característica en términos de desempeño de clasificación, los resultados de la metodología implementada muestran que es posible discriminar y reconocer con un buen porcentaje de acierto, rostros de caras famosas y desconocidas utilizando herramientas con potenciales relacionados a eventos en las regiones Frontal-parietal-occipital.

Finalmente, se compararon los resultados con investigaciones realizadas por el autor Zheng et. donde trabajan con un conjunto de características de las señales EEG de 7 sujetos, en función de la frecuencia de tiempo. En el protocolo implementado, los sujetos están expuestos a estímulos visuales de imágenes familiares y desconocidas en un período de tiempo fijo durante un paradigma experimental. Los resultados muestran que la combinación de características tales como los valores de potencia de banda, los picos de la señal y el desplazamiento de la señal proporciona una precisión promedio del 70,71 % al clasificar imágenes familiares y no familiares [36]. El clasificador utilizado fue SVM.

Capítulo 5.

Conclusiones

Se han realizado diferentes esfuerzos por lograr una metodología de clasificación automática de registros de potenciales evocados. Para la presente investigación se han logrado algunos resultados satisfactorios, a pesar de la naturaleza compleja de este tipos de señales, todavía quedan muchos esfuerzos que agotar. En el presente estudio se validó que los electrodos ubicados en la región cerebral parietal-occipital contiene importante información de las componentes N170, P2 y N250, que pueden facilitar estudios posteriores donde se analice mejor la interacción de los lóbulos al momento se experimentar estímulos externos. Fue necesario realizar un buen procesamiento para lograr tener una señal mucho más limpia y poder extraer buenas características. Las características que mayor aporte tuvieron para la etapa de clasificación fueron las morfológicas. Por último el clasificador que mejor resultados obtuvo fue la regresión logística binaria logrando un porcentaje de acierto superior a un 80 %, utilizando las características de amplitud y latencia de las componentes mencionadas anteriormente.

Como trabajo futuro se propone, continuar evaluando algoritmos de extracción de

características más robustos que permitan emplear otro tipo de patrones discriminantes para describir los cambios generados en la forma de ondas de los potenciales evocados visuales y considerar el uso de algoritmos no supervisados mediante técnicas no lineales.

Capítulo 6.

Bibliografía

- [1] Lopera, R. F. (2000). Procesamiento de caras: bases neurológicas, trastornos y evaluación. *Revista de Neurología*, 30(5), 1-5.
- [2] Y.Pérez, Memoria de rostros y reconocimiento emocional: generalidades teóricas , bases neurales y patologías asociadas Face memory and emotional recognition: Theory , neural substrates and related pathologies, vol. 28, no. 116, pp. 27–40, 2014.
- [3] E. I. Olivares, C. Saavedra, and J. Iglesias, “Potenciales evocados como marcadores neurofisiológicos de la percepción y el reconocimiento de caras,” pp. 27–38, 2012.
- [4] ÖZBEYAZ and S. ARICA, “Classification of EEG signals of familiar and unfamiliar face stimuli exploiting most discriminative channels,” *Turkish J. Electr. Eng. Comput. Sci.*, vol. 25, pp. 3342–3354, 2017.
- [5] Y. Li et al., “Single Trial EEG Classification Applied To a Face Recognition Experiment Using Different Feature Extraction Methods,” *IEEE Eng Med Biol Soc.*, pp. 7246–7249, 2015.
- [6] R. N. Henson, D. G. Wakeman, V. Litvak, K. J. Friston, and N. J. Trujillo-barreto,

“A parametric empirical Bayesian framework inverse problem generative models for multi-subject and multimodal integration,” vol. 5, August, pp. 1–16, 2011.

[7] E. I. Olivares, C. Saavedra, and J. Iglesias, “Potenciales evocados como marcadores neurofisiológicos de la percepción y el reconocimiento de caras,” pp. 27–38, 2012.

[8] T. Zheng, H. Ernest, K. G. Smitha, and A. P. Vinod, “Detection of Familiar and Unfamiliar Images using EEG-based Brain-Computer Interface,” 2015. pp. 1–2.

[9] Florez.L. (2017). “Análisis de Señales Electromiográficas de Superficie para la Estimación de Estados de Fatiga Muscular Mediante el Uso de la Transformada Wavelet y Regresión Logística Binaria .”

[10] Berkow, R. (2003). Trastorno del cerebro y del sistema nervioso. Manual Merck De Información Médica. Editorial OCEANO. pp 292-293

[11] Adrián Triglia, “Los lóbulos del cerebro y sus distintas funciones,” 12 Diciembre, p. 1, 2017.

[12] D. O. Beta, O. Alfa, O. Theta, and O. Delta, “Sensorium,” pp. 3–4, 2018.

[13] D. Saceda, “Estudio de potenciales evocados,” pp. 1–5, 2017.

[14] Byrne, J.M., Connolly, J.F., Maclean, S. (1999). Brain Activity and language assesment using event-related potentials: Developmet of a clinical protocil. Developmental Medicineand Child Neurology

[15] Definición de la biblioteca virtual en salud (Decs). Recuperado el 8 de mayo de

2018. <http://decs.bvs.br/cgi-bin/wxis1660.exe/decsserver/>

[16] J. G. Webster, *Encyclopedia of Medical Devices and Instrumentation*. John Wiley&Sons, 2006, vol.6.

[17] Gonzalez,L (2013)“Características Neuropsicológicas y Neurofisiológicas de la Memoria de Trabajo del Traductor”.

[18] S. A. H. M. Kutas, “Event-related brain potentials to semantically inappropriate and surprisingly large words,” *Biological Psychology*, vol. 11, no. 2, p. 99–116, Sep 1980.

[19] “Reading senseless sentences: Brain potentials reflect semantic incongruity,” *Science*, vol. 207, no. 4427, p. 203–205, 1980.

[20] Bishop, Christopher (2008) *Pattern Recognition and Machine Learning*. Springer Verlag. ISBN=978-0-3873-1073-2.

[21] Flach, Peter (2012) *Machine Learning: The Art and Science of Algorithms that Make Sense of Data*. Cambridge University Press. ISBN 978-1-107-42222-3.

[22] Benitez Raul, libro inteligencia artificial avanzada, editorial fuoc, marzo 2012.

[23] Garreta Raul learning scikit-learn machine learning in python, editorial packt, abril 2013

[24] Mitchell, T. (1997). *Machine Learning*, McGraw Hill. ISBN 0-07-042807-7

[25] R. N. Henson, “Multi-modal Face Dataset,” *Funct. Imaging Lab*, <http://www.fil.ion.ucl.ac.uk/sp>

p. 2018, 2009.

[26] Members and collaborators of the Wellcome Trust Centre for Neuroimaging, “SPM software- Statistical Parametric Mapping,” <http://www.fil.ion.ucl.ac.uk/spm/software/>, vol. no. 13/04/2012, pp. 3–4, 1991.

[27] R. Barry, S. Johnstone, and A. Clarke, “A review of electrophysiology in attention-deficit/hyperactivity disorder: Ii. event-related potentials,” *Clinical Neurophysiology*, vol. 114, no. 2, pp. 184–198, 2003.

[28] F. Restrepo, L. Tamayo-Orrego, J. Parra Sanchez, A. Vera Gonzalez, and O. Moscoso Ariza, p300-wave modulation in a group of colombian children with attention deficit/hyperactivity disorder,” *Acta neurol. colomb*, vol. 27, no. 3, pp. 146–153, 2011.

[29] Chethan, P., Cox, M. (2002). Frequency characteristics of wavelets. *IEEE Transactions on Power Delivery*, 17(3), 800- 804.

[30] Prias, L. (2017). Analisis de Señales Electromiograficas de Superficie para la Estimacion de Estados de Fatiga Muscular Mediante el Uso de la Transformada Wavelet y Regresion Logistica Binaria. pp 35-36

[31] A. Ahmadi, O. Dehzangi, and R. Jafari, “Brain-computer interface signal processing algorithms: A computational cost vs. accuracy analysis for wearable computers,” in *Wearable and Implantable Body Sensor Networks (BSN)*, 2012 Ninth International Conference on. IEEE, 2012, pp. 40–45.

- [32] P. Alexandra and C. Cabrera, “Extracción y Selección de Características Discriminantes para la Detección de TDAH en Registros de Potenciales Evocados Cognitivos,” 2011.pp. 12–13.
- [33] Prias, L. (2017). Analisis de Señales Electromiograficas de Superficie para la Estimacion de Estados de Fatiga Muscular Mediante el Uso de la Transformada Wavelet y Regresion Logistica Binaria. pp 38-39
- [34] U.D.E.S.D.E. Compostela and T. Doctoral, “Potenciales cerebrales relacionados con el procesamiento del estímulo y con la programación motora ante tareas de reconocimiento y denominación de caras en jóvenes y mayores.”
- [35] E. I. Olivares, C. Saavedra, and J. Iglesias, “Potenciales evocados como marcadores neurofisiológicos de la percepción y el reconocimiento de caras,” pp. 2–3, 2012.
- [36] T. Zheng, H. Ernest, K. G. Smitha, and A. P. Vinod, “Detection of Familiar and Unfamiliar Images using EEG-based Brain-Computer Interface,” 2015.pp. 3–4.