

INSTITUTO TECNOLÓGICO DE CHIHUAHUA
DIVISIÓN DE ESTUDIOS DE POSGRADO E INVESTIGACIÓN

**“RECONOCIMIENTO DE EMOCIONES EN SEÑALES
EEG MEDIANTE ALGORITMO DE APRENDIZAJE
AUTOMÁTICO”**

TESIS

QUE PARA OBTENER EL GRADO DE

**MAESTRO EN CIENCIAS EN INGENIERÍA
ELECTRÓNICA**

PRESENTA:

FELIPE ELIACIM GARAY ACUÑA

DIRECTOR DE LA TESIS:
DR. JUAN ALBERTO RAMÍREZ QUINTANA

CHIHUAHUA, CHIH., JUNIO, 2022



EDUCACIÓN
SECRETARÍA DE EDUCACIÓN PÚBLICA



TECNOLÓGICO
NACIONAL DE MÉXICO





Chihuahua, Chih. 6 de junio de 2022

C. FELIPE ELIACIM GARAY ACUÑA
PRESENTE

En cumplimiento con los requerimientos para la obtención del grado de Maestro en Ciencias en Ingeniería Electrónica y a propuesta de su Comité Tutorial, la División de Estudios de Posgrado e Investigación le concede la autorización para imprimir la tesis titulada *"Reconocimiento de emociones en señales EEG mediante algoritmo de aprendizaje automático"* dirigida por el Dr. Juan Alberto Ramírez Quintana con el siguiente contenido de capítulos:

- I Introducción
- II Antecedentes
- III Análisis de los modelos presentes en la literatura
- IV Propuestas iniciales
- V Modelo propuesto
- VI Resultados
- VII Conclusiones y trabajo futuro

A T E N T A M E N T E

Excelencia en Educación Tecnológica®
"La Técnica por el Engrandecimiento de México"

ROGELIO ENRIQUE BARAY ARANA
JEFE DE LA DIVISIÓN DE ESTUDIOS DE POSGRADO E INVESTIGACIÓN

REBA/adcs





Chihuahua, Chih. 2 de junio de 2022

ROGELIO ENRIQUE BARAY ARANA
JEFE DE LA DIVISIÓN DE ESTUDIOS DE POSGRADO E INVESTIGACIÓN
PRESENTE

En cumplimiento con los requerimientos para la obtención del grado de Maestro en Ciencias en Ingeniería Electrónica, le notificamos que el documento de tesis del alumno **C. FELIPE ELIACIM GARAY ACUÑA**, titulado *"Reconocimiento de emociones en señales EEG mediante algoritmo de aprendizaje automático"* dirigido por el Dr. Juan Alberto Ramírez Quintana, ha sido aprobado y aceptado para su impresión.

Por lo anterior, proponemos le sea concedida la autorización de impresión correspondiente.

Agradeciendo la atención a la presente, quedamos de usted:

ATENTAMENTE
Excelencia en Educación Tecnológica®
"La Técnica por el Engrandecimiento de México"

Juan Ramírez

DR. JUAN ALBERTO RAMÍREZ QUINTANA
MIEMBRO DEL COMITÉ TUTORIAL

DR. MARIO IGNACIO CHACÓN MURGUÍA
MIEMBRO DEL COMITÉ TUTORIAL

MTRO. ALFREDO CHACÓN ALDAMA
MIEMBRO DEL COMITÉ TUTORIAL

MTRA. ALMA DELIA CORRAL SÁENZ
MIEMBRO DEL COMITÉ TUTORIAL





CARTA CESIÓN DE DERECHOS

En la ciudad de Chihuahua el día 7 de junio de 2022, el que suscribe, C. FELIPE ELIACIM GARAY ACUÑA con número de control G19061415, de la Maestría en Ciencias en Ingeniería Electrónica, adscrita a la División de Estudios de Posgrado e Investigación del Instituto Tecnológico de Chihuahua, manifiesta que es autor intelectual del presente trabajo de Tesis bajo la dirección del el Dr. Juan Alberto Ramírez Quintana y cede los derechos del trabajo titulado "Reconocimiento de emociones en señales EEG mediante algoritmo de aprendizaje automático", al Tecnológico Nacional de México y/o Instituto Tecnológico de Chihuahua para su difusión, divulgación, transmisión, reproducción, así como su digitalización con fines académicos y de investigación.

C. FELIPE ELIACIM GARAY ACUÑA





DECLARACIÓN DE ORIGINALIDAD

En la ciudad de Chihuahua el día 7 de junio de 2022, el que suscribe, C. FELIPE ELIACIM GARAY ACUÑA de la Maestría en Ciencias en Ingeniería Electrónica, con número de control G19061415, adscrito a la División de Estudios de Posgrado e Investigación del Instituto Tecnológico de Chihuahua, manifiesta que es autor intelectual de la tesis titulada "Reconocimiento de emociones en señales EEG mediante algoritmo de aprendizaje automático" bajo la dirección el Dr. Juan Alberto Ramírez Quintana; que el contenido es original y que las fuentes de información consultadas para su fundamentación están debidamente citadas y referenciadas.

C. FELIPE ELIACIM GARAY ACUÑA



Chihuahua, Chihuahua, junio de 2022

María Elena Álvarez-Buylla Roces
Directora de Conacyt

Sirva la presente para saludarla e informarle que a la fecha he obtenido el grado de **Maestro en Ciencias en Ingeniería Electrónica** en la División de Estudios de Posgrado e Investigación del Instituto Tecnológico de Chihuahua, motivo por el cual agradezco todo el apoyo brindado por este Consejo que usted representa, con el otorgamiento de una beca que permitió dedicarme de manera exclusiva a la realización de mis estudios de posgrado y de esta manera lograr el objetivo principal del convenio establecido.

Sin otro particular quedo a sus órdenes no sin antes reiterar mi agradecimiento.
Atentamente



Felipe Eliacim Garay Acuña

A Aquel por cuya causa son todas las cosas

Y por el cual todas las cosas subsisten.

Por ser mi sustento y fortaleza en todo momento.

Por cuya gracia soy lo que soy y estoy donde estoy.

Agradecimientos

Agradezco Dios por ser mi fuerza y motivación de cada momento para caminar esta vida, sin cuya Palabra y Vida no podría conocer la verdadera vida.

Agradezco a mi esposa Elizabeth, por su apoyo, tolerancia y mucha comprensión, y por ser una muy grande motivación en mi vida y en mi trabajo, al lado de quien he experimentado los mejores momentos de mi vida.

Agradezco a mi familia, a mi padre Felipe Garay, mi madre Matilde Acuña, mi hermana Daniela Garay y mi hermano Abraham Garay, por sus palabras en el momento oportuno, sus risas y apoyo incondicional a lo largo de mi formación, con quienes he experimentado enriquecedores momentos.

Agradezco a mis amigos cercanos por los momentos inolvidables en el laboratorio y a lo largo de mi formación, a Vicente González, Miguel Gutiérrez y Xavier Nevarez, por sus risas, chistes, comentarios e interesantes debates sobre la vida y la fe.

Agradezco a mi director de tesis el Dr. Juan A. Ramírez Quintana, por su confianza y mucha tolerancia durante esta etapa, sin cuyos consejos y enseñanzas no podría haber terminado mi extensa tesis.

Agradezco a todos aquellos con cuyas palabras, consejos, ánimos y porras, me ayudaron a no perder de vista la meta.

RESUMEN

RECONOCIMIENTO DE EMOCIONES EN SEÑALES EEG MEDIANTE ALGORITMO DE APRENDIZAJE AUTOMÁTICO

Ing. Felipe Eliacim Garay Acuña
Maestría en Ciencias en Ingeniería Electrónica
División de Estudios de Posgrado e Investigación del
Instituto Tecnológico de Chihuahua
Chihuahua, Chih. 2021
Director de Tesis: Dr. Juan Alberto Ramírez Quintana

El reconocimiento de emociones con señales de electroencefalografía (EEG) es un tema importante debido a su éxito en la descripción del estado anímico de una persona. Existe en la literatura una cantidad significativa de trabajos de reconocimiento de emociones con EEG que usan inteligencia artificial, sin embargo, la mayoría de ellos se basan en el modelo dimensional y no se ha encontrado una revisión de la literatura para definir cuál es la mejor metodología para esta tarea de reconocimiento. Por lo tanto, en esta tesis se desarrolló un estudio del estado del arte de los métodos de reconocimiento de emociones para proponer un método novedoso con el modelo discreto en una red neuronal convolucional con módulo *Inception* modificado llamada *D-Inception*. Este módulo agrega otra capa de convolución, activación, sub-muestreo y normalización por lote en cada nivel jerárquico. La entrada de la red son las señales obtenidas de los electrodos AF3, AF4, F7, F8, F3, F4, FC5, FC6, T7, T8, P7, P8, O1 y O2, que forman muestras de una imagen de tres dimensiones, donde el primer canal posee información sobre la asimetría del espectro de energía en la banda de frecuencia alfa, el segundo canal contiene información de la entropía espectral (SE) en la banda de frecuencia beta y el tercer canal muestra la información de la entropía temporal de la señal en la banda de frecuencia theta. Con esta información, se clasifican cuatro emociones discretas: neutralidad, tristeza, miedo y felicidad. El entrenamiento de la red neuronal convolucional propuesta se realizó con el optimizador ADAM (*Adaptive Moment*

Estimation) y de acuerdo con los experimentos, se obtuvieron los mejores resultados en el modelo discreto con precisiones con valor de 99.81% para felicidad, 88.99% para miedo, 87.5% para tristeza y 88.06% para neutralidad. Se concluye que la clasificación de emociones con señales EEG utilizando pocos electrodos, el modelo discreto y redes neuronales convolucionales (CNN), permite detectar el estado anímico de una persona con buena precisión y baja cantidad de operaciones computacionales.

CONTENIDO

LISTA DE FIGURAS.....	xii
LISTA DE TABLAS	xv
CAPÍTULO 1. INTRODUCCIÓN	16
CAPÍTULO 2. ANTECEDENTES.....	18
2.1 Computación afectiva.....	18
2.2 Sistemas BCI.....	18
2.3 Emociones	20
2.3.1 Teorías del concepto de emoción	20
2.3 La anatomía cerebral de la emoción.....	23
2.4 Modelos de las emociones.....	25
2.4.1 Modelo discreto	26
2.4.2 Modelo dimensional	26
2.5 Estado del arte del reconocimiento de emociones	27
CAPÍTULO 3. ANÁLISIS DE LOS MODELOS PRESENTES EN LA LITERATURA.....	30
3.1 Instrumento de evaluación de algoritmos.....	30
3.2 Conclusiones del instrumento de evaluación	33
3.2.1 Modelos con mejor ponderación	33
3.2.2 Modelos con peor ponderación.....	36
3.3 Conclusiones generales	37
CAPÍTULO 4. PROPUESTAS INICIALES	42
4.1 Definición conceptual de modelos	42
4.1.1 Preprocesamiento.....	42
4.1.2 Extracción de características	45

4.1.3 Clasificadores	47
4.2 Propuestas preliminares	50
4.2.1 Propuesta preliminar 1	50
4.2.2 Propuesta preliminar 2.....	52
4.2.3 Propuesta preliminar 3.....	54
4.2.4 Propuesta preliminar 4.....	55
4.3 Conclusiones obtenidas	56
CAPÍTULO 5. MODELO PROPUESTO.....	60
5.1 Bases de datos	60
5.1.1 SEED	60
5.1.2 DEAP.....	61
5.2 Modelo de emociones.....	62
5.3 <i>D-Inception</i>	62
5.3.1 Preprocesamiento.....	63
5.3.2 Extracción de características	66
5.3.3 Clasificador.....	72
CAPÍTULO 6. RESULTADOS.....	82
6.1 Obtención de métricas de evaluación.....	82
6.2 Comparación de modelos	84
6.3 Análisis final de activaciones.....	86
6.4 Análisis sobre el cambio de valores de kernel	92
6.5 Análisis de <i>D-Inception</i> por validación cruzada	95
CAPÍTULO 7. CONCLUSIONES Y TRABAJO FUTURO	99
REFERENCIAS.....	101

LISTA DE FIGURAS

Figura 2.1. Sistema Internacional. (a) 10-20, (b) 10-10.....	19
Figura 2.2. Teoría de emociones de James-Lange.....	21
Figura 2.3. Teoría de emociones de Cannon-Bard	21
Figura 2.4. Circuito emocional de Papez	22
Figura 2.5. Teoría de emociones propuesta por Schacter-Singer	22
Figura 2.6. Sistema límbico	23
Figura 2.7. Comunicación de sistemas para el proceso emocional.....	24
Figura 2.8. Distribución de las zonas cerebrales.....	24
Figura 2.9. Imagen representativa de la información procesada por cada hemisferio cerebral	25
Figura 2.10. Rueda de las emociones de Plutchik	26
Figura 2.11. Mapeo de emociones del modelo dimensional.....	27
Figura 3.1 Resultados del criterio de precisión y año de publicación del instrumento de evaluación	31
Figura 3.2 Resultados del criterio de forma de publicación y cuartil del instrumento de evaluación	32
Figura 3.3 Técnicas de preprocesamiento en modelos con mejor ponderación.	38
Figura 3.4 Técnicas de preprocesamiento en modelos con peor ponderación.....	39
Figura 3.5 Características extraídas en modelos con mejor ponderación.....	40
Figura 3.6 Características extraídas en modelos con peor ponderación.	40
Figura 3.7 Clasificadores utilizados en modelos con mejor ponderación.	41
Figura 3.8 Clasificadores implementados en modelos con peor ponderación.....	41
Figura 4.1 Esquema general de un decimador	44
Figura 4.2 Gráfica del comportamiento de la operación logaritmo base 2.....	47
Figura 4.3 Esquema de los modelos propuestos	50

Figura 4.4 Matrices de confusión de clasificador propuesto 1, (a) resultados con 5 bandas de frecuencia, (b) resultados con 3 bandas de frecuencia.....	51
Figura 4.5 Resultado del análisis normado o con correlaciones.....	52
Figura 4.6 Arquitectura de red neuronal diseñada.....	53
Figura 4.7 Matrices de confusión de clasificador propuesto 2, (a) entrenamiento, (b) validación, (c) prueba y (d) resultado general.....	54
Figura 4.8 Matrices de confusión de clasificador propuesto 3, (a) clasificador con 30 épocas de entrenamiento, (b) clasificador con 40 épocas de entrenamiento.....	55
Figura 4.4 Matrices de confusión de clasificador propuesto 4.....	56
Figura 5.1 Estructura de señales de base de datos SEED-IV.....	61
Figura 5.2 Esquema general del modelo propuesto D-Inception.....	63
Figura 5.3 Precisión de modelo durante entrenamiento por característica y banda independiente.....	67
Figura 5.4 Precisión de modelo durante validación por característica y banda independiente	68
Figura 5.5 Precisión de modelo durante validación con DEAP por característica y banda independiente.....	68
Figura 5.6 Descripción de estructura de muestra $j=j14$	69
Figura 5.7 Precisión de modelo durante entrenamiento por característica y combinación de bandas.....	70
Figura 5.8 Precisión de modelo durante validación por característica y combinación de bandas	70
Figura 5.9 Precisión de modelo durante validación con DEAP por característica y combinación de bandas.....	70
Figura 5.10 Precisión y función de activación implementada en clasificador de 4 emociones discretas.....	73
Figura 5.11 Precisión y función de activación implementada para emociones positivas y negativas.....	73

Figura 5.12 Precisión y función de activación implementada para emociones de neutralidad y felicidad.....	74
Figura 5.13 Precisión y función de activación implementada para emociones de tristeza y miedo	74
Figura 5.14 Comparación de valor del tamaño de mini-lote y precisión de cada clasificador	76
Figura 5.15 Propuesta de CNN D-Inception (parte 1)	78
Figura 5.16 Propuesta de CNN D-Inception (parte 2)	78
Figura 5.17 Método basado en D-Inception.	81
Figura 6.1 Primera línea de análisis, convolución 10x10 (a), primera función de activación (b) y primera normalización por lote (c)	87
Figura 6.2 Primera línea de análisis, convolución 2x2 (a), segunda función de activación (b) y segunda normalización por lote (c).....	88
Figura 6.3 Segunda línea de análisis, convolución 5x5 (a), primera función de activación (b) y primera normalización por lote (c)	89
Figura 6.4 Segunda línea de análisis, convolución 2x2 (a), segunda función de activación (b) y segunda normalización por lote (c).....	90
Figura 6.5 Tercera línea de análisis, convolución 3x3 (a), primera función de activación (b) y primera normalización por lote (c)	91
Figura 6.6 Función de activación final	92
Figura 6.7 Cambio de pesos en Conv1r, c1	93
Figura 6.8 Cambio de pesos en Conv1r, c2	93
Figura 6.9 Cambio de pesos en Conv1r, c3	93
Figura 6.10 Cambio de pesos en Conv2r3, c31.....	94
Figura 6.11 Cambio de pesos en Conv2r3, c32.....	94
Figura 6.12 Cambio de pesos en Conv2r3, c33.....	95

LISTA DE TABLAS

Tabla 2.1 Resumen de modelos utilizados para reconocimiento de emociones en la literatura. ..	28
Tabla 3.1 Tabla de criterios a evaluar y sus respectivas ponderaciones	31
Tabla 3.2 Evaluación de algoritmos en impacto y desempeño	32
Tabla 4.1 Comparación de precisión y tiempo de los modelos implementados	58
Tabla 5.1 Comparación de resultados de precisión con respecto al experimento con 62 electrodos	66
Tabla 5.2 Comparación de resultados al variar el optimizador implementado para entrenar la red	77
Tabla 6.1 Resultados obtenidos en entrenamiento.....	82
Tabla 6.2 Métricas de exactitud, sensibilidad y precisión	83
Tabla 6.3 Resultados de precisión y características de los resultados	83
Tabla 6.4 Comparación de modelos de clasificación de emociones discretas.....	84
Tabla 6.5 Comparación de modelos de clasificación de emociones semi-discretas.....	85
Tabla 6.6 Comparación de modelos de clasificación de emociones general	85
Tabla 6.7 Validación cruzada con $K=10$	96
Tabla 6.8 Validación cruzada con $K=5$	96
Tabla 6.9 Validación cruzada con $K=3$	97
Tabla 6.10 Validación cruzada con $K=20$	97
Tabla 6.11 Resumen de resultados de validación cruzada.....	98

CAPÍTULO 1. INTRODUCCIÓN

Las señales EEG contienen información fisiológica utilizada para el análisis, diagnóstico y comprensión de los procesos cognitivos en el ser humano. Un proceso que se ha podido analizar con éxito es el reconocimiento de emociones, que consiste en interpretar señales EEG para determinar el estado emocional de un sujeto mediante patrones presentes en la actividad cerebral. En este ámbito, se han desarrollado diferentes algoritmos computacionales con clasificadores supervisados y no supervisados que logran desempeños que varían de 50% a 92% de precisión [1]. En la literatura se reporta una amplia variedad de modelos para el reconocimiento de emociones, empleando diferentes técnicas de preprocesamiento, extracción de características y clasificadores, pero aquellos basados en redes neuronales presentan los mejores resultados de precisión durante la clasificación. En el reconocimiento de emociones existen dos formas de modelar el estado anímico de una persona con interfaces cerebro-computadora (BCI por sus siglas en inglés): el dimensional y el discreto. El dimensional es el más estudiado y existe una cantidad significativa de trabajos con excelentes desempeños, mientras que el discreto es poco explorado y los algoritmos reportados tienen desempeños por debajo del 80%. Por ello, en este trabajo de tesis se realizó un análisis del estado del arte sobre el reconocimiento de emociones con señales EEG que utiliza el modelo dimensional y discreto. A partir de este análisis, se propuso *Deeper Inception (D-Inception)*, un método basado en la red neuronal convolucional Inception que reconoce emociones con el modelo discreto. *D-Inception* tiene como contribuciones lo siguiente:

1. Logra el mejor desempeño en la literatura utilizando el modelo discreto con 2 bases de datos populares en la literatura.
2. *D-Inception* utiliza solo 14 electrodos para lograr buenos resultados, mientras que el resto de los métodos utilizan más de 60 electrodos para generar desempeños aceptables.

La estructura de este trabajo se conforma de 7 capítulos. En el capítulo II se presentan los antecedentes necesarios para comprender el desarrollo del modelo de clasificación de emociones. En el capítulo III se realiza un análisis de los modelos presentes en la literatura. En el capítulo IV se proponen 4 modelos experimentales de clasificación de emociones que se

INTRODUCCIÓN

utilizaron para el diseño de un nuevo método de reconocimiento de emociones con señales EEG. En el capítulo V se describe *D-Inception*, el método propuesto en esta tesis. En el capítulo VI se reportan los resultados de *D-Inception* y finalmente, en el capítulo VII se presentan las conclusiones de esta investigación y el trabajo a futuro.

CAPÍTULO 2. ANTECEDENTES

En este capítulo se presentan algunos conceptos básicos para entender el desarrollo del trabajo de esta tesis. Por ello, el capítulo se divide en secciones que presentan las ideas principales sobre computación afectiva, interfaces cerebro computadora, teoría de emociones y un análisis estadístico del estado del arte del reconocimiento de emociones con señales EEG.

2.1 Computación afectiva

La computación afectiva (AC) es una disciplina de la inteligencia artificial que desarrolla métodos computacionales orientados a reconocer emociones humanas y generar emociones sintéticas. Se encarga de dos problemáticas: el reconocimiento de emociones y la simulación/expresión de estados emocionales por parte de las computadoras [2]. Esta disciplina parte del entendimiento que las emociones juegan un importante papel en diferentes escenarios y compañías en campos de política, percepción de marcas, filtros de spam, inteligencia gubernamental, monitoreo de indicadores de hostilidad, apoyo psicológico, etc. [3].

2.2 Sistemas BCI

El desarrollo de tecnologías y sistemas de computación afectiva requieren interfaces que analicen señales cerebrales para comprender fenómenos naturales y procesos fisiológicos que interpreten el estado mental de un ser humano para determinar una respuesta a tal estado mental. Para ello, existen las BCI, que se definen a continuación.

Una BCI es un sistema de comunicación que permite a los humanos interactuar con su entorno mediante la actividad cerebral. El sistema crea un canal no muscular para que un usuario se comunique con dispositivos tales como computadoras, sintetizadores de voz, asistentes virtuales, etc. Existen varias técnicas para medir la actividad cerebral que parten de dos procesos fisiológicos: hemodinámico o electrofisiológico. Los procesos hemodinámicos miden la cantidad de sangre y calor que se genera en diferentes partes del cerebro y los electrofisiológicos miden la actividad electroquímica del sistema nervioso.

Partiendo de esto, existen técnicas invasivas y no invasivas para la obtención de actividad cerebral y la más utilizada es la electroencefalografía (EEG). EEG es una técnica no invasiva para medir la actividad cerebral a partir de electrodos posicionados en el cuero cabelludo. Estos electrodos miden la actividad cerebral causada por el flujo de corriente eléctrica durante la excitación sináptica de las dendritas en la neurona [4]. El orden de la amplitud de las señales EEG corresponde a los microvolts (μV), por lo que las EEG son propensas al ruido electrónico. La banda de frecuencia de las señales EEG con mayor utilidad va de 0.5Hz a 100Hz, ya que allí se encuentran los procesos motrices, estados cognitivos y emocionales [6].

Para la localización de electrodos, existe un estándar aprobado por la Federación Internacional de Neurofisiología Clínica y se implementa usando referencias craneales [7]. En este estándar, los electrodos mantienen una relación de espacios entre ellos de 10-20 (10% y 20%) o 10-10 (10% y 10%) con relación a las referencias craneales del nasión (es el punto de intersección del hueso frontal y de dos huesos nasales del cráneo humano) e inion (es la proyección más prominente del hueso occipital en la parte posterior e inferior del cráneo humano). Cada electrodo es identificado con una o varias letras según el área del cráneo donde se encuentre posicionado. La Figura 2.1 muestra el esquema de dicha distribución de electrodos, donde cada letra (o conjunto de letras) corresponden al área sobre la que se encuentra la posición del electrodo: A (lóbulo del oído), C (región central), P (región parietal), F (región frontal), O (occipital) y T (temporal).




Figura 2.1. Sistema Internacional. (a) 10-20, (b) 10-10.

Las BCI basadas en señales EEG han sido muy útiles y tienen aplicaciones en videojuegos, comunicación, rehabilitación motora, control de entorno (domótica), locomoción (transporte), Neuromarketing, educación, auto-regulación, seguridad y tratamiento de diferentes enfermedades [8]-[16].

2.3 Emociones

El concepto de emoción es complejo de definir debido a diferentes factores físicos, psicológicos y neurológicos que se manifiestan al presentarse un estado anímico [17]. De acuerdo con [18], existen 5 sistemas del cuerpo humano que se activan en respuesta a la evaluación de estímulos externos/internos. Dichos sistemas activan una serie de procesos en el sistema nervioso central y autónomo para generar las emociones. Estos procesos se pueden analizar desde el cerebro mediante lecturas con señales EEG para reconocer emociones [19].

Una emoción es un conjunto de reacciones orgánicas que experimenta un individuo cuando responde a ciertos estímulos externos que le permiten adaptarse a una situación con respecto a una persona, objeto, lugar, entre otros, y se caracteriza por ser una alteración del ánimo de corta duración pero de mayor intensidad que un sentimiento. Se puede definir una emoción desde la perspectiva fisiológica, expresiva y consciente (psicológica), las cuales se describen a continuación.

2.3.1 Teorías del concepto de emoción

Para conformar el concepto de emoción considerado en este trabajo de tesis, es necesario conocer las principales teorías que sustentan su definición.

La primera teoría, propuesta por William James y Carl Lange, estipula que el sistema nervioso autónomo crea respuestas fisiológicas que posteriormente estimulan las emociones. Esta idea se representa en la Figura 2.2, donde según James-Lange, la emoción nace de la interpretación de la reacción fisiológica que inicia en el tálamo y termina en la corteza cerebral [20].




Figura 2.2. Teoría de emociones de James-Lange

Por otro lado, Walter Cannon y Philip Bard, propusieron entre 1927 y 1938 que los estímulos anímicos generan la emoción en el cerebro y la reacción fisiológica al mismo tiempo (a través del sistema nervioso) [21]. La Figura 2.3 muestra el concepto de la teoría propuesta por Cannon y Bard.

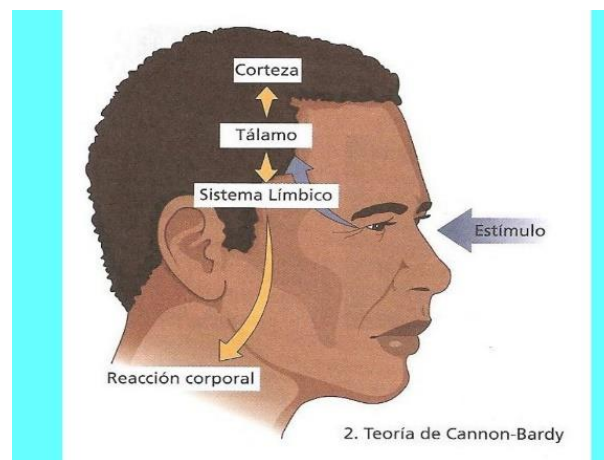


Figura 2.3. Teoría de emociones de Cannon-Bard

En 1937, James Papez estableció que el sistema límbico es un sistema de control de las emociones [22], donde la corteza cingulada integra las señales provenientes de la corteza sensorial e hipotálamo, mismas que avanzan hacia el hipocampo, donde se controlan las respuestas emocionales, tal como se muestra en la Figura 2.4.

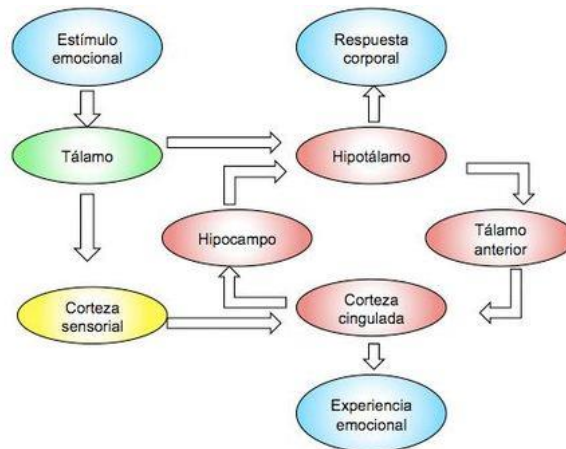


Figura 2.4. Circuito emocional de Papez

La teoría de Schacter-Singer (1962) establece que son necesarios dos factores para constatar la existencia de una emoción: un estímulo y una evaluación cognitiva del estímulo. En esta teoría, la activación física se detecta por medio de una retroalimentación, luego de la cual, se intenta examinar las circunstancias [21]. La Figura 2.5 muestra la teoría propuesta por Schacter-Singer.




Figura 2.5. Teoría de emociones propuesta por Schacter-Singer

Entre 1980 y 1984, Zajonc, expone que las emociones pueden ser más rápidas que la interpretación de una situación, lo que implica que el ser humano siente algunas emociones antes de pensarlas y que algunas vías nerviosas implicadas en la emoción no pasan por las áreas corticales vinculadas al pensamiento.

Basado en estas definiciones, se puede entender que la emoción es la respuesta de todo organismo que implique una excitación fisiológica, conductas expresivas y una experiencia consciente.

Con esta definición se consideran las tres teorías principales sobre el concepto de emoción, ya que se describe el componente fisiológico, el cognitivo (experiencia subjetiva) y el expresivo [23].

2.3 La anatomía cerebral de la emoción

Diferentes estudios han establecido que existen zonas específicas del cerebro involucradas en el proceso neurofisiológico de la emoción [24]. Primeramente, se encuentra el sistema límbico que regula la actividad emocional, participa activamente en los procesos de almacenamiento y archivo de información y coordina las respuestas autónomas y endócrinas con los estados emocionales. Este sistema se compone de múltiples estructuras subcorticales interconectadas hacia el hipotálamo como se ve en la Figura 2.6. Estas estructuras subcorticales se conectan a los lóbulos frontal, temporal y al núcleo del sistema cerebral autónomo, interactuando en el proceso emocional como se observa en la Figura 2.7 [25].




Figura 2.6. Sistema límbico

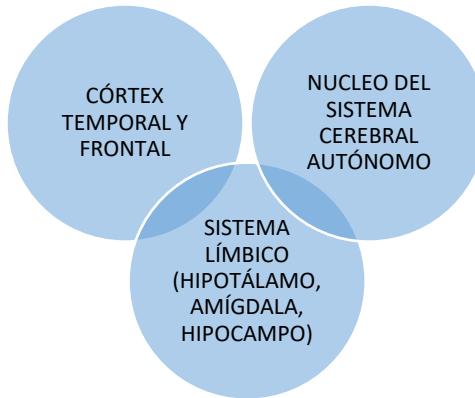


Figura 2.7. Comunicación de sistemas para el proceso emocional

Considerando el sistema límbico y la comunicación de sistemas para el proceso emocional, se encuentra que la corteza prefrontal, que ocupa la zona anterior del lóbulo frontal, constituye la base de los procesos de pensamiento más específicos, como las funciones motoras, cognitivas y comportamentales. La corteza occipito-parieto-temporal, combina e integra información sensorial visual, táctil y auditiva. La corteza límbica se sitúa entre ambos hemisferios y guarda una relación directa con los procesos emocionales y motivacionales. Las zonas cerebrales se distribuyen como se muestra en la Figura 2.8.




Figura 2.8. Distribución de las zonas cerebrales

Adicional al concepto de las estructuras corticales y las emociones, está el concepto de las asimetrías, como se muestra en la Figura 2.9. Este concepto se desarrolló a partir de estudiar el grado de activación metabólica y neurofisiológica en el procesamiento de determinadas

emociones. Las asimetrías se basan en que cada hemisferio se especializa en procesar determinada información, separando la información en distintas clases. Por ejemplo, el hemisferio izquierdo se especializa en el procesamiento de emociones positivas, mientras que el hemisferio derecho se especializa en el procesamiento de emociones negativas.




Figura 2.9. Imagen representativa de la información procesada por cada hemisferio cerebral

2.4 Modelos de las emociones

Existen modelos que representan una emoción de forma cuantitativa considerando los componentes fisiológicos, expresivos y psicológicos. Estos modelos son muy útiles para describir las diferencias entre emociones y utilizan la siguiente información:

1. La medición de cambios del sistema nervioso.
2. Los patrones de respuesta del sistema neuro-endócrino.
3. Los cambios motivacionales producidos por las tendencias de actividad.
4. Los patrones de expresión vocal y facial.
5. Los movimientos corporales.
6. La naturaleza de la experiencia subjetiva que se refleja en el cambio de los componentes.

Con base en esto, los psicólogos utilizan dos métodos para obtener evaluaciones de respuesta forzada del episodio emocional: el enfoque de emociones discretas y el dimensional. [26], los cuales se describen a continuación.

2.4.1 Modelo discreto

El modelo discreto se fundamenta en el concepto de emociones básicas, que propone un conjunto limitado de emociones (por ejemplo, alegría, tristeza, ira, miedo, disgusto, etc.) que son universales, biológicamente heredadas y que poseen un único y fisiológico perfil neuronal que las distinguen unas de otras [27]. Esto significa que cada emoción existe como una entidad de propiedades y características específicas. No existe un estándar sobre la cantidad de emociones básicas existentes. Por ejemplo, Ekman definió 6 [28], Carlos Crivelli de la Universidad de Madrid definió únicamente 3 [29], mientras que Robert Plutchik creó la Rueda de las Emociones (mostrada en la Figura 2.10) donde define 8 emociones básicas.




Figura 2.10. Rueda de las emociones de Plutchik

2.4.2 Modelo dimensional

Wilhelm Wundt fue pionero en describir el modelo dimensional [30], donde el sentimiento subjetivo podía ser descrito por su posición en un espacio tridimensional formado por la dimensión de valencia (*valence*), activación (*arousal*) y tensión (*tense*) [31]. En este modelo se describe qué tan positiva o negativa, y qué tan fuerte era la emoción que se presentaba, mapeando el resultado como en la Figura 2.11.




Figura 2.11. Mapeo de emociones del modelo dimensional

Las dimensiones se evalúan de la siguiente manera:

- La valencia o placer, describe qué tan negativa o positiva es una emoción específica.
- La activación o intensidad, describe la excitación interna de un individuo y va desde estar muy tranquila hasta estar muy activa.
- La energía o dominación describe el grado de control del individuo sobre la situación, o en otras palabras, qué tan fuerte o débil se muestra el individuo.

Este modelo es el más utilizado en la literatura, aunque en algunos casos se descarta la tensión para trabajar únicamente con un mapeo bidimensional.

2.5 Estado del arte del reconocimiento de emociones

Al inicio de esta tesis, se realizó un análisis del estado del arte de los métodos que se utilizan para reconocimiento de emociones basados en señales EEG. En la Tabla 2.1 se muestra un resumen de dicho análisis.

En lo referente al análisis de características, se puede ver que el 56.25% utiliza características espectrales, de energía o potencia; el 37.5%, usa información de la entropía de la señal; el 25%, extrae información sobre la asimetría de hemisferios y aproximadamente el 50%, usa alguna otra característica de tipo estadística o fractal. En cuanto a los clasificadores, el 62.5% de los métodos consultados implementa SVM; el 43.75%, usa K-ésimo vecino más cercano (*K-nearest neighbor* o KNN); el 37.5%, implementa algún clasificador basado en redes

neuronales y aproximadamente 31.5%, implementa clasificadores basados en otras técnicas, como discriminantes lineales, bayesianos o estadísticos. Además, se puede ver que más del 55% de los trabajos utilizan el modelo dimensional para describir las emociones, mientras que el modelo discreto conserva un 45% de uso. Dentro del modelo discreto, el 50% de los modelos clasifica 4 emociones discretas, mientras el resto implementa 1, 3 o 6 emociones discretas.

En conclusión, se observa que el uso de redes neuronales para reconocimiento de emociones es poco explorado a pesar de que sus resultados son mayores del 80% de precisión, el modelo discreto tiene menor frecuencia de uso en estos sistemas y la característica espectral tiene un amplio uso con resultados más altos de precisión.

Tabla 2.1 Resumen de modelos utilizados para reconocimiento de emociones en la literatura.

Referencia	Características	Clasificador(es)	Modelo
[32]	Entropía diferencial (DE), densidad espectral de potencia (PDS), asimetrías (ASM).	Red neuronal convolucional gráfica dinámica (DGCNN)	Discreto
[33]	Asimetrías (ASM), densidad espectral de potencia (PDS).	Máquina de vectores de soporte (SVM)/ perceptrón multi-capas (MLP)	Discreto
[34]	Coefficientes de correlación y matriz de sincronización de probabilidad.	Bayesiano	Dimensional
[35]	Entropía, energía.	Máquina de vectores de soporte (SVM)/ K-ésimo vecino más cercano (KNN)	Dimensional
[36]	Características basadas en métodos de correlación.	GDA/ K-ésimo vecino más cercano (KNN)/ máquina de vectores de soporte (SVM)	Discreto
[37]	Características estadísticas y en el dominio de la frecuencia.	K-ésimo vecino más cercano (KNN)/ máquina de vectores de soporte (SVM)	Dimensional
[38]	Características en tiempo-frecuencia.	máquina de vectores de soporte (SVM).	Dimensional
[39]	Densidad espectral de potencia (PDS), patrón espacial común.	Análisis de discriminante lineal (LDA)	Dimensional
[40]	Dimensión Fractal.	Máquina de vectores de soporte (SVM) (RBF, polinomial y lineal)	Discreto
[41]	EMD, entropía aproximada (EA).	Máquina de vectores de soporte (SVM).	Discreto
[42]	HOS	Análisis de discriminante lineal (LDA)	Dimensional
[43]	Características en frecuencia.	K-ésimo vecino más cercano (KNN)/Red neuronal artificial (ANN)	Dimensional
[44]	Densidad espectral de potencia (PDS), entropía diferencial (DE), asimetrías (ASM) y caudalidad diferencial.	Máquina de vectores de soporte (SVM)/ K-ésimo vecino más cercano (KNN)/regresión lineal/ máquina de grafos regularizada en extremo (GELM).	Dimensional
[45]	Densidad espectral de potencia (PDS).	K-ésimo vecino más cercano (KNN)/ mapa auto-organizado (SOM).	Discreto
[46]	Entropía diferencial (DE).	Red neuronal convolucional jerárquica (HCNN) / máquina de vectores de soporte	Dimensional

ANTECEDENTES

		(SVM)/ K-ésimo vecino más cercano (KNN)/codificador automático apilado (SAE)	
[47]	Asimetrías (ASM), caudalidad diferencial, entropía diferencial (DE), densidad espectral de potencia (PDS).	Máquina de vectores de soporte (SVM)/ máquina de grafos regularizada en extremo (GELM).	Discreto

CAPÍTULO 3. ANÁLISIS DE LOS MODELOS PRESENTES EN LA LITERATURA

Existe una amplia variedad de algoritmos para reconocimiento de emociones con EEG que pueden ser analizados bajo el esquema de preprocesamiento, extracción de características y clasificación. Sin embargo, no existen revisiones de literatura que indiquen la evolución de estos algoritmos y cuáles son los más exitosos. Por ello, en este capítulo se realiza un análisis estadístico de métodos para reconocimiento de emociones con señales EEG reportados en la literatura. Para ello, se diseñó un instrumento de evaluación que examina la disponibilidad de código, precisión obtenida, año de publicación, forma de publicación y el cuartil de la revista. Con base en los resultados obtenidos de esta evaluación, la sección 3.1 describe el instrumento de evaluación. La sección 3.2 describe los resultados obtenidos de este instrumento. La sección 3.2.1 describe los modelos con mejor desempeño. La sección 3.2.2 describe los modelos con peor desempeño y la sección 3.3 muestra las conclusiones obtenidas.

3.1 Instrumento de evaluación de algoritmos

Se realizó un estudio de los algoritmos de reconocimiento de emociones presentes en la literatura, encontrando 32 artículos de interés para este trabajo, de los cuales, el 84% son publicaciones en revista y el resto memorias en extenso. Con el fin de cuantificar la relevancia de los algoritmos de reconocimiento de emociones encontrados, se diseñó un instrumento que considera criterios basados en el impacto en la literatura del método publicado. La Tabla 3.1 muestra el criterio a evaluar y la ponderación correspondiente a cada caso, donde cada criterio se evaluó de la siguiente manera:

- Cantidad de citas del artículo publicado. Se definió en un rango de 0 a 100 para evaluar la cantidad de citas que posee cada modelo, siendo 0 una cantidad menor a 50 citas (lo que indica poco impacto) y 100 una cantidad mayor a 200 citas (lo que indica un mayor impacto).
- Año y forma de publicación. Se consideró una escala de 0 a 100 para clasificar los modelos según el año de publicación, siendo 0 una fecha anterior al año 2010, y 100 una fecha más reciente del 2015. Asimismo, se consideró la forma de publicación, siendo un valor de 25 para trabajos de grado y 100 para revistas.

- Cuartil. Para este criterio, se consideró 20 puntos para un cuartil 4 o un cuartil no asignado, y 100 para un cuartil 1.
- Precisión. Se evaluó considerando la precisión de clasificación del modelo, donde 0 implica un resultado menor del 50%: un valor de 33, si se encuentra entre 50% y 60%; un valor de 66 si se encuentra entre 61% y 78%, y un valor de 100, si el resultado es mayor a 81%.

Tabla 3.1 Tabla de criterios a evaluar y sus respectivas ponderaciones

Criterio	Cantidad de citas (C)	Precisión (P)	Año de publicación (A)	Forma de publicación	Cuartil
Ponderación	0 si C<50	0 si P<50%	0 si A<2010	25 si es trabajo de grado	25 si Q4 o ninguno
	25 si 49<C<101	33 si 50%≤P<60%	50 si 2010<A<2015	50 si es memoria en extenso	50 si Q3
	50 si 100<C<151	66 si 60%≤P<80%	100 si 2015<A	75 si es libro o capítulo en libro	75 si Q2
	75 si 150<C<201	100 si 80%≤P		100 si es revista	100 si Q1
	100 si 200<C				

La Figura 3.1 muestra que más del 50% de los artículos consultados poseen un valor de precisión del 80%, lo cual indica un resultado competitivo con los modelos presentes en la literatura. Se observa también que más del 55% son publicaciones recientes, únicamente 4 de ellas son anteriores al 2010, esto con fines de comparación y análisis de los métodos y resultados.




Figura 3.1 Resultados del criterio de precisión y año de publicación del instrumento de evaluación

En la Figura 3.2 se observa que predomina por mucho la publicación en revistas. Solo se tienen 5 memorias en extenso consultadas y no existen libros sobre el tema. También se puede encontrar que hay una variedad de cuartiles según la publicación seleccionada, predominando el cuartil 1 en revistas de mayor impacto. Luego, sigue el cuartil 4 que se presentó en 10 de los casos consultados.

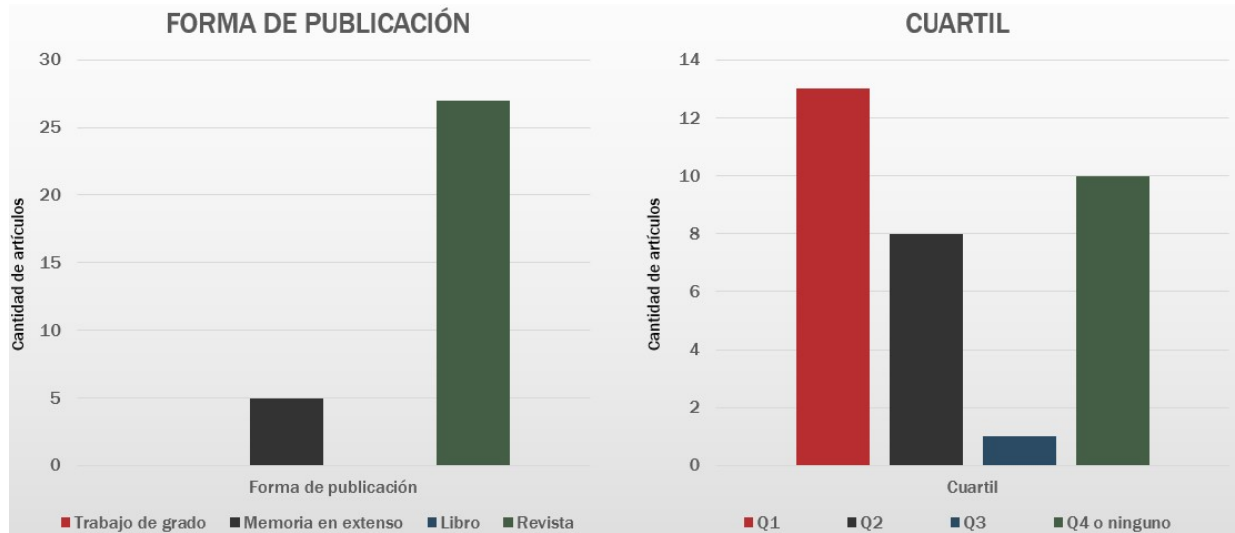


Figura 3.2 Resultados del criterio de forma de publicación y cuartil del instrumento de evaluación

Dado que se desea analizar el resultado desde dos perspectivas: desempeño e impacto, la Tabla 3.2 muestra el resultado de la evaluación de cada método utilizando el instrumento diseñado. La columna de color azul representa la clasificación del desempeño del modelo y la columna de color verde representa el impacto de dicho modelo.

Tabla 3.2 Evaluación de algoritmos en impacto y desempeño

Método	Impacto	Desempeño	Método	Impacto	Desempeño
[32]	7.142	10.0	[40]	3.571	10.0
[33]	9.285	10.0	[41]	6.428	10.0
[34]	5.00	6.66	[42]	6.428	10.0
[47]	7.142	6.66	[44]	6.428	10.0
[48]	4.282	6.66	[53]	5.714	10.0
[45]	2.857	10.0	[54]	5.714	10.0
[49]	5.714	3.33	[55]	3.571	10.0
[35]	7.142	10.0	[43]	6.428	6.666
[46]	7.142	10.0	[56]	5.0	10.0
[50]	9.285	10.0	[24]	5.714	6.666
[36]	7.142	6.666	[57]	6.428	6.666

[37]	6.428	3.333	[58]	7.857	10.0
[38]	7.142	10.0	[59]	7.857	3.333
[39]	7.142	10.0	[60]	8.571	0.0
[51]	2.857	6.666	[61]	9.285	6.666
[52]	5.0	6.666	[62]	8.571	10.0

3.2 Conclusiones del instrumento de evaluación

En esta sección se presentan los resultados obtenidos de la implementación del instrumento de evaluación. Para entender estos resultados, se explicarán los 15 métodos con mejores resultados y los 10 con peor resultado. El objetivo de analizar estos métodos es conocer la tendencia de las metodologías con mejores y peores resultados en el reconocimiento de emociones.

3.2.1 Modelos con mejor ponderación

En el análisis de literatura realizado, se reportaron artículos donde se presentan algoritmos para el reconocimiento de emociones con EEG, que lograron una precisión por encima del 81% y fecha de publicación no anterior al 2016. Estos artículos se presentan en esta subsección con un pequeño resumen de su metodología.

En [32] se diseñó una DGCNN para reconocer emociones a partir de la PDS, DE, asimetría diferencial (DASM), asimetría racional (RASM) y caudalidad diferencial. Utilizan diferente cantidad de canales por emoción y se procesa la información en 5 bandas diferentes de frecuencia: delta, tetha, alfa, beta y gamma.

Y- Lin *et al* diseñaron en [33], un modelo de clasificación de emociones evocadas por estímulos auditivos. Para ello, filtran las señales para eliminar artefactos, se implementa la Transformada Corta de Fourier (STFT) con una ventana tipo Hamming de un segundo y se utilizan 5 bandas de frecuencia (delta, tetha, alfa, beta y gamma), extrayendo PDS y ASM. Finalmente, se clasifica con SVM y MLP.

P. Li *et al*, diseñaron en [47] un algoritmo de clasificación de emociones a partir de la DE y PDS de las señales EEG. Se eliminan artefactos por medio de filtros y con submuestreo de las señales a 256Hz, luego se analizan las señales en 4 bandas de frecuencia (tetha, alfa, beta y gamma) y finalmente se clasifican con SVM y GELM.

En [35] se diseñó un clasificador de emociones en términos de excitación y valencia. Se utilizaron 10 electrodos y se analizaron las señales en 5 bandas de frecuencia (delta, tetha, alfa, beta y gamma) con la transformada Wavelet Daubechies 4 (db4). Después se extraen características con energía y entropía, y finalmente la clasificación se realiza con SVM y un KNN con $2 \leq k \leq 5$.

En [46], J. Li *et al* diseñaron una HCNN de 3 capas para clasificar emociones en tres clases: positivas, negativas y neutrales. Se utilizaron 62 electrodos y como procesamiento, se utilizaron filtros para eliminar artefactos visuales y se aplicó la STFT con ventanas de un segundo para extraer la DE organizada en mapas bidimensionales.

X. Wang *et al*, diseñaron en [50], un clasificador de emociones basado en la densidad espectral de energía (EDS por sus siglas en inglés), PDS, dimensión fractal, EA y exponente Hurst. Se suavizan las señales para remoción de ruido con submuestreo de la señal a 200Hz, luego se eliminaron artefactos usando las bandas delta, tetha, alfa, beta y gamma. Después se aplicó la STFT y transformaciones Wavelet, luego se redujo la dimensión de las señales con LDA y análisis de componente principal (PCA), finalmente la clasificación se realizó con SVM con kernels lineales, múltiples y de base radial.

En [62] se propone un método para reconocer el estrés en los trabajadores de sitios de construcción a través de señales EEG. Se extrajeron características estadísticas y otras de frecuencia. Se filtraron las señales para eliminación de artefactos, se redujo la dimensión de los datos con PCA, se aplicaron ventanas a las señales y se implementó como clasificadores el análisis de discriminante gaussiano, SVM (con kernel lineal, cuadrático, cúbico y gaussiano) y KNN.

D. Lacoviello *et al*, diseñaron en [38] un clasificador de emociones auto-inducidas, en tiempo real. Se implementa la transformada Wavelet discreta para extraer características estadísticas en el dominio del tiempo-frecuencia y se utiliza como clasificador SVM con distintos kernels.

L. Nicolas-Alonso *et al* proponen en [4] un sistema de clasificación de emociones positivas, negativas y neutrales en tiempo real. Se utilizan señales EEG de las bandas de frecuencia tetha, alfa, beta y gamma para extraer características de PDS, patrones espaciales comunes (CSP) y la potencia total de la señal. La clasificación se realizó con un LDA.

En [39] se diseña un método de clasificación de emociones basado en las funciones intrínsecas de EA de los primeros 4 eigenvalores, normalizando la longitud de las señales para implementar PCA, y EDS, y finalmente analizar la información en 4 bandas de frecuencia y se clasificó con una red Belief profunda y SVM.

D. D. Chackladar *et al* diseña en [42] un clasificador de emociones basado en EEG con LDA, utilizando como características los valores estadísticos de orden superior, la media, desviación estándar, valores máximos, oblicuidad y curtuosis. Se clasifican emociones positivas, negativas, enojo y armonía, aplicando filtros adaptivos para eliminar artefactos, reduciendo dimensiones y analizando las señales en 5 bandas de frecuencia (delta, beta, alfa, tetha y gamma).

W- Zheng *et al* analizan en [44] los patrones en señales EEG para la clasificación de emociones, filtrando las señales en las bandas delta, beta, alfa, tetha y gamma y aplicando la STFT con ventaneo de 1 segundo y ventana Hanning, utilizando como características la PD, DE, DASM, RASM, ASM y caudalidad diferencial. Luego se implementó PCA y mínima redundancia máxima relevancia para finalmente clasificar con SVM con kernel lineal, KNN con k=5 y GELM.

A. Mert *et al* proponen en [43] un modelo de reconocimiento de emociones basado en EEG utilizando un análisis en tiempo-frecuencia y la transformación multivariada sincronizada para la extracción de características. Se filtran las señales para eliminar artefactos y se aplica el análisis de componentes independientes (ICA). Se implementaron los clasificadores con base en SVM (con kernel lineal y de base radial), KNN y ANN.

En [58] se diseñó un modelo para reconocer felicidad, tristeza, amor e ira. Para ello, se realizó el submuestreo de las señales y se filtraron para eliminar artefactos. Como características se extrajeron la relación de latencia de amplitud, propiedades de los valores de pico a pico, la potencia de la señal, la media del valor de la señal, la curtosis y la movilidad, la PDS y la banda de potencia, entropía y la energía. Como clasificador se implementó un MLP, una SVM y KNN.

J. Atkinson *et al* propone en [60] un modelo para reconocimiento de emociones con base en EEG. El modelo aplica PCA, filtrando las señales para eliminar artefactos y analizando la información en las bandas de frecuencia tetha, baja alfa, alfa, beta y gamma. También se extrajeron PDS, parámetros de Hjort, dimensión fractal y se aplicó la técnica de mínima redundancia máxima

relevancia para eliminar redundancias de información. La clasificación se realizó con una SVM multiclase.

3.2.2 Modelos con peor ponderación

A continuación se presentarán 10 artículos con modelos para reconocimiento de emociones con EGG y cuyos resultados de precisión no superan el 61% o fueron publicados antes del año 2016.

R. Jeneke *et al* diseñaron en [61] un método de clasificación de emociones considerando modelos de la literatura. Para ello, se filtraron las señales para eliminación de artefactos. Se utilizaron los potenciales relacionados a eventos (P100, N100, P200 y P300), PDS, valores estadísticos, DASM, RASM, parámetros de Hjorth y dimensión fractal para caracterizar las señales. Luego se realizó un análisis con la transformada Wavelet y el espectro Hilbert-Huang. Se implementó como clasificador un discriminante cuadrático con covarianza diagonal, Naive Bayes.

B. Kaur *et al*, clasifica en [40] tres emociones principales: calma, ira y felicidad. Se utiliza la dimensión fractal de emociones en señales crudas y se clasifica utilizando SVM con kernel lineal, polinomial y de base radial. En este modelo no se realizó ningún preprocesamiento.

K. Ko *et al* diseña en [49], un sistema de reconocimiento de emociones basado en señales EEG comparando los resultados obtenidos con los valores estándar de una red bayesiana. Se filtraron las señales para eliminar artefactos, implementando la Transformada Rápida de Fourier (FFT) y analizando la información en las bandas delta, tetha, alfa, beta y gamma. También se extrajo PDS. La red bayesiana se utiliza como clasificador.

M. M. Raja *et al* diseñan en [37] un método de extracción de características para reconocimiento de emociones basado en señales EEG, considerando el modelo dimensional. Se eliminaron artefactos por medio de filtros selectivos de frecuencia para luego utilizar la transformada FFT. Luego se analizaron las señales en las bandas delta, tetha, alfa, beta y gamma, seguido de implementar ICA para reducción de dimensiones. Finalmente se utilizaron 6 valores estadísticos y la potencia de la señal como características. La información se representó con base logarítmica, y se implementó un clasificador KNN con $k=5$ y una SVM.

Q. Zhang *et al* diseñaron en [52] un sistema para el reconocimiento de emociones basado en la actividad cerebral y GIST (obteniendo características de contorno, color, contraste, etc) para clasificar emociones positivas y negativas. Se utilizó PCA para reducir las dimensiones del vector

de datos conservando los primeros 100 componentes principales de las señales. Se utilizó ASM de los canales F3 y F4, y cada una de las señales de cada electrodo como características. Se implementó una SVM, utilizando un kernel línea y un kernel de base radial.

En [53] se diseñó un sistema para reconocimiento de emociones. Se procesaron las señales aplicando filtros selectivos de frecuencia para eliminar artefactos. Se analizó la información en dos bandas de frecuencia (alfa y beta). Se aplicó PCA para reducir la cantidad de características. Se implementaron clasificadores lineales binarios del análisis del discriminante de Fisher, uno para cada combinación de características entre las dos bandas de potencia extraídas: alfa y beta.

M. Murugappan *et al* diseñaron en [56] un modelo para reconocimiento de emociones con base en señales EEG obtenidas de 63 canales, clasificando 5 emociones (disgusto, felicidad, sorpresa, tristeza y enojo). Se filtraron las señales para eliminar artefactos y luego normalizarlas para implementar la transformada Wavelet con db4. Finalmente clasificando con MLP con dos capas de entrada y gradiente descendiente con momento como optimizador.

L. Brown *et al* proponen en [55] un modelo para reconocimiento de emociones con base en el comportamiento del estado de valencia de sujetos en actividades de la vida real. Primeramente, se filtraron las señales EEG obtenidas para eliminar artefactos luego se extrajo la PDS de las señales con ventanas deslizantes y el pico de frecuencia de mayor magnitud, y utilizando la banda de frecuencia alfa, se implementó un clasificador discriminante cuadrático, una SVM y KNN.

R. Khosrowabadi *et al* diseñó en [45] un sistema de reconocimiento de emociones basando en EEG y utilizando SOM como clasificador. Se normalizaron y filtraron las señales para eliminar artefactos, y extrayendo la magnitud estimada de coherencia cuadrada como característica se clasificó para comparar los resultados con KNN.

3.3 Conclusiones generales

La Figura 3.3 muestra las técnicas de preprocesamiento utilizadas en los algoritmos con mejor ponderación. El 90% filtra las señales por selección de frecuencia y analiza el resultado en las bandas de frecuencia delta, theta, alfa y gamma y el 40% hace un submuestreo de la señal. La Figura 3.4 muestra las técnicas de preprocesamiento implementadas en los algoritmos con peor ponderación. El 70% usan el filtrado LTI por selección de frecuencia, 20% elimina artefactos y 10% no preprocesa las señales. Además, un 40% de los modelos con peor ponderación filtra las

señales para analizar en 5 bandas de frecuencia, el 40% utiliza técnicas de reducción de dimensión (PCA o ICA) y el 60% realiza una normalización entre [0,1] de las señales.

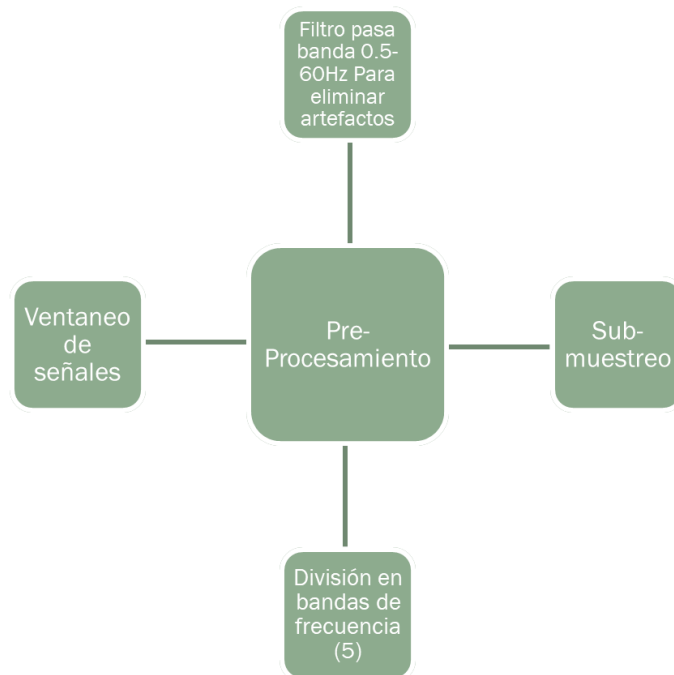


Figura 3.3 Técnicas de preprocesamiento en modelos con mejor ponderación.



Figura 3.4 Técnicas de preprocesamiento en modelos con peor ponderación.

Entre los métodos de extracción de características que están en algoritmos con mejor ponderación, se tiene que el 50% extraer al menos una de las siguientes características: PDS, entropía (DE especialmente), ASM (diferencial, racional, en frecuencia o en tiempo) y características estadísticas (mediana, moda, etc.) La Figura 3.5 muestra las características utilizadas en dichos modelos. En los modelos con peor ponderación se encuentra que el 50% extraen PDS y/o entropía, el 30% utiliza características estadísticas variadas, y el 20% extraen características en tiempo-frecuencia. La Figura 3.6 muestra las características extraídas en los modelos con peor ponderación.

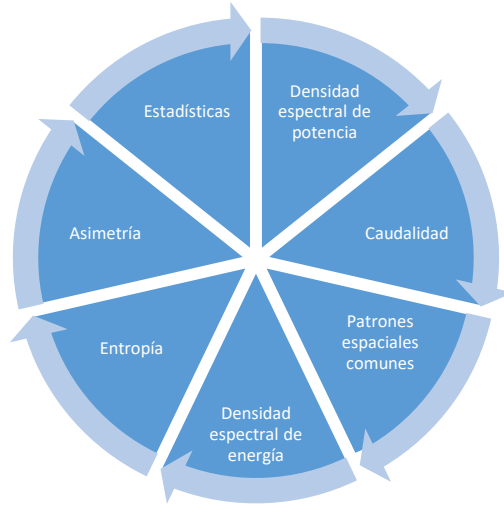


Figura 3.5 Características extraídas en modelos con mejor ponderación.

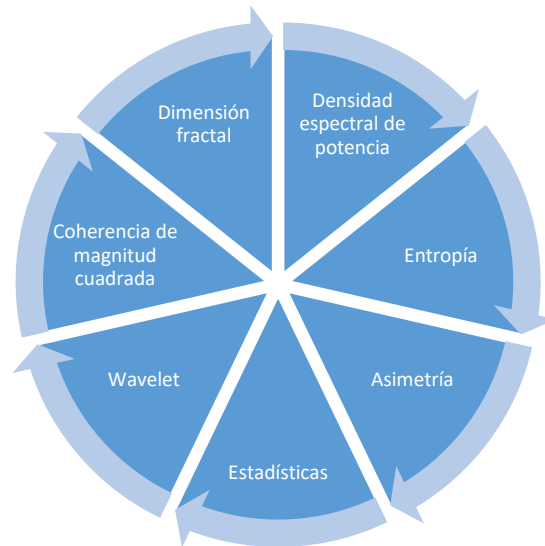


Figura 3.6 Características extraídas en modelos con peor ponderación.

Con respecto a los clasificadores, en los modelos con mejor ponderación consultados se destaca el uso de SVM con un 70%, combinado con clasificadores de tipo KNN. Las ANN son utilizadas con menor frecuencia, alrededor del 30%. La Figura 3.7 muestra las técnicas de clasificación utilizadas en los modelos con mejor ponderación. En los modelos con peor ponderación se tiene que el 50% implementa SVM, 20% usa redes bayesianas, y el 10% utiliza el análisis discriminante de Fisher, cuadrático o mapas auto-organizados. La Figura 3.8 muestra los clasificadores utilizados en los modelos con menor ponderación.



Figura 3.7 Clasificadores utilizados en modelos con mejor ponderación.



Figura 3.8 Clasificadores implementados en modelos con peor ponderación.

Con base en el análisis realizado, se concluye que las técnicas de preprocesamiento con mejor resultado son el filtrado por selección de frecuencia para eliminar artefactos y dividir en bandas de frecuencia. Las características con mejor resultado son las extraídas en frecuencia, sea PDS, ASM, energía y/o valores estadísticos. Con respecto a los clasificadores, presentan mejor resultados aquellos basados en SVM, ANN y KNN, aún y cuando ANN sea poco utilizado, sus resultados muestran potencial de aplicación.

CAPÍTULO 4. PROPUESTAS INICIALES

En este capítulo se describen los métodos que presentaron mayor contribución al buen desempeño de los algoritmos evaluados, considerando las técnicas de preprocesamiento, las características extraídas y los clasificadores utilizados. Se compone de 4 secciones: en la primera de ellas, se definirán conceptualmente las propiedades a utilizar obtenidas del análisis del capítulo anterior; en la segunda sección, se presentarán los modelos como propuestas preliminares; en la tercera sección, se muestran los resultados obtenidos de la implementación de dichos modelos. Finalmente, en la cuarta sección, se presentan las conclusiones obtenidas de su implementación.

4.1 Definición conceptual de modelos

En esta sección se describen los modelos de los métodos con mayor precisión presentes en la literatura, subdivididos en técnicas de preprocesamiento, características extraídas y clasificadores.

4.1.1 Preprocesamiento

La representación y calidad de los datos es uno de los factores que afectan directamente los algoritmos supervisados para obtener el desempeño deseado; por ejemplo, si existe mucha y redundante información o si está contaminada con ruido e información no confiable, el reconocimiento de patrones en las muestras de datos ingresadas al algoritmo será más difícil, y por lo tanto, más tardado. El propósito de esta etapa es identificar y eliminar tanta información irrelevante y redundante como sea posible. Se puede englobar el preprocesamiento en cuatro diferentes áreas según [63]: integración, limpieza de datos, transformación y reducción. En el área del preprocesamiento de datos no se tiene una metodología concreta para todos los problemas, pues cada problema puede requerir la implementación de alguna técnica específica o, en su defecto, la combinación de diferentes técnicas para preparar la información.

4.1.1.1 Filtrado para eliminación de artefactos

Los artefactos son potenciales eléctricos indeseables que provienen de fuentes distintas al cerebro [64]. Para su eliminación se utilizan filtros selectivos de frecuencia pasabajas con frecuencias de corte de 50Hz. Con estos filtros se puede obtener la actividad cerebral relacionada al reconocimiento de emociones.

4.1.1.2 División en bandas de frecuencia

Para el análisis de las señales EEG es de gran utilidad filtrar las señales en una serie de frecuencias asociadas a determinadas actividades cerebrales, las cuales son [4]:

- Delta: frecuencias menores de 4Hz. Presentes en estado de sueño y otras enfermedades relacionadas con el insomnio.
- Tetha: frecuencias entre 4Hz y 7.5Hz. Se asocia a estados de concentración meditativa, procesos cognitivos como el cálculo.
- Alfa: frecuencias entre 8Hz y 13Hz. Están asociadas con la relajación y poca atención.
- Beta: frecuencias entre 14Hz y 26Hz. Relacionadas con proceso de pensamiento matemático e imaginación motora.
- Gamma: frecuencias entre 30Hz-50Hz. Relacionado con el mecanismo de la consciencia, la atención, percepción y emoción.

4.1.1.3 Funciones ventana

Una función ventana se define como una función valuada cero excepto en un intervalo finito. Esta función se multiplica por otra función para utilizar una porción finita de esta. Cada ventana posee características propias en términos de forma y amplitud, y existen diferentes tipos de ventanas implementadas según la aplicación deseada, como por ejemplo las Hamming, Hann, Blackman-Harros, Kaiser-Bessel, etc, y dejando determinados parámetros para ser definidos según la aplicación de la misma [5].

4.1.1.4 Submuestreo de la señal

La técnica de submuestreo por decimación o interpolación es un término asociado con el proceso de volver a muestrear una señal en un sistema de procesamiento. Es decir, cambiar la tasa de muestreo de una señal discreta a una tasa menor (submuestreo) o mayor (sobremuestreo) con la que fue muestreada originalmente [67]. El orden del submuestreo se realiza con un escalamiento en el tiempo ($x[nM]$, donde n es tiempo discreto y M el escalamiento), y se refiere a conservar únicamente cada M -ésima muestra de la señal original, es decir, se conservan únicamente las muestras cuyo índice es múltiplo de M , lo cual se representa como:

$$x_d[n] = x[nM] = x_c(nMT) = x[Mt] \quad (4.1)$$

En la definición de la ecuación 4.1, $x_d[nM]$ es la señal submuestreada, que puede ser obtenida a partir de muestrear la señal $x_c[2n]$, donde $M = 2$ y equivale a un muestreo de $x(2t)$. La tasa de muestreo puede ser reducida por un factor M sin aliasing, si la tasa de muestreo original fuera al menos M veces la frecuencia de Nyquist, o si el ancho de banda de la secuencia es primero reducida por un factor M mediante filtrado en tiempo discreto. Para evitar problemas de aliasing se implementa la técnica de decimación [68], definida como se muestra en la Figura 4.1, donde $x[n]$ representa la señal discreta, F_d el filtro anti aliasing, M es la tasa de submuestreo y $x_d[nM]$ la señal filtrada y submuestreada, es decir, decimada.




Figura 4.1 Esquema general de un decimador

4.1.1.5 Reducción de dimensiones

La reducción de dimensiones consiste en escoger un subconjunto de variables, de tal manera que el espacio de características quede óptimamente reducido de acuerdo a un criterio de evaluación, cuyo fin es distinguir el subconjunto que representa mejor el espacio inicial de entrenamiento [69].

En la literatura, dos métodos comúnmente utilizados para este fin son; el Análisis de componente Independiente (ICA) y el PCA. Estos métodos realizan un mapeo del espacio de características a un espacio transformado que puede ser de menor dimensión. El propósito de la reducción de dimensiones es disminuir el tiempo y trabajo de procesamiento de los sistemas al tratar con espacios de características múltiples, grandes y a veces redundantes.

4.1.1.6 Dominio del tiempo y de la frecuencia

Se suelen representar las señales obtenidas en uno de los tres dominios siguientes [70]:

- *Temporal*: las señales se muestrean con cierta frecuencia de muestreo durante determinado tiempo.
- *Frecuencia*: se utilizan dos tipos de transformaciones de Fourier:

- La Transformada Corta de Fourier (STFT por sus siglas en inglés), es una derivación de la Transformada de Fourier, donde se multiplica la transformación a un ventaneo de la señal original, conservando información en frecuencia y un poco de información en el tiempo. Esta transformación obedece a la expresión 4.2 en tiempo discreto.

$$STFT\{x(n)\} = X(m, \omega) = \sum_{n=-\infty}^{\infty} x(n)\omega(n - m)e^{-j\omega n} \quad (4.2)$$

Donde $\omega(n)$ es la función de ventana en tiempo discreto, $x(n)$ representa la señal a transformar en el tiempo discreto y $X(m, \omega)$ representa la transformada procedente de una señal en el tiempo discreto.

- La Transformada Rápida de Fourier o FFT, es un algoritmo para el cálculo de la Transformada Discreta de Fourier (DFT). Su importancia radica en que elimina gran parte de los cálculos repetitivos a los que está sometida la DFT, por lo tanto, se logra un cálculo más rápido y disminuye los errores de redondeo. La DFT obedece a la ecuación 4.3.

$$X(k) = \sum_{n=0}^{N-1} x(n)e^{-j2\pi k \frac{n}{N}} \quad k = 0, 1, \dots, N - 1 \quad (4.3)$$

Donde $x(n)$ representa la señal discreta en el tiempo, mientras $X(k)$ representa la señal en el dominio de la frecuencia y $e^{-j2\pi k \frac{n}{N}}$ es el kernel de transformación.

- *Tiempo-Frecuencia*: se trata de la transformación a multiresolución con la Transformada Wavelet. Se hace uso de las wavelets definidas en el espacio y se emplean como funciones de análisis. En la función discreta se debe discretizar la función madre como en la ecuación 4.4.

$$\Psi_{j,k}(n) = a^{-\frac{j}{2}}\Psi(a^{-j}n - kb) \quad (4.4)$$

Donde los parámetros a y b corresponden a variables que son parámetros de escala y traslación respectivamente e irán cambiando de valor a lo largo del proceso de análisis. El factor de normalización se presenta como $a^{-\frac{j}{2}}$.

4.1.2 Extracción de características

Dentro del proceso de los algoritmos analizados, la extracción de características consiste en realizar un análisis para seleccionar las propiedades que describen la información descriptiva de la señal. Un objetivo de esta etapa es encontrar el patrón descriptivo de la señal, pero reduciendo

la cantidad de datos. A continuación, se presentan las características de los métodos con mejores resultados.

4.1.2.1 Densidad espectral

La densidad espectral de una señal es una función cuadrática que refleja la distribución de la potencia (PDS) o energía (EDS) de dicha señal respecto a sus componentes de frecuencia [44].

La EDS es aquella que se obtiene de una señal que posee un cantidad finita de energía, es decir, si $0 < E_x < \infty$. Así pues, la EDS de una señal estará dada por la ecuación 4.5 para tiempo discreto. Donde $x(n)$ representa la señal en el dominio de frecuencia de la señal $x(n)$, y $S_{xx}(k)$ representa la EDS obtenida a partir de $x(k)$.

$$Ek_n = \sum_{n=-N}^N x(n)^2 \quad (4.5)$$

La potencia P_x representa la potencia de la señal por periodo discreto N de tiempo de una señal discreta $x(n)$, y está definida por la expresión 4.6.

$$P_x = \lim_{N \rightarrow \infty} \frac{1}{2N+1} \sum_{n=-N}^N |x(n)|^2 \quad (4.6)$$

4.1.2.2 Entropía de información

La entropía de información es una medida que describe la distribución de probabilidad $P = \{p_1, p_2, \dots, p_N\}$ de un conjunto de datos $X = \{x_1, x_2, \dots, x_N\}$, en términos de la uniformidad de la misma, donde al presentarse mayor uniformidad en la distribución de probabilidad disminuirá la entropía, y al disminuir la uniformidad en la distribución de probabilidad incrementará la entropía [71]. La ecuación 4.7 describe lo antes mencionado.

$$Entropía(X) = - \sum_{j=1}^N P_j \cdot \log_2[P_j] \quad (4.7)$$

La ecuación 4.7 considera la probabilidad de los datos con respecto al logaritmo base 2, obteniéndose un comportamiento como el que se muestra en la Figura 4.2. Este comportamiento indica que, al aumentar el rango de la función de distribución de los datos, se tiene una mayor entropía. Pero, al disminuir el rango de distribución de los datos y tener probabilidades más desiguales disminuye la entropía.




Figura 4.2 Gráfica del comportamiento de la operación logaritmo base 2

4.1.2.3 Asimetría

La asimetría se refiere a la comparación de la actividad cerebral en los hemisferios al realizar una tarea [72]. De acuerdo con los experimentos realizados por Terzian y Cecotto [73] ambos hemisferios del cerebro presentan asimetría en el procesamiento de emociones y el área de mayor actividad es la corteza prefrontal [74]. La asimetría diferencial (DASM) se obtiene de la resta entre las señales de ambos hemisferios, y la asimetría racional (RASM) se obtiene de la razón entre ellos [75], obteniendo información que describe una comparación entre las características estadísticas las señales de ambos hemisferios.

4.1.3 Clasificadores

Un clasificador puede definirse como un modelo que asigna una categoría o clase a la que pertenece un objeto. Los clasificadores pueden ser supervisados, no supervisados o reforzados, y constan de dos fases: el entrenamiento que consiste en que el clasificador aprende a partir de grupos masivos de datos, y la prueba que evalúa la capacidad de aprendizaje del calificador. Los clasificadores supervisados son aquellos en los que se conoce a priori el número de clases y las etiquetas de clasificación de cada elemento de los datos. Los no supervisados son aquellos que deben ajustar sus parámetros con base en los datos, y los reforzados aprenden a través de un proceso de ensayo y error, aprendiendo de experiencias pasadas y adaptando su enfoque para mejorar resultados.

4.1.3.1 K-enésimo vecino más cercano (KNN)

Es un algoritmo supervisado basado en distribuciones de probabilidad no paramétrica. Puede usarse para clasificar nuevas muestras (valores discretos) o para predicción (regresión, valores continuos). Es un método que busca la clase de pertenencia en los vectores más cercanos a la que se está tratando de predecir y se clasifica basado en la mayoría de datos que le rodean. De manera muy general, el algoritmo calcula la distancia entre los vectores de características y el resto de elementos de la base de entrenamiento. Posteriormente se seleccionan los k elementos más cercanos al vector de características para contar cuántos vecinos se tienen por cada clase. La cantidad máxima de vectores vecinos pertenecientes a cada clase indica a cuál pertenece el vector de características [76].

4.1.3.2 Máquina de vectores de soporte (SVM)

La máquina de vectores de soporte es un discriminante lineal con la forma:

$$g(x) = \omega^T q + \omega_o \quad (4.8)$$

donde $\omega = (\omega_1, \dots, \omega_l)$ representa el vector de pesos y $q = (q_1, \dots, q_l)$ representa el vector de características, y ω_o es un número real. La forma de encontrar la solución es a partir de los vectores de soporte, los cuales definen la separabilidad entre las clases, en los cuales se busca el hiperplano con mayor margen entre dos clases, donde el margen se refiere a la mayor distancia entre los puntos de características de cada clase. Considerando un conjunto de muestras de entrenamiento denotadas por u_j , cada una con su respectiva etiqueta g_j , siendo el subíndice j la enumeración de muestras. Se busca que los valores de ω y ω_o lleven el valor de $\|\omega\|$ a ser minimizado [77]. El cual está sujeto a la expresión 4.9.

$$y_i(\omega^T x_i + \omega_o) \geq 1 \quad i = 1, \dots, r \quad (4.9)$$

Donde r es la cantidad vectores de soporte y y_i representa el resultado del discriminante. Considerando lo anterior, la función de Lagrange queda definida como:

$$L(\omega, \omega_o, \lambda) = \frac{1}{2} \omega^T \omega - \sum_{i=1}^r \lambda_i [y_i(\omega^T x_i + \omega_o) - 1] \quad (4.10)$$

Donde L es la función de Lagrange, y λ_i son los multiplicadores de Lagrange. La expresión para obtener el vector de pesos queda entonces definida como:

$$\omega = \sum_{i=1}^r \lambda_i y_i x_i \quad (4.11)$$

4.1.3.3 Redes neuronales (ANN)

Las ANN son modelos computacionales inspirados en el sistema nervioso y el cerebro. Están constituidas por elementos que se comportan de forma similar a una neurona biológica en sus funciones más comunes. Dichos elementos están organizados a la manera en cómo se presentan las neuronas interconectadas en el cerebro, permitiendo realizar tres funciones principales: aprender, generalizar y abstraer.

En las ANN, la unidad análoga a la neurona biológica es el elemento procesador (PE o *process element*). Un elemento procesador tiene varias entradas y las combina normalmente con una suma básica. La suma de las entradas es modificada por una función de transferencia y el valor de la salida de esta función de transferencia se pasa directamente a la salida del elemento procesador. La salida del PE se puede conectar a las entradas de otras neuronas artificiales mediante conexiones ponderadas correspondientes a la eficacia de la sinapsis de las conexiones neuronales. El entrenamiento de una red neuronal se realiza modificando los pesos de sus neuronas para que consigan los resultados deseados. Para ello, lo que se hace es introducir datos de entrenamiento en la red y, en función de la salida, se modifican los pesos de las neuronas según el error obtenido por:

$$\omega_z^a(h+1) = \omega_z^a(h) + \mu \frac{\partial}{\partial \omega_z^a} (\sum_{h=0}^H e^2(h)) \quad (4.12)$$

Donde el superíndice a representa la a -ésima capa de la red, z representa la z -ésima neurona, h representa cada iteración del algoritmo, μ es el parámetro de aprendizaje y $e^2(h)$ es el error cuadrático en la iteración h , definido por:

$$e^2(h) = \frac{1}{2} \sum_{k=1}^{k_L} (y(h) - \bar{y}(h))^2 \quad (4.13)$$

Donde $y(h)$ representa el vector de salida deseada en la iteración h , k representa la cantidad de elementos del vector $y(h)$ y $\bar{y}(h)$ representa el vector de salida calculado.

4.2 Propuestas preliminares

De acuerdo con la información presentada en la sección anterior y con los resultados plasmados en el instrumento de evaluación diseñado, se realizaron cuatro propuestas de métodos de reconocimiento de emociones en los que se combinan las técnicas de preprocesamiento, extracción de características y clasificadores.

Los modelos propuestos tienen el propósito de examinar más a detalle el aporte de cada técnica de preprocesamiento, extracción de características y cada clasificador. La Figura 4.3 muestra el esquema de los diferentes métodos que fueron propuestos, cada uno con sus propios elementos de preprocesamiento, análisis de características y clasificadores.

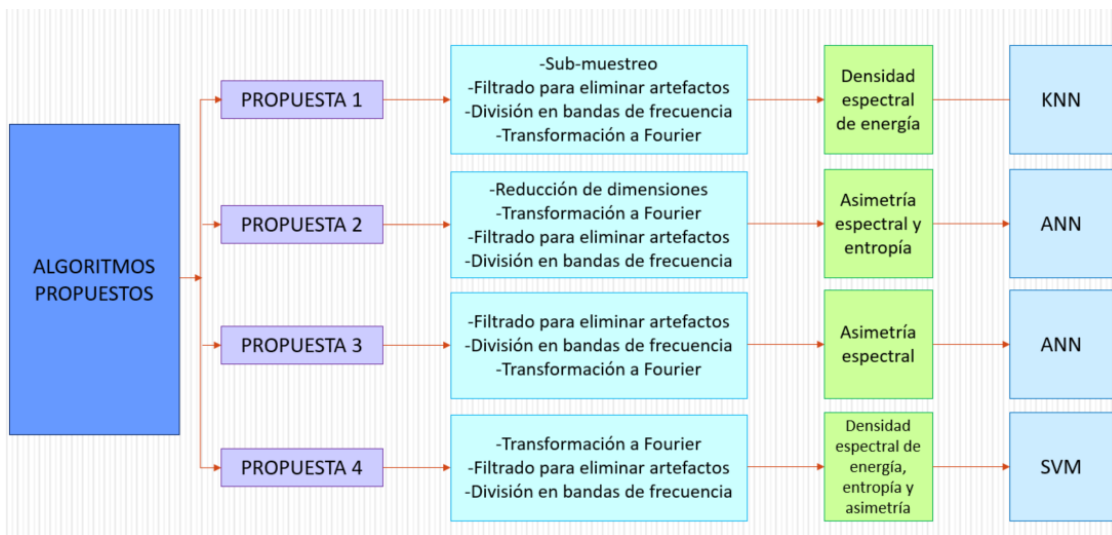


Figura 4.3 Esquema de los modelos propuestos

4.2.1 Propuesta preliminar 1

En la Figura 4.3 se muestran las 4 técnicas de preprocesamiento implementadas, una característica y un clasificador. Se realizó el submuestreo de la señal con un valor de decimación igual a 2 y un filtro Chebychev pasa bajas con frecuencia de corte normalizada a 0.8 para reducir la cantidad de operaciones. Luego se aplicó un filtro pasa banda de 0.5Hz a 55Hz, para eliminar artefactos de muy baja y muy alta frecuencia, de tipo IIR por su rapidez y su buena definición en frecuencias bajas.

Después, se aplicó la FFT utilizando una ventana tipo Hamming para ruido debido a la no continuidad de la señal, se promediaron las señales de todos los canales y se obtuvo la energía de cada señal. Se implementaron filtros pasa baja, pasa banda y pasa altas para dividir la señal de energía en las distintas frecuencias: delta, tetha, alfa, beta y gamma, entregando el resultado de energía total de cada banda. Finalmente, se entrenó el clasificador utilizando la energía total de cada banda como un vector de características de 5 dimensiones, entrenando un clasificador KNN.

En la Figura 4.4 se observa el resultado de la implementación de la propuesta preliminar 1. La Figura 4.4(a) muestra los resultados de implementar la información de las 5 bandas de frecuencia, donde se puede ver una precisión del 58.1% promedio para un clasificador de 4 emociones discretas. La Figura 4.4(b) muestra el resultado de precisión de 61.9% promedio al utilizar únicamente 3 bandas de frecuencia: alfa, beta y gamma, para un clasificador de 4 emociones discretas.

Clase de salida	Clase objetivo				
	Neutralidad	Tristeza	Miedo	Felicidad	Promedio
Neutralidad	180 20.8%	61 7.1%	63 7.3%	69 8.0%	48.3% 51.7%
Tristeza	9 1.0%	127 14.7%	47 5.4%	37 4.3%	57.7% 42.3%
Miedo	11 1.3%	17 2.0%	94 10.9%	9 1.0%	71.8% 28.2%
Felicidad	16 1.9%	11 1.3%	12 1.4%	101 11.7%	72.1% 27.9%
	83.3% 16.7%	58.8% 41.2%	43.5% 56.5%	46.8% 53.2%	58.1% 41.9%

Clase de salida	Clase objetivo				
	Neutralidad	Tristeza	Miedo	Felicidad	Promedio
Neutralidad	216 25.0%	57 6.6%	42 4.9%	62 7.2%	57.3% 42.7%
Tristeza	0 0.0%	159 18.4%	67 7.8%	47 5.4%	58.2% 41.8%
Miedo	0 0.0%	0 0.0%	107 12.4%	54 6.3%	66.5% 33.5%
Felicidad	0 0.0%	0 0.0%	0 0.0%	53 6.1%	100% 0.0%
	100.0% 0.0%	73.6% 26.4%	49.5% 50.5%	24.5% 75.5%	61.9% 38.1%

Figura 4.4 Matrices de confusión de clasificador propuesto 1, (a) resultados con 5 bandas de frecuencia, (b) resultados con 3 bandas de frecuencia

Con respecto a este modelo, se puede concluir que el aumento del valor de decimación reduce tanto el entrenamiento, como el tiempo y la complejidad de cómputo. No obstante, el filtrado en el tiempo incrementa la complejidad computacional en comparación con el filtrado en la frecuencia. También, se pudo observar también que la técnica de promediado tiene poco aporte al desempeño del modelo porque se pierde información precisa sobre electrodos particulares.

4.2.2 Propuesta preliminar 2

Como se observa en la Figura 4.3, la segunda propuesta preliminar implementa 4 técnicas de preprocesamiento, dos características y un clasificador basado en ANN. Inicialmente, se realizó una reducción de dimensiones para un mejor manejo de la información con PCA, del cual se utilizó un análisis de la varianza que permite observar la dispersión de datos acumulada que aporta cada componente principal. De dicho análisis, se seleccionaron 15 componentes principales, obteniendo los resultados como los mostrados en la Figura 4.5.

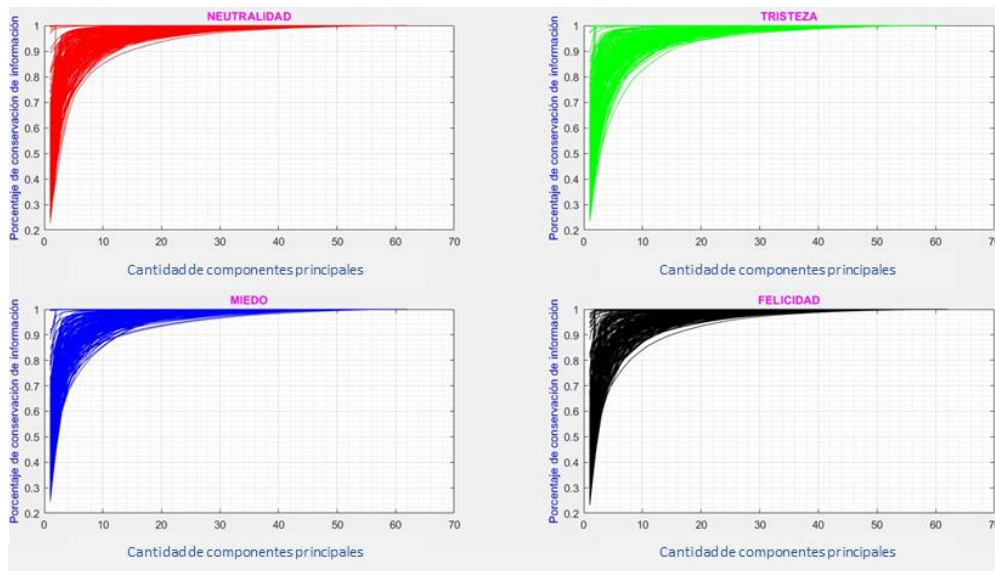


Figura 4.5 Resultado del análisis normado o con correlaciones

Una vez seleccionada la cantidad de componentes principales para trabajar, se realizó una transformación al dominio de frecuencia utilizando el algoritmo de la FFT. Luego se aplicó un filtro pasabanda en el dominio frecuencial, con frecuencias de corte en 0.5Hz y 55Hz, para eliminar los artefactos presentes. Posteriormente, se obtuvo el valor de energía de cada señal para así calcular la DASM espectral (para la cual se realizó un promediado de los electrodos utilizados, 7 de cada hemisferio). Luego de esto, se filtró la señal para obtener la información en cada banda de frecuencia, utilizando 5 filtros distintos. Finalmente se calculó la SE de las señales. En la etapa de clasificación, se diseñó una red neuronal con la cantidad de nodos de entrada según el tamaño de la señal utilizada (25900 para este caso), con 200 neuronas en la capa oculta, manejando una codificación en la capa de salida con dos neuronas, dicha codificación se diseñó como se muestra a continuación:

- “00” corresponde a la etiqueta 1: Neutralidad
- “01” corresponde a la etiqueta 2: Tristeza
- “10” corresponde a la etiqueta 3: Miedo
- “11” corresponde a la etiqueta 4: Felicidad

La arquitectura de la red se muestra en la Figura 4.6.

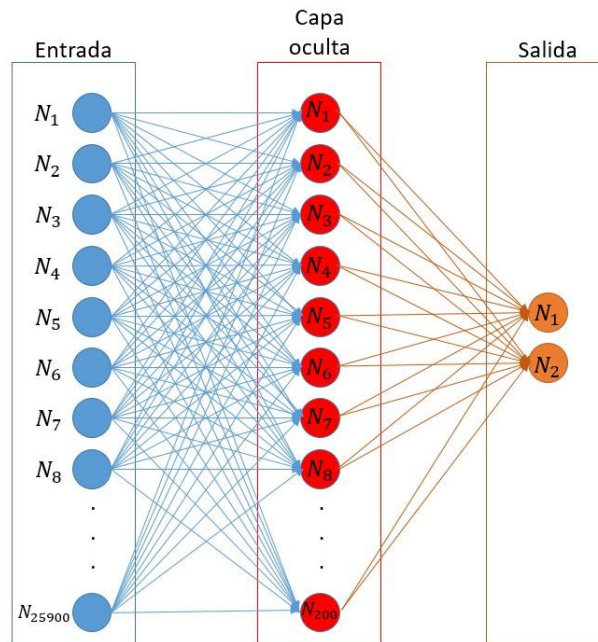


Figura 4.6 Arquitectura de red neuronal diseñada

En la Figura 4.7 se muestran los resultados de entrenamiento, validación y prueba del modelo. Se entregan valores de 67.6% de precisión en entrenamiento (Figura 4.7(a)), que es un valor comparable con los presentes en la literatura. El valor de precisión se incrementa aún más durante la validación con un 76.3% (Figura 4.7(b)) y prueba con 84.5% (Figura 4.7(c)), y un valor general de 71.5% (Figura 4.7(d)). Por lo tanto, el modelo presenta una clasificación competente con respecto a los demás modelos de la literatura, teniendo mayor facilidad de clasificar emociones positivas que negativas, aunque en éstas últimas hay mayor error al realizar la clasificación.

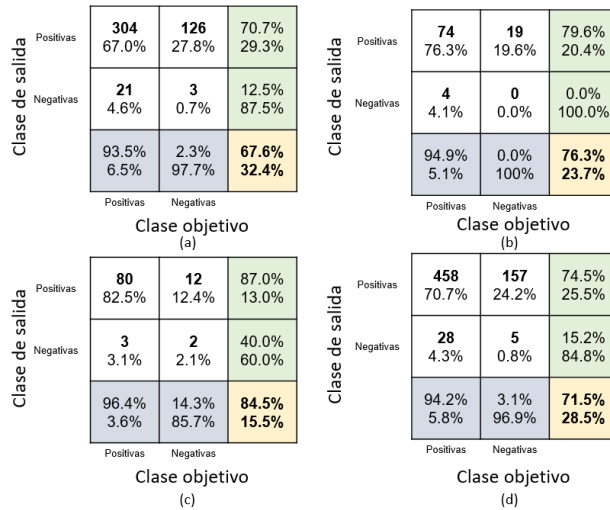


Figura 4.7 Matrices de confusión de clasificador propuesto 2, (a) entrenamiento, (b) validación, (c) prueba y (d) resultado general

Se realizaron pruebas con diferente cantidad de neuronas en la capa oculta. En estas pruebas se encontraron valores abajo del 40% de precisión para una cantidad menor a 150 neuronas. Además, el valor decrece a valores inferiores al 35% para una cantidad superior a 260 neuronas. No obstante, el mejor desempeño observado considera 200 neuronas en la capa oculta.

4.2.3 Propuesta preliminar 3

En la Figura 4.3 se muestra que la propuesta preliminar 3 es un algoritmo que comienza por filtrar todas las señales de la base de datos con un filtro IIR Butterworth con frecuencias de corte de 0.5Hz y 55Hz. Luego se filtraron las señales para obtener información en cada banda de frecuencia, cuyo proceso se realizó en el dominio temporal. Se obtuvo el espectro de energía de cada señal, y después la ASM entre los electrodos de un hemisferio y otro. Se implementó la DASM como características, obteniendo un valor escalar correspondiente a la misma. Luego se realizó una transformación al dominio de frecuencia utilizando la FFT. Se estructuraron las muestras en una imagen bidimensional, utilizando la propuesta de [32], pero con la característica del modelo propuesto. Finalmente, se implementó un clasificador basado en redes neuronales convolucionales, que posee una capa de convolución, una función de activación lineal, una operación de max-pooling y su capa de salida.

En la Figura 4.8 se muestra el resultado de implementar la propuesta preliminar 3. La Figura 4.8(a) corresponde a un clasificador binario de emociones basado en CNN entrenado con el

optimizador de estimación de momentum adaptivo (ADAM) con tasa de aprendizaje de 0.001, un tamaño de mini-lote de 50 y 30 épocas de entrenamiento. Los resultados obtenidos fueron de 70.4% de precisión. Los resultados del modelo muestran que es capaz de clasificar emociones positivas y negativas correctamente, con resultados competitivos respecto a la literatura.




Figura 4.8 Matrices de confusión de clasificador propuesto 3, (a) clasificador con 30 épocas de entrenamiento, (b) clasificador con 40 épocas de entrenamiento

En la Figura 4.8(b), se muestra la matriz de confusión de un clasificador binario basado en redes neuronales convolucionales, utilizando un optimizador ADAM, con parámetro de aprendizaje 0.001, un tamaño de lote de 50 y 40 épocas de entrenamiento; obteniendo un resultado de precisión del 80.9%.

La modificación de los parámetros de aprendizaje produce un incremento en el desempeño del modelo, mostrando un gran potencial como clasificador de emociones, tanto en clasificadores binarios como en emociones discretas. La estructura de las muestras de entrenamiento presenta un alto potencial de conservar información de electrodos específicos en distintas bandas de frecuencia, tanto en el dominio espectral como un poco de información temporal.

4.2.4 Propuesta preliminar 4

En la Figura 4.3 se aprecia que la propuesta preliminar 4 implementa 3 técnicas de preprocesamiento, tres características y un clasificador. Primeramente, se utiliza un filtro pasa banda con frecuencias de corte de 0.5Hz y 55Hz, tipo FIR. Posteriormente, se lleva a cabo un promediado de los distintos canales para obtener información de cada señal en cada una de las frecuencias que se están manejando. Se realizó la transformación al dominio de la frecuencia para el análisis, aplicando el algoritmo de la FFT y se obtuvo la energía de cada señal en cada banda de

frecuencia. A continuación, se calculó la DASM en cada hemisferio (utilizando la energía de las señales de 7 electrodos de cada hemisferio), empleando únicamente el valor absoluto de dicha diferencia de asimetría, buscando encontrar las frecuencias donde se presenta el valor mayor. Luego, se obtuvo como característica la entropía temporal (*Temporal Entropy* o TE). Finalmente, se estructuró un vector de tres características, una para cada característica, y se entrenó una SVM para cada par de emociones.

En la Figura 4.9 se muestra el resultado de implementar la propuesta preliminar 4. La cual se entrenó para clasificar emociones binarias utilizando una SVM, obteniendo un valor de precisión de 66.2%.

Clase de salida	Positivas	356 33.2%	182 17.0%	66.2% 33.8%
	Negativas	180 16.8%	354 33.0%	66.3% 33.7%
		66.4% 33.6%	66.0% 34.0%	66.2% 33.8%
		Positivas	Negativas	
		Clase objetivo		

Figura 4.4 Matriz de confusión de clasificador propuesto 4

Se entrenaron diferentes clasificadores binarios usados para detectar distintos pares de emociones, utilizando como vector de características la energía de la señal, DASM y la entropía. Es decir, un vector de tres dimensiones que posee información tanto temporal como frecuencial. Como conclusión final de este modelo se obtuvo que el filtrado en el tiempo presenta un mayor tiempo de procesamiento que los otros métodos habiendo utilizado un filtro en el dominio del tiempo (el filtrado en tiempo requiere la operación de convolución, mientras que en frecuencia se implementa una multiplicación) y un promediado de los 62 canales.

4.3 Conclusiones obtenidas

En esta sección se presentan las conclusiones de la implementación de los modelos antes mencionados.

En lo referente a la propuesta preliminar 1, se encontró que los resultados obtenidos muestran que es posible la clasificación con valores de precisión por debajo del 65% que, según el instrumento de evaluación, está entre los modelos con más bajo desempeño. Al realizar el cambio de 5 a 3 bandas de frecuencia, se muestra un incremento del 3.8% que, aunque es una mejora, no es significativo para profundizar en la propuesta preliminar y sus variaciones. Sin embargo, en esta propuesta preliminar se encontró que la reducción de bandas de frecuencia permite eliminar información redundante.

De acuerdo con los resultados obtenidos en la propuesta preliminar 2, se concluyó que los clasificadores basados en ANN obtienen valores de precisión competitivos con los presentes en la literatura. Esta propuesta preliminar entregó el segundo valor de precisión más alto de entre las propuestas preliminares, y de acuerdo con el análisis realizado al variar la cantidad de neuronas en la capa oculta, este modelo tiene la capacidad de incrementar los resultados de precisión.

En lo referente a la propuesta preliminar 3, se puede concluir que la estructura de las muestras de entrenamiento es una opción fiable para el manejo de la información en el dominio espacial y en la frecuencia, con lo que se puede incrementar el desempeño de la red. De igual manera, la modificación de parámetros de entrenamiento mostró un incremento de 10.5% de precisión.

La propuesta preliminar 4, entrega como resultado un valor de precisión de 66.2%, lo que, según el instrumento de evaluación, se encuentra entre los métodos con más baja precisión. Sin embargo, la información procesada en frecuencia mejora el desempeño del modelo, aunque no de manera significativa. Otras variaciones en los parámetros de entrenamiento no aportan mejor precisión al resultado.

Con base en el análisis de los modelos, se puede concluir que el esquema que presenta el desempeño más alto es aquel que integra filtrado en frecuencia, características en el dominio de la frecuencia y ANN. Por lo tanto, con base en las contribuciones de las propuestas preliminares presentadas en este capítulo, se puede concluir que es posible el diseño de un método de reconocimiento de emociones con las técnicas que aportaron mejor desempeño en los experimentos realizados.

La Tabla 4.1 muestra los resultados obtenidos en cuanto a precisión, tiempo de preprocesamiento, tiempo de extracción de características y tiempo de entrenamiento de las cuatro propuestas preliminares descritas en esta sección.

Tabla 4.1 Comparación de precisión y tiempo de los modelos implementados

Modelo propuesto	Tiempo de ejecución preprocesamiento (segundos)	Tiempo de ejecución en extracción de características (segundos)	Tiempo de ejecución en entrenamiento de modelo (segundos)	Precisión obtenida en clasificación
Modelo 1	304.02237	13.771370	57.821434	61.9%
Modelo 2	112.068681	20.281167	12.35487	67.6%
Modelo 3	106.069748	2675.971102	87.16586	80.9%
Modelo 4	105.633374	501.014277	125.726227	66.2%

De acuerdo con lo mostrado en la Tabla 4.1, las propuestas preliminares 3 y 4 tuvieron los tiempos menores de preprocesamiento. Las propuestas preliminares 1 y 2 tuvieron el menor tiempo en cuanto a ejecución de extracción de características. Para el entrenamiento de los modelos, el menor tiempo se obtiene en las propuestas preliminares 1 y 2. Como se puede observar, el tiempo de ejecución para crear las muestras de entrenamiento se eleva considerablemente para la propuesta preliminar 3 (el que posee mayor precisión).

Se concluyó que las técnicas de preprocesamiento que entregan un mayor aporte a la clasificación son el filtrado para eliminación de artefactos y la división en bandas de frecuencia. Para la extracción de características, los modelos con mejor resultado son la ASM, la energía y la entropía. En los siguientes capítulos se aclarará más el uso de cada una de ellas y sus respectivos aportes con mejor claridad.

También se concluye que los modelos basados en ANN poseen un alto potencial de mejora en precisión y extracción de información que los modelos basados en SVM y KNN. Por lo tanto, las ANN se seleccionaron como clasificador a utilizar. De entre los dos distintos modelos de ANN, el que se basa en CNN (propuesta preliminar 3) presentó el mejor desempeño, ya que incrementa el

resultado de precisión aún y cuando se varían los distintos parámetros intervienen en la configuración y el entrenamiento.

Partiendo del análisis anterior, se encontraron las técnicas de preprocesamiento que entregaron los resultados con mejor aporte en términos de precisión, así como las características que describen las emociones con mejor particularidad y los clasificadores que muestran los mejores resultados. Con base en esto, en el siguiente capítulo se describe la metodología seguida para el diseño del modelo de clasificación propuesto.

CAPÍTULO 5. MODELO PROPUESTO

Los capítulos anteriores presentan los conceptos y experimentos necesarios con el objetivo de definir cuál es la metodología adecuada para comprender la forma de diseñar un nuevo método. Este capítulo presenta el desarrollo del método propuesto en este documento: *Deeper Inception (D-Inception)*. Para describirlo, en este capítulo se presentan las bases de datos más utilizadas, la selección del modelo de emociones y una descripción detallada del método *D-Inception*; especificando los factores que se tomaron en consideración para la selección de elementos y configuración de parámetros.

5.1 Bases de datos

Existen pocas bases de datos que se estructuran con señales EEG relacionadas a las emociones [78]. Por lo tanto, la selección de las mismas es de vital importancia para el propósito de este trabajo. Para este trabajo, se siguió el mismo esquema que existe en la literatura de emociones discretas, de manera que la base de datos *SJTU Emotion EEG Dataset for four emotions (SEED-IV)* [79] se utilizó para el entrenamiento y validación del modelo. Por otro lado, la base de datos *Database for Emotion Analysis using Physiological Signals (DEAP)* [82], se utilizó para una prueba, a la que se referirá en lo futuro como validación con DEAP. La descripción de las mismas se encuentra en las siguientes subsecciones.

5.1.1 SEED

La base de datos fue creada por el laboratorio BCMI (*Brain-like Computing & Machine Intelligence*) liderado por el profesor Bao-Liang Lu. Creada con fines de investigación en aras de comprender los mecanismos del procesamiento de información cerebral y procesos cognitivos. Para poder acceder a la base de datos se requiere una solicitud y firma de convenio para usos de investigación.

La base de datos posee diferentes variantes según la aplicación que se trabajará, de entre las cuales se seleccionó la variante SEED-IV debido a que posee muestras clasificadas en 4 clases: neutralidad, tristeza, miedo y felicidad. Las señales EEG de se grabaron con 62 canales colocados con base en el Sistema Internacional 10-10, una frecuencia de muestreo de 1000Hz y cada experimento tiene una duración distinta. La estructura de la base de datos se muestra en la Figura 5.1, donde se observa que se experimentó con 15 sujetos de prueba, realizando 3 experimentos en

cada uno. Se evocaron las emociones con 72 clips de películas escogidas por medio de un estudio preliminar. Se realizaron 3 sesiones diferentes del experimento, el cual posee 24 episodios (6 evocaciones por emoción), entregando un total de 1080 señales en total.

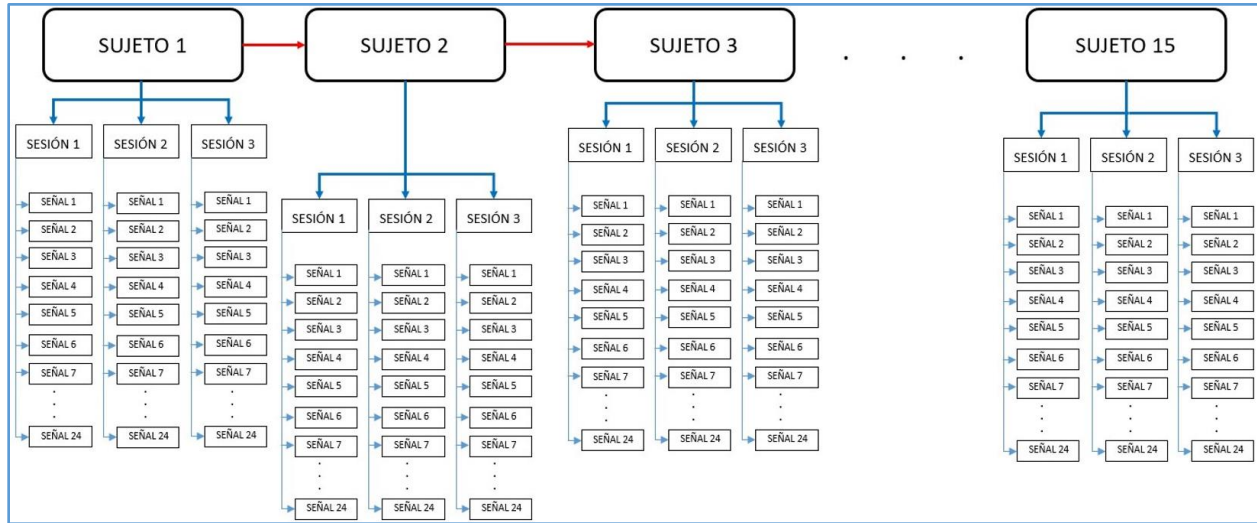


Figura 5.1 Estructura de señales de base de datos SEED-IV

5.1.2 DEAP

Esta base de datos es de uso público, generada con fines de investigación y divulgación. Para tener acceso a esta base de datos se requiere la firma de solicitud y licencia.

DEAP fue seleccionada por su estructura con respecto a las clases pues permite hacer una correlación con las clases de neutralidad, tristeza, miedo y felicidad. Esta correlación se realizó con la rueda de emociones de Plutchik descrita en el Capítulo 2 (Figura 2.10). Esta base de datos posee señales de 32 sujetos de prueba, utilizando 40 clips de videos musicales estimulantes. Los clips se seleccionaron por medio de un estudio preliminar de evaluación. Se utilizaron 32 electrodos colocados, con referencia al Sistema Internacional 10-10, con una frecuencia de muestreo de 512Hz y se utilizan solamente los electrodos: Fp1, AF3, F3, F7, FC5, FC1, C3, T7, CP5, CP1, P3, P7, PO3, O1, Oz, Pz, Fp2, AF4, Fz, F4, F8, FC6, FC2, Cz, C4, T8, CP6, CP2, P4, P8, PO4, O2. Se realizó la auto-evaluación de los sujetos en términos de excitación, valencia, dominancia, gusto y familiaridad. Las clases asignadas se clasifican según el modelo discreto: orgullo, elación, alegría, satisfacción, descanso, esperanza, interés, sorpresa, tristeza, miedo, vergüenza, culpa, envidia, disgusto, desprecio e ira.

5.2 Modelo de emociones

De acuerdo a la Tabla 2.1, el modelo discreto es menos utilizado que el dimensional. Esto se debe a que en el modelo dimensional se realiza un mapeo que genera una mejor visualización de la diferenciación de las emociones. Sin embargo, aun y cuando el modelo dimensional ha obtenido resultados competitivos con los métodos reportados en la literatura, sigue conservando en gran medida el componente psicológico de la evaluación personal del individuo del experimento. Por otro lado, el modelo discreto presenta la idea de que las emociones son entidades básicas, diferenciables en concepto y naturaleza que son propias de respuestas neurofisiológicas y conceptuales. De esta manera, la autoevaluación de la experiencia del sujeto de experimento se centra en una emoción específica y completamente diferenciada de las demás, compartiendo la idea de un clasificador que separe en clases los tipos de emociones, por esta razón seleccionó el modelo discreto de emociones para *D-Inception*, pues considera un número limitado de emociones altamente diferenciables por el individuo para evitar, en medida de lo posible, la confusión de la experiencia subjetiva del mismo.

5.3 *D-Inception*

Habiendo seleccionado el modelo discreto de emociones y las conclusiones presentadas en el capítulo anterior, se desarrolló el método *D-Inception*, descrito de manera general en la Figura 5.2. La entrada es una señal EEG ya preprocesada de la que se extrae información de las bandas alfa, beta y tetha. Luego, se extraen características en el dominio del tiempo y la frecuencia, mismas que se estructuran como una imagen de tres canales, donde cada canal corresponde a la información en una banda de frecuencia. Después se pasa a una red convolucional tipo *Inception* pero modificada y previamente entrenada que extrae las propiedades abstractas de la muestra para obtener un resultado probabilístico de la emoción clasificada (una de cuatro posibles). Las categorías en que clasifica la red son emociones de: neutralidad, tristeza, miedo y felicidad.

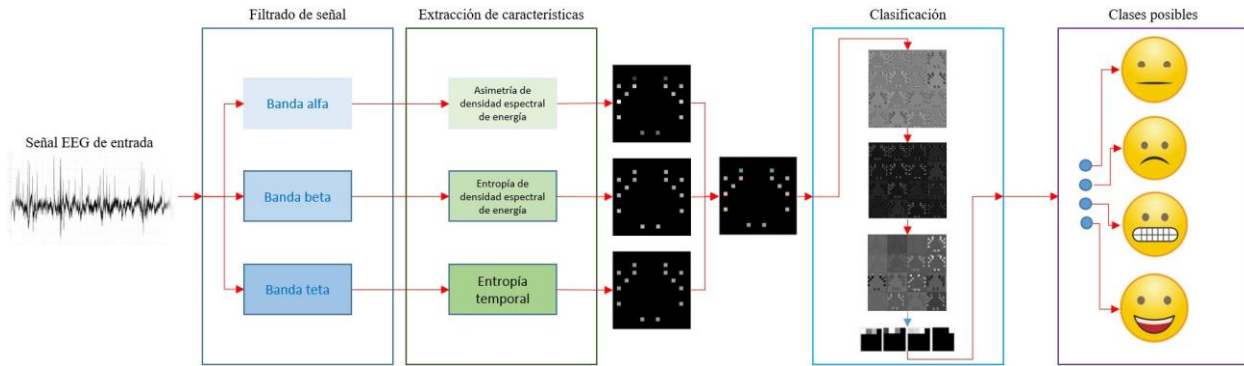


Figura 5.2 Esquema general del modelo propuesto D-Inception

Para llegar a consolidar la arquitectura final de la red propuesta, se llevaron a cabo diferentes experimentos con el fin de obtener los mejores resultados de precisión en clasificación, entre los cuales destacan:

- Pruebas con diferentes bandas de frecuencia.
- Modificaciones en la arquitectura de la red.
- Parámetros de filtros y capas.

Cada una de las etapas de *D-Inception* se describirá a continuación.

5.3.1 Preprocesamiento

La selección de las técnicas de preprocesamiento se definió con base en el análisis de la literatura descrito al inicio de este documento, implementando las técnicas que presentaron un mejor aporte a la precisión de la clasificación.

La entrada de *D-Inception* son las señales EEG $E_j(t)$, donde j es el índice que representa el canal de la señal y t el índice de tiempo.

El primer paso es hacer una normalización tanto en amplitud como en longitud para que las señales tengan el mismo rango dinámico. Esta normalización está dada por la ecuación 5.1.

$$Q_j(t) = \frac{E_j(t) - \overline{E_j(t)}}{\sigma[E_j(t)]} \quad (5.1)$$

donde $\overline{E_j(t)}$ representa el valor medio de la señal y $\sigma[E_j(t)]$ representa la desviación estándar de la misma señal.

Después, se implementó un filtro pasa bandas con frecuencias de corte en 0.5Hz y 50Hz para eliminar artefactos, el modelo del filtro se puede ver en [5] y la señal resultante se denominó $S_j(t)$. Luego, se realizó la división en bandas de frecuencia delta, alfa, beta, gamma y tetha, con los filtros que se pueden ver en [83], obteniéndose una familia de señales $S_{\tau j}(t)$, donde $\tau = \{\text{delta}, \text{alfa}, \text{beta}, \text{gamma}, \text{tetha}\}$. Finalmente, se hizo la transformación al dominio de frecuencia con la Transformada Rápida de Fourier (FFT) [70], obteniéndose $S_{\tau j}(f)$, donde f es el índice de frecuencia.

Un aspecto importante es la cantidad de electrodos, ya que, entre menos electrodos, es más cómodo el uso de las BCI y es menor la cantidad de operaciones y uso de memoria del algoritmo que procesa las señales EEG. Para analizar la reducción de la cantidad de electrodos se realizó una investigación con expertos del área de psicología y neuropsicología en referente al procesamiento de las emociones en el cerebro. De acuerdo con [82] y los expertos entrevistados, el proceso emocional es resultado de procesos neurofisiológicos y pensamientos abstractos que generan mayor actividad en los lóbulos frontal y temporal. Con base en esta información, los experimentos con *D-Inception* se realizaron considerando 4 configuraciones de electrodos para obtener la mejor relación entre desempeño y baja cantidad de electrodos. Los entrenamientos se realizaron con 62, 24, 14 y 8 electrodos para clasificar emociones como positivas y negativas, y también como neutralidad, tristeza, miedo y felicidad.

La primera configuración designada por $j = j62$ considera los 62 electrodos del Sistema Internacional 10-10, tal como se muestra en la Figura 2.1(b). Esta configuración forma la señal preprocesada $S_{\tau j62}(f)$.

La segunda configuración $j = j24$ considera los electrodos AF3, FP1, FPZ, FP2, AF4, F7, F5, F3, F1, FZ, F2, F4, F6, F8, FT7, FC5, FC6, FT8, T7, T8, TP7, TP8, P7, P8, generando la señal $S_{\tau j24}(f)$. Estos electrodos consideran los lóbulos frontal y temporal con un alto nivel de resolución.

La tercera configuración $j = j14$ considera los electrodos AF3, AF4, F7, F8, F3, F4, FC5, FC6, T7, T8, P7, P8, O1, O2, generando la señal $S_{\tau j14}(f)$. Estos electrodos consideran los lóbulos frontal y temporal con un nivel de resolución medio. También se consideraron las posiciones O1

y O2 para revisar si el estímulo visual generado por los videos que evocan la emoción genera alguna actividad en la corteza visual que se pueda considerar [83].

La cuarta configuración $j = j8$ considera los electrodos AF3, AF4, F7, F8, F3, F4, T7, T8, generando la señal $S_{\tau j8}(f)$. Estos electrodos consideran los lóbulos frontal y temporal con un nivel de resolución bajo.

Para encontrar la cantidad adecuada de electrodos, se diseñó un algoritmo para clasificar emociones que extrae características con $TE(S_{\tau j}(f))$, $SE(S_{\tau j}(f))$, $EDS(S_{\tau j}(f))$ y $ASM_{EDS}(S_{\tau j}(f))$, donde j es el superconjunto $j: \{j62, j24, j14, j8\}$. Estas características se seleccionaron por presentar resultados de precisión competitiva en los métodos analizados de la literatura. El clasificador fue la red *Inception* de [34], donde la entrada de la red está dada por el vector de características $X_{feat} = \{TE(S_{\tau j}(f)), SE(S_{\tau j}(f)), EDS(S_{\tau j}(f)), ASM_{EDS}(S_{\tau j}(f))\}$. La salida de la red es $C_E = \{1,2,3,4\}$, donde el valor 1 corresponde a neutralidad; 2 a tristeza; 3 a miedo y 4 a felicidad. De este experimento se obtuvo la relación de los resultados, comparando la reducción de electrodos con el valor de precisión obtenido. La Tabla 5.1 muestra los resultados obtenidos de la reducción de electrodos, donde se compara el incremento o decremento del desempeño del sistema en términos de precisión para cada característica; siendo el punto de referencia los resultados de utilizar 62 electrodos. Los valores con mejor variación se resaltaron de distintos colores, el color verde muestra los mejores resultados para $TE(S_{\tau j}(f))$; el color café, para $SE(S_{\tau j}(f))$; el azul, para $EDS(S_{\tau j}(f))$ y amarillo, para $ASM_{EDS}(S_{\tau j}(f))$.

Al final del experimento se pudo concluir que la disminución de la cantidad de electrodos es posible conservando también el valor de precisión que ofrece el clasificador con 62 electrodos [46]. En algunos de los casos, se incrementó el valor de precisión en relación al clasificador con los electrodos, mientras que, en otros casos, la precisión disminuye considerablemente. Los mejores resultados para el clasificador de emociones positivas/negativas se obtienen en entrenamiento con $j = j24$, así como en validación y validación con DEAP. Para el clasificador de emociones de neutralidad/felicidad el mejor resultado en entrenamiento se obtiene con $j = j14$; para validación, con $j = j8$ y para validación con DEAP $j = j24, j14, j8$. Para el clasificador de emociones de tristeza/miedo, el valor más alto se obtiene al utilizar $j = j14$, tanto en entrenamiento, como en validación y validación con DEAP.

Se concluyó entonces que es posible trabajar los clasificadores con número reducido de electrodos, teniendo los mejores resultados al utilizar $j = j14$. El resultado del experimento de esta sección, mostró con claridad que la información necesaria para discriminar entre una emoción y otra, se encuentra en la zona frontal y temporal del cerebro.

Tabla 5.1 Comparación de resultados de precisión con respecto al experimento con 62 electrodos

EMOCIONES	CARACTERÍSTICAS	ENTRENAMIENTO			VALIDACIÓN			VALIDACIÓN CON DEAP		
		$j8$	$j14$	$j24$	$j8$	$j14$	$j24$	$j8$	$j14$	$j24$
POSITIVAS / NEGATIVAS	$TE(S_{\tau_j}(f))$	1.5%	1.5%	2.33%	2.77%	-2.32%	2.31%	-5.6%	-2.3%	-2.7%
	$SE(S_{\tau_j}(f))$	3%	3.83%	-7.84%	-6.94%	-2.77%	-6.3%	8%	1.2%	4.4%
	$EDS(S_{\tau_j}(f))$	2.16%	10.5%	1.0%	-7.87%	-3.7%	-4.63%	1.9%	-0.3%	1.7%
	$ASM_{EDS}(S_{\tau_j}(f))$	2.5%	6.67%	13.33%	-3.24%	-0.93%	4.17%	-2.6%	-1.1%	2.9%
NEUTRALIDAD / FELICIDAD	$TE(S_{\tau_j}(f))$	0%	0%	0%	0%	0%	0%	68.4%	68.4%	68.4%
	$SE(S_{\tau_j}(f))$	-13.67%	-13.67%	-26.67%	6.48%	-3.7%	-4.67%	-2.5%	-2.5%	37.8%
	$EDS(S_{\tau_j}(f))$	-0.5%	2%	-9.34%	0.93%	1.85%	-3.7%	6.2%	-23.2%	13.9%
	$ASM_{EDS}(S_{\tau_j}(f))$	-25.5%	-2.17%	-5.5%	-9.26%	-13.89%	-7.4%	-30.7%	-19.9%	15%
TRISTEZA / MIEDO	$TE(S_{\tau_j}(f))$	6.16%	-7.17%	-13%	-7.41%	1.22%	0%	-14.2%	-22.2%	-20.9%
	$SE(S_{\tau_j}(f))$	10.0%	8.33%	5.83%	-5.56%	-1.86%	-0.93%	23.7%	23.8%	0%
	$EDS(S_{\tau_j}(f))$	-4.17%	0%	-8.75%	-12.04%	-9.26%	-3.7%	0.1%	4.8%	12.7%
	$ASM_{EDS}(S_{\tau_j}(f))$	-25.84%	15%	-27.5%	-1.85%	-6.48%	0%	10%	11.3%	-4%

5.3.2 Extracción de características

En esta sección se presentan dos experimentos destinados a definir las bandas de frecuencia a utilizar, y aquellas características que realmente aportan a la clasificación del modelo. El primer experimento está relacionado a conocer cual banda de frecuencia aporta más información respecto al reconocimiento de emociones y el segundo experimento es para conocer qué característica aporta más a cada banda de frecuencia de la señal.

5.3.2.1 Bandas de frecuencia

El propósito del experimento fue conocer qué bandas de frecuencias utilizadas en el estado del arte del reconocimiento de emociones aporta la mejor información no redundante y el menor ruido posible. Para ello, se utilizó la CNN utilizada en la sección 5.3.1, con un optimizador ADAM [84]

con parámetro de aprendizaje adaptivo que comienza en 0.01 y a las 350 épocas se multiplica por 0.005, un tamaño de mini-lote de 120 y un total de 500 épocas. Se realizó el experimento por característica y por banda.

En las Figuras 5.3, 5.4 y 5.5 se muestran los resultados obtenidos. Para el clasificador de emociones positivas/negativas (incisos (a) de las Figuras), los mejores resultados se obtienen con las bandas alfa (α), beta (β) y theta (θ), con valores de precisión promedio en entrenamiento de 78.95%, 78.33% y 78.75%, respectivamente. De igual manera, se tienen valores de precisión promedio en validación de 58.22%, 57.40% y 59.60%, respectivamente. Para el clasificador de emociones de neutralidad/felicidad (incisos (b) de las Figuras) se tienen los mejores resultados con las bandas α , β y θ con valores de precisión promedio de entrenamiento de 66.66%, 63.19% y 69.21%, así como valores de precisión promedio en validación de 63.66%, 63.19%, y 69.21%, respectivamente. Para el clasificador de emociones de tristeza/miedo (incisos (c) de las Figuras), se tienen los mejores resultados con las bandas α , β y θ , con valores de precisión promedio en entrenamiento de 67.54%, 78.12% y 77.70%. Finalmente, los valores de precisión promedio en validación fueron de 49.30%, 45.37% y 53.01%, respectivamente.

Por lo tanto, las bandas de frecuencia con mejor aporte para la clasificación de emociones son las bandas α , β y θ , ya que presentan un comportamiento que permite diferenciar con mayor fidelidad las emociones.

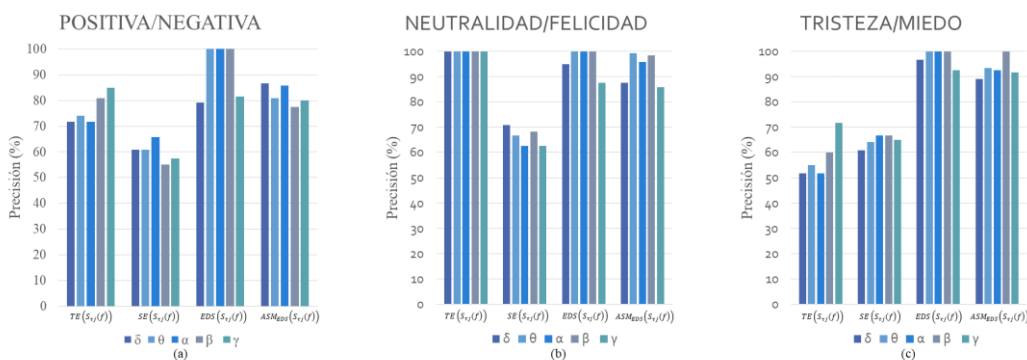


Figura 5.3 Precisión de modelo durante entrenamiento por característica y banda independiente




Figura 5.4 Precisión de modelo durante validación por característica y banda independiente




Figura 5.5 Precisión de modelo durante validación con DEAP por característica y banda independiente

5.3.2.2 Características de cada banda de frecuencia

Se experimentó con las características de $TE(S_{\tau_j}(f))$, $SE(S_{\tau_j}(f))$, $EDS(S_{\tau_j}(f))$ y $ASM_{EDS}(S_{\tau_j}(f))$ en las bandas de frecuencia $\tau = \{\alpha, \beta, \theta\}$, y se continuó utilizando la misma arquitectura de red y las configuraciones de entrenamiento que la sección anterior. Se entrenaron cuatro clasificadores distintos para asignar clase a los siguientes grupos de emociones:

- Positivas y negativas.
- Tristeza y miedo.
- Neutralidad y felicidad.
- 4 emociones discretas (neutralidad, tristeza, miedo y felicidad).

Las muestras obtenidas para entrenamiento se generaron mediante un script en MATLAB. Para obtener cada muestra de entrenamiento se realizó una transformación del vector de características a una imagen RGB de 20x20 píxeles, conservando de esta manera la información espectral y poca

información espacial de cada señal. La conformación de las muestras se tomó de [31], donde cada muestra está estructurada como una imagen de tres canales, RGB, donde cada canal corresponde a una banda de frecuencia. Las muestras quedaron ordenadas como se muestra en la Figura 5.6, donde cada banda de frecuencia (espectro de la señal en sus respectivas bandas) se mapea en una imagen bidimensional para generar cada canal de una imagen RGB, entregando en la salida una imagen de tres canales. La muestra generada conserva poca información espacial de los electrodos y mucha información espectral de cada uno de ellos. En secciones posteriores se analizará la mejor combinación de bandas de frecuencia y características a utilizar para generar las imágenes de muestra.

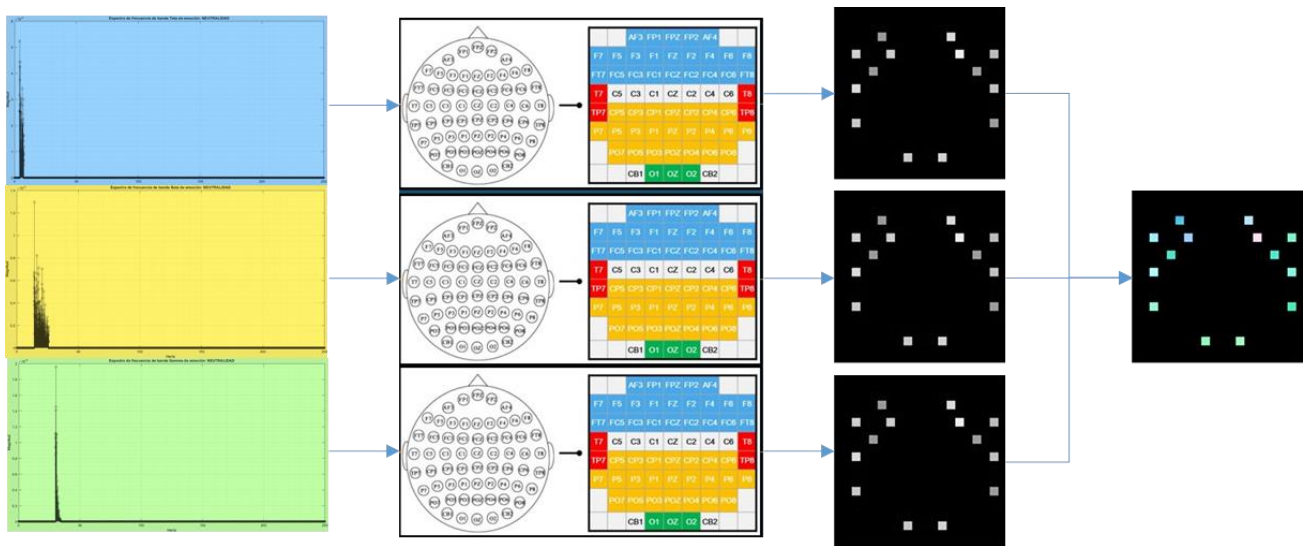


Figura 5.6 Descripción de estructura de muestra $j=j14$

Las Figuras 5.7, 5.8 y 5.9 muestran los resultados de los experimentos con las bandas de frecuencia para cada característica en entrenamiento, validación, y validación con DEAP, respectivamente. En ellas se puede observar la característica, la banda utilizada en cada canal y el resultado de precisión obtenido.




Figura 5.7 Precisión de modelo durante entrenamiento por característica y combinación de bandas




Figura 5.8 Precisión de modelo durante validación por característica y combinación de bandas




Figura 5.9 Precisión de modelo durante validación con DEAP por característica y combinación de bandas

Se encontró en los resultados del clasificador de emociones positivas/negativas, que los mejores valores de precisión en entrenamiento/validación se obtienen al combinar las características en la siguiente manera:

1. $ASM_{EDS}(S_{\alpha_j}(f)), EDS(S_{\beta_j}(f))$ y $TE(S_{\theta_j}(f))$.
2. $SE(S_{\alpha_j}(f)), EDS(S_{\beta_j}(f))$ y $TE(S_{\theta_j}(f))$.

En referente al clasificador de emociones de neutralidad/felicidad, se observó un gran potencial de separabilidad entre ambas emociones definido por las características de cada uno de estos estados emocionales, donde 13 de las 24 combinaciones posibles de bandas de frecuencia (3 bandas a combinar en cada una de las 4 características) muestran resultados de precisión superiores al 95%.

Para el clasificador de emociones de tristeza/miedo, se obtuvieron resultados prometedores en entrenamiento, mientras que en validación desciende considerablemente, teniendo los mejores resultados en las siguientes combinaciones:

1. $TE(S_{\alpha_j}(f)), ASM_{EDS}(S_{\beta_j}(f))$ y $EDS(S_{\theta_j}(f))$.
2. $SE(S_{\alpha_j}(f)), ASM_{EDS}(S_{\beta_j}(f))$ y $EDS(S_{\theta_j}(f))$.
3. $EDS(S_{\alpha_j}(f)), TE(S_{\beta_j}(f))$ y $ASM_{EDS}(S_{\theta_j}(f))$.
4. $EDS(S_{\alpha_j}(f)), SE(S_{\beta_j}(f))$ y $ASM_{EDS}(S_{\theta_j}(f))$.
5. $ASM_{EDS}(S_{\alpha_j}(f)), TE(S_{\beta_j}(f))$ y $EDS(S_{\theta_j}(f))$.
6. $ASM_{EDS}(S_{\alpha_j}(f)), EDS(S_{\beta_j}(f))$ y $TE(S_{\theta_j}(f))$.

Finalmente, los mejores resultados para el clasificador de cuatro emociones discretas (neutralidad, tristeza, miedo, felicidad) están dados por la combinación de bandas y características que se muestran a continuación:

1. $TE(S_{\alpha_j}(f)), EDS(S_{\beta_j}(f))$ y $SE(S_{\theta_j}(f))$.
2. $EDS(S_{\alpha_j}(f)), ASM_{EDS}(S_{\beta_j}(f))$ y $TE(S_{\theta_j}(f))$.
3. $ASM_{EDS}(S_{\alpha_j}(f)), TE(S_{\beta_j}(f))$ y $SE(S_{\theta_j}(f))$.
4. $ASM_{EDS}(S_{\alpha_j}(f)), EDS(S_{\beta_j}(f))$ y $TE(S_{\theta_j}(f))$.

Aún y cuando todas las combinaciones antes mencionadas generan buen desempeño en la clasificación, se puede buscar una combinación general para todas las formas de clasificación. De esta manera, para obtener los mejores resultados, desde la perspectiva de las características, las combinaciones son:

1. $ASM_{EDS}(S_{\alpha_j}(f)), EDS(S_{\beta_j}(f))$ y $TE(S_{\theta_j}(f))$.
2. $ASM_{EDS}(S_{\alpha_j}(f)), SE(S_{\beta_j}(f))$ y $EDS(S_{\theta_j}(f))$.
3. $SE(S_{\alpha_j}(f)), EDS(S_{\beta_j}(f))$ y $TE(S_{\theta_j}(f))$.

Las combinaciones anteriores poseen valores de precisión superiores al 80%, sin embargo, la combinación de características y bandas de frecuencia con los resultados más altos es:

1. $ASM_{EDS}(S_{\alpha_j}(f)), SE(S_{\beta_j}(f))$ y $TE(S_{\theta_j}(f))$.

5.3.3 Clasificador

Para definir la arquitectura final de la red *D-Inception* se realizaron varias pruebas, tomando como base el módulo *Inception* [85] y haciendo modificaciones para obtener los mejores resultados, variando los valores de:

- Función de activación.
- Inicialización de pesos.
- Tamaño de mini-lote.
- Optimizador.

5.3.3.1 Función de activación

En la Figura 5.10, 5.11, 5.12 y 5.13 se muestran los resultados de implementar diferentes funciones de activación en el clasificador de 4 emociones discretas, positivas/negativas, neutralidad/felicidad y tristeza/miedo, respectivamente. Se puede observar que el mejor desempeño en entrenamiento se obtiene con Leaky-ReLU (por sus siglas en inglés *Rectified Linear Unit*), ELU (por sus siglas en inglés *Exponential Linear Unit*) y Tangencial. En validación, los mejores resultados se adquieren con Leaky-ReLU, y Clipped-ReLU. En validación con DEAP, el mejor resultado se obtiene de Tangencial, ReLU y SoftPlus [86].

MODELO PROPUESTO

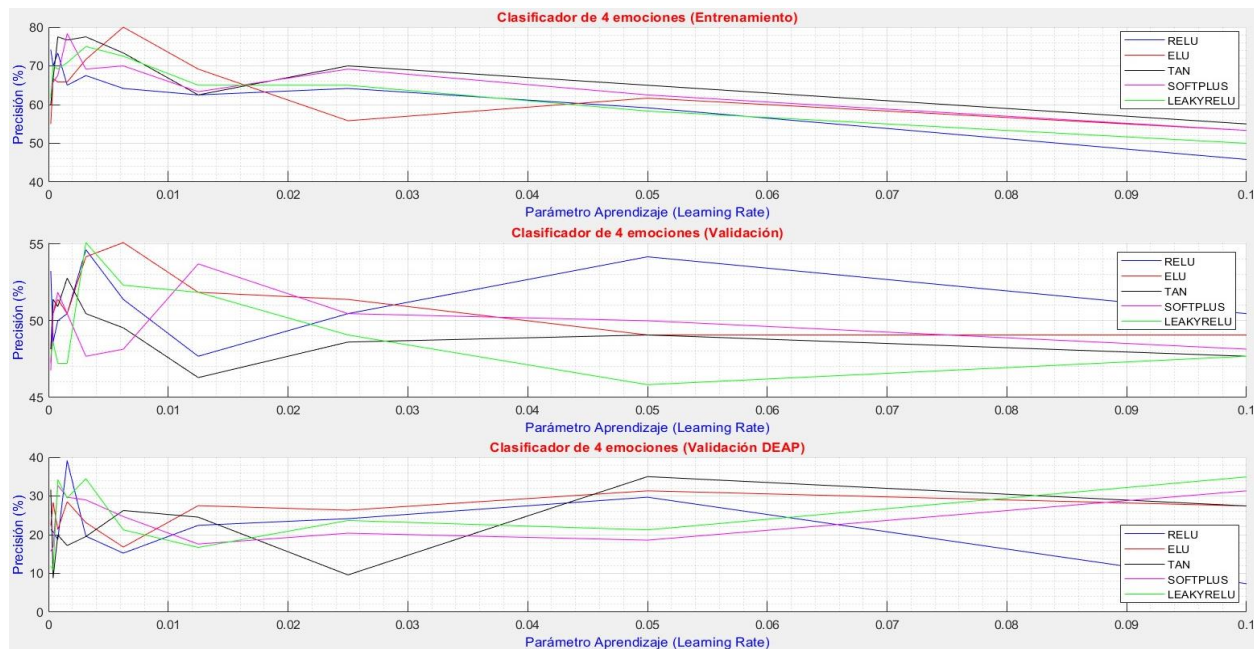


Figura 5.10 Precisión y función de activación implementada en clasificador de 4 emociones discretas

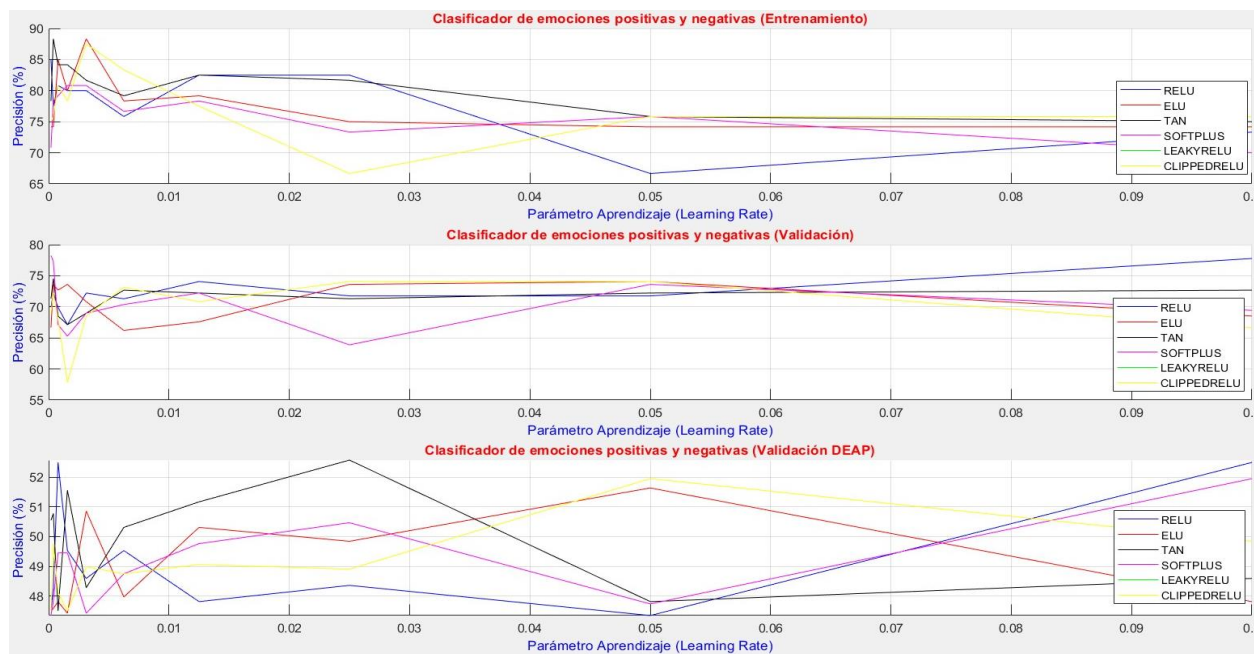


Figura 5.11 Precisión y función de activación implementada para emociones positivas y negativas




Figura 5.12 Precisión y función de activación implementada para emociones de neutralidad y felicidad




Figura 5.13 Precisión y función de activación implementada para emociones de tristeza y miedo

Como conclusión se pudo observar que las funciones de activación que presentan el mejor rendimiento son: ReLU, Leaky-ReLU y Soft-Plus. De entre las cuales, la que presenta mejor desempeño es Leaky-ReLU, mostrando un comportamiento más estable a lo largo del cambio del parámetro de aprendizaje, así como valores altos de precisión.

5.3.3.2 Inicialización de pesos

Existen diferentes técnicas para inicializar los pesos de los kernels de la CNN, entre ellos se encuentran: Glorot, He, Narrow-normal, ceros o unos [87]. Para el desarrollo de este trabajo se seleccionó la técnica de Kaiming He, presentada en 2015, la cual consiste en utilizar una distribución normal para la inicialización de pesos, luego se divide entre el número de elementos la entrada entre 2. Se considera que al utilizar una función ReLU, se están ignorando la mitad de los datos, por lo tanto, la varianza de los datos de entrada no corresponde con la varianza de los datos de salida. Es por esto, que en esta técnica de inicialización, se agrega un número 2 a la fórmula de inicialización de Glorot, y se considera que la desviación estándar de la distribución utilizada para inicializar se ve afectada por un factor definido por $\sqrt{\frac{2}{n_l}}$, obteniendo un esquema de inicialización descrito por la ecuación 5.2.

$$\omega_l \sim N_d \left(0, \frac{2}{n_l} \right) \quad (5.2)$$

Donde n_l representa la cantidad de pesos a modificar, ω_l la matriz de pesos a inicializar, considerando un valor de bias de cero y definida por una gaussiana (N_d) centrada en 0.

5.3.3.3 Tamaño de mini-lote

Para encontrar el tamaño apropiado de mini-lote, se realizó la prueba de variar el tamaño del mini-lote (*batch size*), iniciando con un valor de 10 y repitiendo el experimento 30 veces, por 500 épocas. En cada repetición, el tamaño del mini-lote cambia respetando la ecuación 5.3.

$$BS = BS + 10 \quad (5.3)$$

Donde BS representa el tamaño del mini-lote. Se definió el parámetro de aprendizaje en 0.01, y se conservó sin modificación hasta la época 350, donde se disminuye su valor un 50%. En la Figura 5.10 se presentan de manera gráfica los resultados de modificar únicamente el tamaño de mini-lote con el fin de observar el rango (o rangos) de mejor desempeño de la CNN. Para cada clasificador implementado, se muestra el resultado de entrenamiento, y validación con DEAP.




Figura 5.14 Comparación de valor del tamaño de mini-lote y precisión de cada clasificador

Se puede observar en las gráficas anteriores, que el comportamiento del modelo ante la variación del tamaño del mini-lote posee cambios poco bruscos y el mejor resultado se puede ver en el rango definido por $100 < BS < 250$.

Basado en lo anterior, se defiende la idea de utilizar un tamaño de mini lote de 120 unidades, con el fin de no perder definición en los resultados y disminuir el coste computacional generado por la complejidad del modelo, lo cual no afecta significativamente al mismo.

5.3.3.4 Optimizador

El siguiente experimento consistió en utilizar tres optimizadores distintos para el entrenamiento y validación mediante 30 pruebas con cada optimizador por 500 épocas. Los optimizadores fueron:

- Estimación de Momento Adaptivo (ADAM).
- Gradiente Estocástico Descendente con Momentum (SGMD).
- Propagación de la Raíz Cuadrada Media (RMSPROP).

Se definió el parámetro de aprendizaje en 0.1 para el optimizador de ADAM y SGMD, y 0.0001 para RMSPROP. En todos los casos, el parámetro de aprendizaje disminuye su valor un 50% después de 350 épocas.

En la Tabla 5.2 se observan los resultados obtenidos del experimento, donde se aprecia que utilizando la configuración de parámetros antes mencionada, el optimizador con mejor desempeño en entrenamiento y validación es ADAM. Esto concuerda con el experimento planteado por Luis Velasco en *Optimizadores en Redes Neuronales profundas: un enfoque práctico* [77], donde implementan diferentes optimizadores para una red poco profunda con diferentes aplicaciones, concluyendo que el optimizador ADAM presenta los mejores resultados de precisión, convergencia y estabilidad.

Tabla 5.2 Comparación de resultados al variar el optimizador implementado para entrenar la red

Clasificador	ADAM			SGDM			RMSPROP		
	Entrenamiento	Validación	Validación DEAP	Entrenamiento	Validación	Validación DEAP	Entrenamiento	Validación	Validación DEAP
Cuatro emociones	74.16	53.70	33.23	73.3	52.77	28.8	68.33	52.77	36.48
Positivas/negativas	87.50	75.0	52.03	83.33	74.53	51.32	82.50	78.70	49.37
Neutralidad/felicidad	100.0	100.0	76.15	100.0	100.0	73.19	100.0	100.0	78.28
Tristeza/miedo	80.83	59.25	61.16	76.66	55.55	61.75	67.50	54.62	61.90

5.3.3.5 Conclusiones

Luego de las diferentes modificaciones en la arquitectura y parámetros de la red, se observó que la arquitectura *Inception* modificada muestra resultados promedio más estables, obteniendo resultados de entrenamiento de 90.83% en clasificador de 4 emociones discretas, 95.93% en clasificador de emociones positivas, 100.0% en clasificador de emociones de neutralidad y felicidad, y 85.0% en clasificador de emociones de tristeza y miedo.

Como conclusión, la red diseñada consta de tres niveles de convolución paralelos, cada uno con dos convoluciones de distintas dimensiones, una etapa de aplanamiento, donde se ingresan los resultados a cada a una capa de *Fully Connected* (una para cada nivel). Los resultados de éstas se concatenan para entrar en una última capa *Fully Connected*, para luego pasar a la normalización exponencial y la etapa de clasificación. La red propuesta se puede observar en la Figura 5.15 y 5.16.

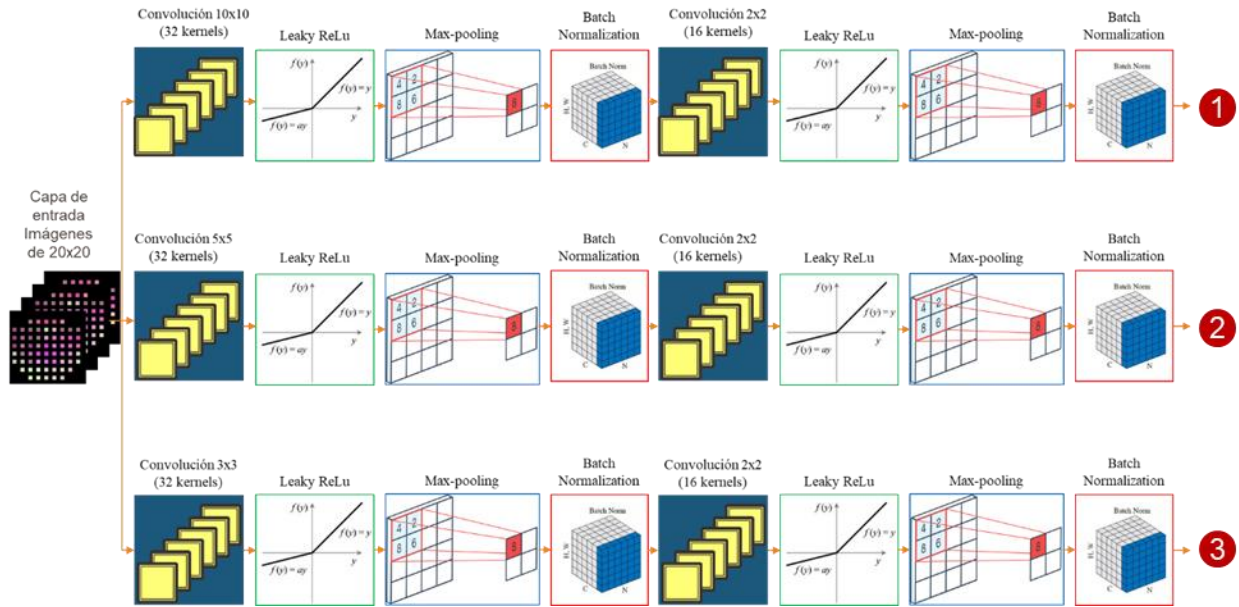


Figura 5.15 Propuesta de CNN D-Inception (parte 1)

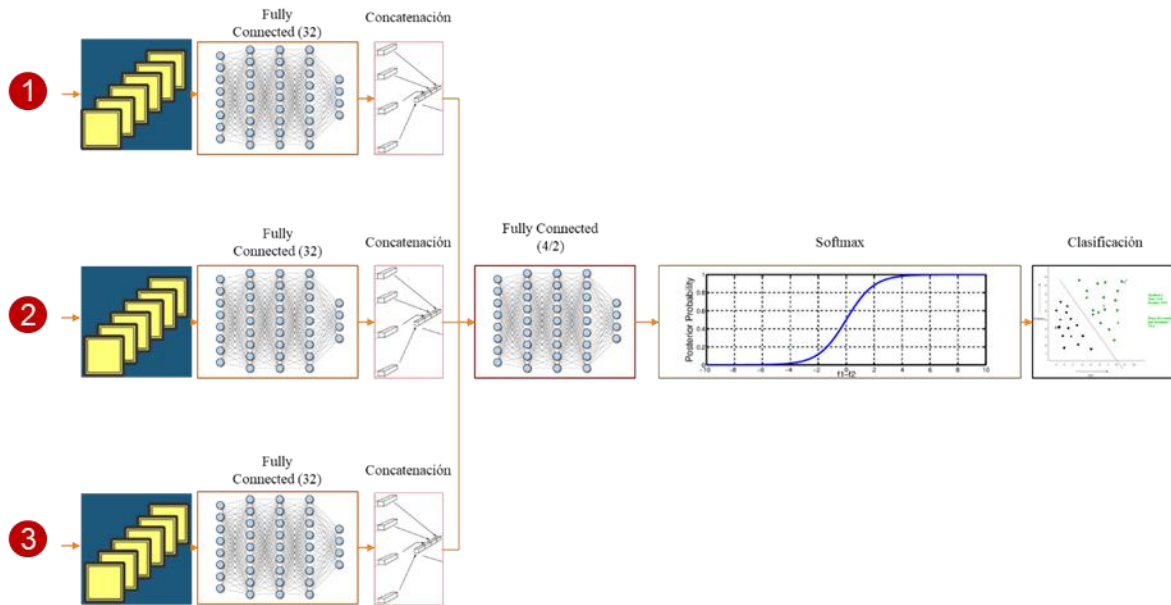


Figura 5.16 Propuesta de CNN D-Inception (parte 2)

5.3.3.6 Algoritmo final

En el diagrama de la Figura 5.15 y 5.16, se puede observar el modelo final de *D-Inception*, el cual se describe a continuación. La entrada está dada por $E_j(t)$, donde $j = \{AF3, AF4, F7, F8, F3, F4, FC5, FC6, T7, T8, P7, P8, O1, O2\}$, luego se realizó una normalización

de la señal utilizando la ecuación 5.1 para obtener $Q_j(t)$. Posteriormente, se aplicó un filtro pasa bandas con frecuencias de corte en 0.5Hz y 50Hz, obteniendo la señal resultante $S_j(t)$. Luego, se filtró la señal en 3 bandas de frecuencia, obteniendo la familia de señales definidas por $S_{\tau j}(t)$, donde $\tau = \{\alpha, \beta, \theta\}$. Después, se realizó la transformación al dominio de frecuencia con la FFT, obteniéndose $S_{\tau j}(f)$, donde f es el índice de frecuencia. Luego, se obtuvieron las características de la señal en el vector de características definido por $x_n(f) = \{ASM_{EDS}(S_{\alpha j}(f)), SE(S_{\beta j}(f)), TE(S_{\theta j}(f))\}$, donde n representa el número de muestra. Finalmente se estructuraron las imágenes de muestra como se representa en la Figura 5.9, obteniendo una imagen $I(r, c, v)$, donde r representa el número de fila, c representa el número de columna y v representa el canal.

La entrada de la red es $I(r, c, v)$ y, como se observa en la Figura 5.15 y 5.16, ésta tiene tres capas de convolución en el mismo nivel jerárquico, con 32 kernels, una de ellas con kernels de 10x10, otra de 5x5 y la tercera de 3x3, definidas por la ecuación 5.4.

$$Conv1_{r,c}^h = \sum_{r=1}^r \sum_{c=1}^c \sum_{a=1}^a \sum_{b=1}^b I(r+a-1, c+b-1) FILTRO_p(a, b) + \vartheta_1 \quad (5.4)$$

donde $FILTRO_p(a, b)$ representa el kernel a aplicar, y p representa el tamaño de kernel aplicado $p = \{3x3, 5x5, 10x10\}$, ϑ_1 representa el bias y h la rama de jerarquía con valores $h = \{1,2,3\}$.

Cada capa de convolución tiene enseguida una función de activación Leaky-ReLU definida por la ecuación 5.5.

$$M1_{r,c}^h = \max(0.1Conv1_{r,c}^h, Conv1_{r,c}^h) \quad (5.5)$$

donde $M1_{r,c}^h$ representa la salida de la función de activación que se ingresa a una operación de max-pooling de 2x2 definida por la ecuación 5.6.

$$MP_{r2,c2}^h = \max[M1_{r,c}^h, M1_{r+1,c}^h, M1_{r,c}^h, M1_{r,c+1}^h] \quad (5.6)$$

donde $MP_{r2,c2}^h$ representa la muestra luego de la reducción de dimensiones por max-pooling con una longitud de r2xc2. Luego se realiza una normalización por lotes definida por la ecuación 5.7.

$$BS_{r2,c2}^h = \frac{MP_{r2,c2}^h - \overline{MP_{r2,c2}^h}}{\sqrt{\sigma_{MP_{r2,c2}^h}^2 + \epsilon}} \quad (5.7)$$

donde $BS_{r2,c2}^h$ es la muestra normalizada por lotes de la rama jerárquica h , $\overline{MP_{r2,c2}^h}$ es el valor medio del lote, $\sigma_{MP_{r2,c2}^h}^2$ la varianza del lote y ϵ un valor arbitrario 0.001 para evitar divisiones entre cero.

Luego de haber normalizado, la muestra se propaga hacia adelante a otra capa de convolución descrita por la ecuación 5.8.

$$Conv2_{r3,c3}^h = \sum_{r=1}^{r2} \sum_{c=1}^{c2} \sum_{a=1}^2 \sum_{b=1}^2 BS(r+a-1, c+b-1) FILTRO_{p2}(a, b) + \vartheta_2 \quad (5.8)$$

Donde el tamaño de $FILTRO_{p2}(a, b)$ es igual para cualquier h , y ϑ_2 es el valor del bias. Luego se ingresa a una segunda función de activación Leaky-ReLU definida por la ecuación 5.9.

$$M2_{r3,c3}^h = \max(0.1Conv2_{r3,c3}^h, Conv2_{r3,c3}^h) \quad (5.9)$$

Después se ingresa a una reducción de dimensiones de 2x2 definida por la ecuación 5.10.

$$MP2_{r4,c4}^h = \max[M2_{r3,c3}^h, M2_{r3+1,c3}^h, M2_{r3,c3+1}^h, M2_{r3,c3}^h] \quad (5.10)$$

Luego se ingresa el resultado a una normalización por lotes descrita por la ecuación 5.11.

$$BS2_{r4,c4}^h = \frac{MP2_{r4,c4}^h - \overline{MP2_{r4,c4}^h}}{\sqrt{\sigma_{MP2_{r4,c4}^h}^2 + \epsilon}} \quad (5.11)$$

Luego de esta segunda normalización por lotes se ingresa el resultado de cada rama de jerarquía a una capa de “totalmente conectado” o “*Fully Connected*” definida para 4 clases, dada por la ecuación 5.12.

$$FC_4^h = BS2_{r4,c4}^h * FILTRO_{p3}(a, b) + \vartheta_3 \quad (5.12)$$

donde FC_4^h son los resultados de la capa *Fully Connected* de 32 neuronas en la capa oculta y 4 neuronas de salida, $FILTRO_{p3}(a, b)$ representa los pesos de las neuronas. Luego de esto se realizó una concatenación de los resultados de las tres ramas jerárquicas, para luego ingresarse a una capa de *Fully Connected* con 4 neuronas en la capa de salida definida por la ecuación 5.13.

$$FC2_4^{ne} = C[FC_4^h] * FILTRO_{p_4}(a, b) + \vartheta_4 \quad (5.13)$$

donde $C[FC_4^h]$ representa los resultados de las capas *Fully Connected* de cada rama jerárquica y $FILTRO_{p_4}(a, b)$ representa los pesos de las neuronas de la capa *Fully Connected*, y donde ne representa cada neurona de salida. Finalmente se pasa a una normalización exponencial (*Softmax*) para determinar el grado de probabilidad de pertenencia a cada clase, y está definida por la ecuación 5.14.

$$SM_{ne} = \frac{e^{FC2_4^{ne}}}{\sum_{ne=1}^4 e^{FC2_4^{ne}}} \quad (5.14)$$

Donde cada elemento de SM_{ne} define el probabilidad de pertenencia a cada una de las cuatro emociones a clasificar. El resultado de esta capa entrega un valor de clasificación. El esquema final del modelo se presenta en la Figura 5.17.




Figura 5.17 Método basado en D-Inception.

CAPÍTULO 6. RESULTADOS

Este capítulo presenta los resultados obtenidos de la implementación de *D-Inception*. Para ello, se mostrarán los valores obtenidos de las métricas de evaluación, la comparación con otros métodos de la literatura, análisis de las activaciones de la red ante muestras de entrada para clasificación y finalmente, una validación cruzada.

6.1 Obtención de métricas de evaluación

Para caracterizar la respuesta del sistema ante nuevas muestras de entrada, se realizó un análisis del desempeño de *D-Inception* con las métricas de *exactitud*, *precisión* y *sensibilidad* dadas por:

$$Exactitud = \frac{Verdaderos\ Positivos + Verdaderos\ Negativos}{Falsos\ Positivos + Falsos\ Negativos + Verdaderos\ Positivos + Verdaderos\ Negativos} \quad (6.1)$$

Exactitud mide la cantidad de muestras correctamente clasificadas entre el total de muestras (ecuación 6.1).

$$Precisión = \frac{Verdadero\ Positivo}{Verdadero\ Positivo + Falso\ Positivo} \quad (6.2)$$

Precisión es la razón de verdaderos positivos contra todas las muestras que resultaron positivas (ecuación 6.2). Esta métrica mide cuantas muestras estuvieron mal detectadas como positivas.

$$Sensibilidad = \frac{Verdadero\ Positivo}{Verdadero\ Positivo + Falso\ Negativo} \quad (6.3)$$

Sensibilidad es la razón de verdaderos positivos contra todas las muestras que realmente son positivas (ecuación 6.3). Esta métrica mide cuantas muestras estuvieron mal detectadas como negativas.

La Tabla 6.1 muestra los resultados de *exactitud* para el clasificador de emociones discretas. Se observa que el valor de exactitud es mayor al clasificar la felicidad, lo que concuerda con lo encontrado en la literatura. La emoción más baja en *exactitud* al momento de clasificar es la neutralidad, en la que hay mayor cantidad de falsos negativos que de falsos positivos. Esto significa que es más susceptible de identificar cuándo no se presenta dicha emoción, que detectar cuándo si se manifiesta.

Tabla 6.1 Resultados obtenidos en entrenamiento

RESULTADOS

Emoción discreta	Exactitud (%)	Verdaderos Positivos	Verdadero Negativo	Falso Positivo	Falso Negativo
Neutralidad	69.77	187	757	47	81
Tristeza	85.44	229	709	95	39
Miedo	74.25	199	755	49	69
Felicidad	99.25	266	804	0	2

La Tabla 6.2 muestra los resultados de *sensibilidad* y *precisión* de clasificación para cada emoción.

Tabla 6.2 Métricas de exactitud, sensibilidad y precisión

Emoción discreta	Precisión (%)	Sensibilidad (%)	Exactitud (%)
Neutralidad	88.06	69.78	69.78
Tristeza	87.50	85.45	85.45
Miedo	88.99	74.25	74.25
Felicidad	99.81	99.25	99.25

Dado que el entrenamiento de la red se realizó con clases equilibradas, la métrica de *exactitud* posee información útil para la caracterización del modelo. Presenta información general sobre la capacidad de clasificar correctamente. Los resultados de clasificación por emoción muestran resultados de *exactitud* por encima del 87%, lo que indica que el modelo clasifica correctamente las emociones discretas. En referente a *precisión*, se tienen resultados por encima del 74% para tristeza, miedo y felicidad. En referente a *sensibilidad* se tienen resultados por encima del 74% para tristeza, miedo y felicidad, mientras que para neutralidad se encuentra por debajo del 70%.

Para caracterizar el funcionamiento de *D-Inception* se obtuvieron los resultados de precisión de clasificación en entrenamiento, validación, tiempo de entrenamiento y la cantidad de operaciones a realizar, los cuales se observan en la Tabla 6.3.

Tabla 6.3 Resultados de precisión y características de los resultados

MODELO PROPUESTO				
Clasificador	Tiempo de entrenamiento	Precisión de entrenamiento	Precisión de validación	Cantidad de operaciones

RESULTADOS

4 emociones discretas	11min 54s	90.83%	51.85%	173,524
Positivas/negativas	42min 47s	95.83%	66.20%	173,330
Neutralidad/felicidad	18min 29s	100.0%	100.0%	173,330
Tristeza/miedo	4min 42s	85.0%	43.52%	173,330

6.2 Comparación de modelos

En esta subsección se muestra la comparación de *D-Inception* con los modelos presentes en la literatura. Para realizar esta comparación, se seleccionaron los métodos de reconocimiento de emociones con EEG sin importar el tipo de clasificador, las características o las técnicas de preprocesamiento utilizadas. La comparación se estructura en tres tablas: la primera de ellas presenta los métodos basados en el modelo discreto, la segunda los métodos basados en el modelo semi-discreto (emociones positivas y negativas o neutrales) y la tercera es una comparación de *D-Inception* con los métodos de reconocimiento de emociones más populares en la literatura.

En la Tabla 6.4 se puede observar una comparación de los métodos presentes en la literatura que utilizan emociones discretas. Se puede ver que el modelo propuesto posee el primer lugar de precisión en la primera base de datos de SEED-IV con un valor de 90.83%, mientras los modelos de la literatura utilizan bases de datos diseñadas por ellos mismos. Por otro lado, *D-Inception* es el único método que se mide en una segunda base de datos (DEAP).

Tabla 6.4 Comparación de modelos de clasificación de emociones discretas

Modelo	Precisión (%)	
	Primera base de datos	Segunda base de datos
[33]	82.29	NA*
[48]	55.75	NA
[49]	44.4	NA
[37]	56.2	NA
[40]	60	NA
[41]	83.34	NA
[56]	66.67	NA
[58]	78	NA
<i>D-Inception</i>	90.83	51.85

* No aplica (NA)

En la Tabla 6.5 se muestra la comparación de *D-Inception* con los diferentes modelos de reconocimiento de emociones semi-discretas. En los resultados obtenidos con la primera base de datos (donde 4 de los 6 modelos utilizan la base de datos SEED) el modelo *D-Inception* obtuvo el

RESULTADOS

valor más alto de precisión con 95.83%. En la segunda base de datos el modelo *D-Inception* obtuvo un valor de precisión 66.2%, utilizando la base de datos DEAP. Como se puede observar, *D-Inception* tiene un valor más bajo que [44] lo cual se debe a que la base de datos DEAP posee muestras etiquetadas en el modelo dimensional principalmente, debiendo hacerse una transformación de las etiquetas para reinterpretarlas, y *D-Inception* se especializa en el modelo discreto.

Tabla 6.5 Comparación de modelos de clasificación de emociones semi-discretas

Modelo	Precisión (%)	
	Primera base de datos	Segunda base de datos
[46]	86.2	NA
[51]	80.25	NA
[44]	69.67	91.07
[55]	82	NA
[59]	86.65	NA
<i>D-Inception</i>	95.83	66.2

En la Tabla 6.6 se muestra la comparación de *D-Inception* con los métodos más populares en la literatura para reconocimiento de emociones en general, pues no se considera el modelo de emociones en el que se trabaja, sino únicamente los resultados de precisión obtenidos. El modelo *D-Inception* ocupa el segundo lugar en valor de clasificación con la base de datos SEED, y el cuarto lugar con la base de datos DEAP. El cuarto lugar se ocupa debido a la estructura de la base de datos DEAP, la cual presenta las muestras etiquetadas con el modelo dimensional y también con etiquetas de modelo discreto con 16 emociones distintas, por lo que una correlación entre las emociones manejadas por la base de datos y las que maneja *D-Inception* fue necesaria.

Tabla 6.6 Comparación de modelos de clasificación de emociones general

Modelo	Precisión(%)		
	1ª base de datos	2ª base de datos	3ª base de datos
[32]	90.4	85.26	NA
[33]	82.29	NA	NA
[34]	76.52	NA	NA
[47]	88	62	68
[48]	55.75	NA	NA
[45]	84.5	NA	NA
[49]	44.4	NA	NA
[35]	86.75	NA	NA

RESULTADOS

[46]	86.2	NA	NA
[50]	83.55	NA	NA
[36]	80.32	NA	NA
[37]	56.2	NA	NA
[38]	90	NA	NA
[39]	86.3	NA	NA
[51]	80.25	NA	NA
[52]	80	NA	NA
[40]	60	NA	NA
[41]	83.34	NA	NA
[42]	82	NA	NA
[44]	69.67	91.07	NA
[53]	80	NA	NA
[54]	86.36	NA	NA
[55]	82	NA	NA
[43]	82.11	NA	NA
[56]	66.67	NA	NA
[24]	94.4	NA	NA
[57]	70.9	NA	NA
[58]	78	NA	NA
[59]	86.65	NA	NA
[60]	63	NA	NA
[61]	45	NA	NA
[62]	62.33	NA	NA
<i>D-Inception</i>	93.33	59.02	NA

6.3 Análisis final de activaciones

Para conocer cómo funcionan estas líneas de análisis y conocer a fondo la manera en cómo trabaja *D-Inception*, esta sección presenta un análisis de las activaciones del bloque de extracción de características. Éste se realizó por línea de análisis (por cada rama de convolución de la red) y finalmente se unificó el resultado para observar la concatenación de la red. El análisis considera las capas que se muestran en la Figura 5.15, donde cada línea tiene dos capas de convolución, dos de funciones de activación y dos normalizaciones por lote. Además, en el análisis de activaciones se muestran ejemplos del procesamiento de cada emoción para conocer el patrón de características que genera cada emoción en *D-Inception* en su salida.

En la Figura 6.1 (a) se presentan las activaciones obtenidas al aplicar la primera capa con kernels de 10x10 en cada una de las muestras de cada emoción. Se puede notar que los patrones

RESULTADOS

extraídos son similares entre cada emoción, y algunas activaciones tienen poca actividad (por ejemplo, el kernel encerrado en el recuadro rojo). Sin embargo, los kernels encerrados en el recuadro azul extraen información sobre los electrodos, lo cual es de mayor importancia que la información que pueda obtenerse del fondo de la imagen de muestra. En la Figura 6.1 (b) se observa la salida de la Leaky-ReLU, que obtiene mayor activación en las zonas donde se presenta información sobre los electrodos. En la Figura 6.1 (c) se muestra la normalización por lote, donde se puede notar que los kernels en el recuadro verde poseen la mayor variación de activación sobre cada emoción.




Figura 6.1 Primera línea de análisis, convolución 10x10 (a), primera función de activación (b) y primera normalización por lote (c)

En Figura 6.2 (a) se muestran los resultados de la segunda capa de convolución, con kernels de 2x2, en la Figura 6.2 (b), la segunda función Leaky-ReLU y en la Figura 6.2 (c), la segunda

normalización por lote. En esta segunda activación, se puede observar que la emoción de felicidad genera mayor magnitud en las activaciones (kernels con recuadro rojo). La emoción de miedo es la segunda con mayor magnitud de activación, seguida por la neutralidad y finalmente la tristeza. En la salida de la función de activación se muestra que los kernels encerrados en color verde conservan la activación más relevante. Finalmente, en la normalización por lote, la activación de mayor magnitud se presenta en los recuadros de color azul, quienes pueden diferenciar entre distintas emociones, pues la activación es distinta en cada emoción.

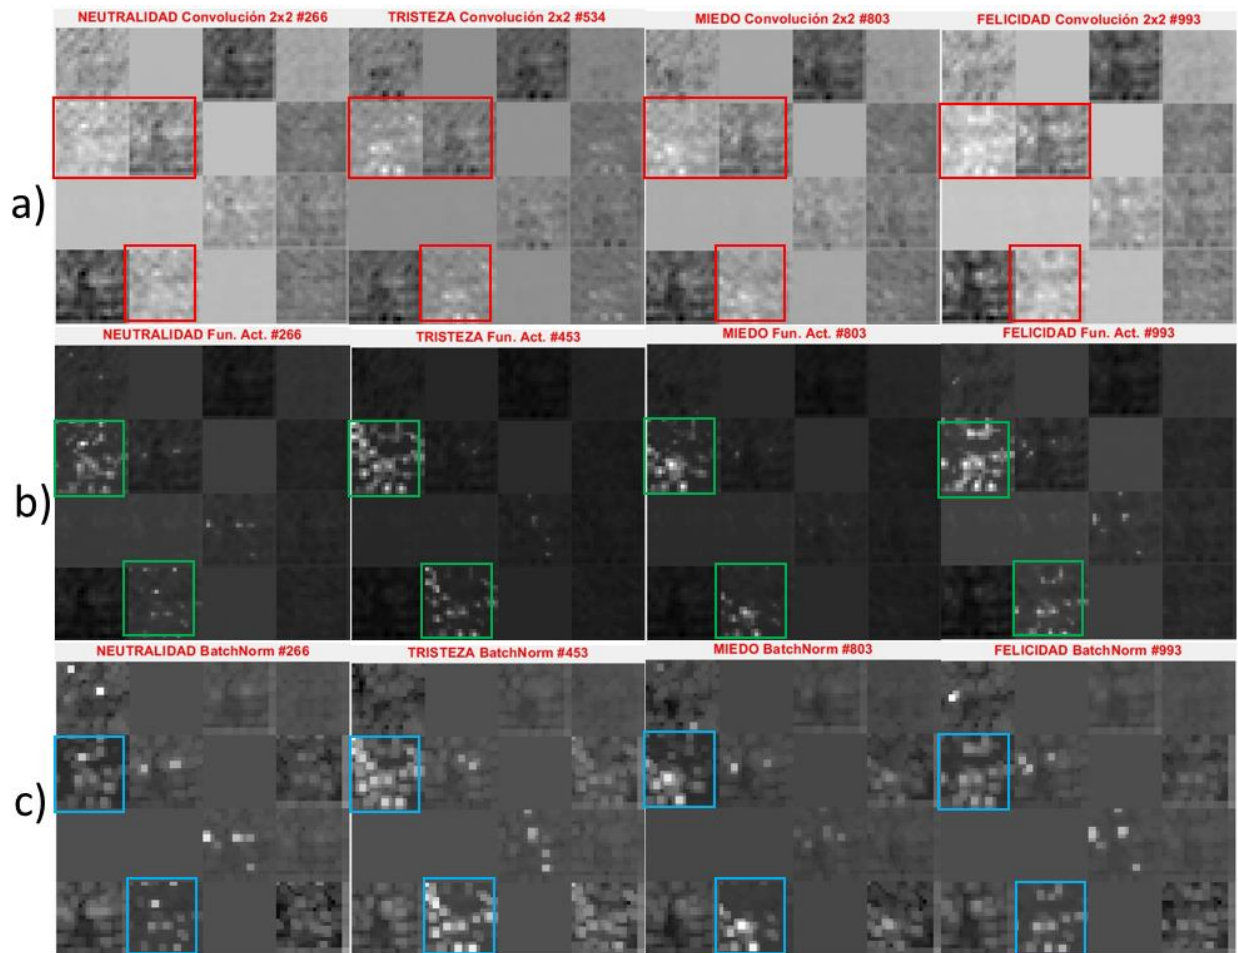


Figura 6.2 Primera línea de análisis, convolución 2x2 (a), segunda función de activación (b) y segunda normalización por lote (c)

En la Figura 6.3 (a) se muestra la primera convolución de la segunda línea de análisis, que tiene kernels de 5x5, la Figura 6.3 (b) presenta la salida de la primera función de activación y la Figura 6.3 (c) ilustra la salida de la normalización por lotes. La primera convolución extrae información

principalmente de los electrodos como se muestra en los recuadros rojos, aunque también se presentan ventanas con información sobre el fondo. En la primera función de activación de esta segunda línea de análisis se conserva únicamente información sobre los electrodos, descartando información del fondo como aparece en los recuadros verdes. La salida de la normalización por lote muestra la extracción de información contenida en los electrodos, donde no se presenta una diferencia significativa en las activaciones presentes, tal como se muestra en los recuadros azules.




Figura 6.3 Segunda línea de análisis, convolución 5x5 (a), primera función de activación (b) y primera normalización por lote (c)

En la Figura 6.4 (a), el resultado de la segunda capa convolución de un kernel de 2x2, la Figura 6.4 (b) la función de activación y en la Figura 6.4 (c), la salida de la normalización por lote. La convolución muestra las activaciones contenidas en los electrodos en los recuadros rojos. En la función de activación, las ventanas en color verde presentan la información del fondo, mientras

que en las ventanas en color amarillo obtienen información más particular de los electrodos, lo que es más significativo para la clasificación.




Figura 6.4 Segunda línea de análisis, convolución 2x2 (a), segunda función de activación (b) y segunda normalización por lote (c)

En la Figura 6.5 (a) se muestra el resultado de la primera convolución de la tercera línea, que tiene kernels de 3x3. La Figura 6.5 (b) presenta una función de activación y Figura 6.5 (c), una normalización por lote. Se puede observar que la convolución extrae la información sobre los electrodos, ilustrada en los recuadros rojos. La función de activación conserva las activaciones sobre la información de los electrodos como se muestra en los recuadros verdes. Finalmente, la normalización extrae información sobre los electrodos a distinta magnitud, cada uno de ellos entregando algo de información como aparece en los recuadros azules.

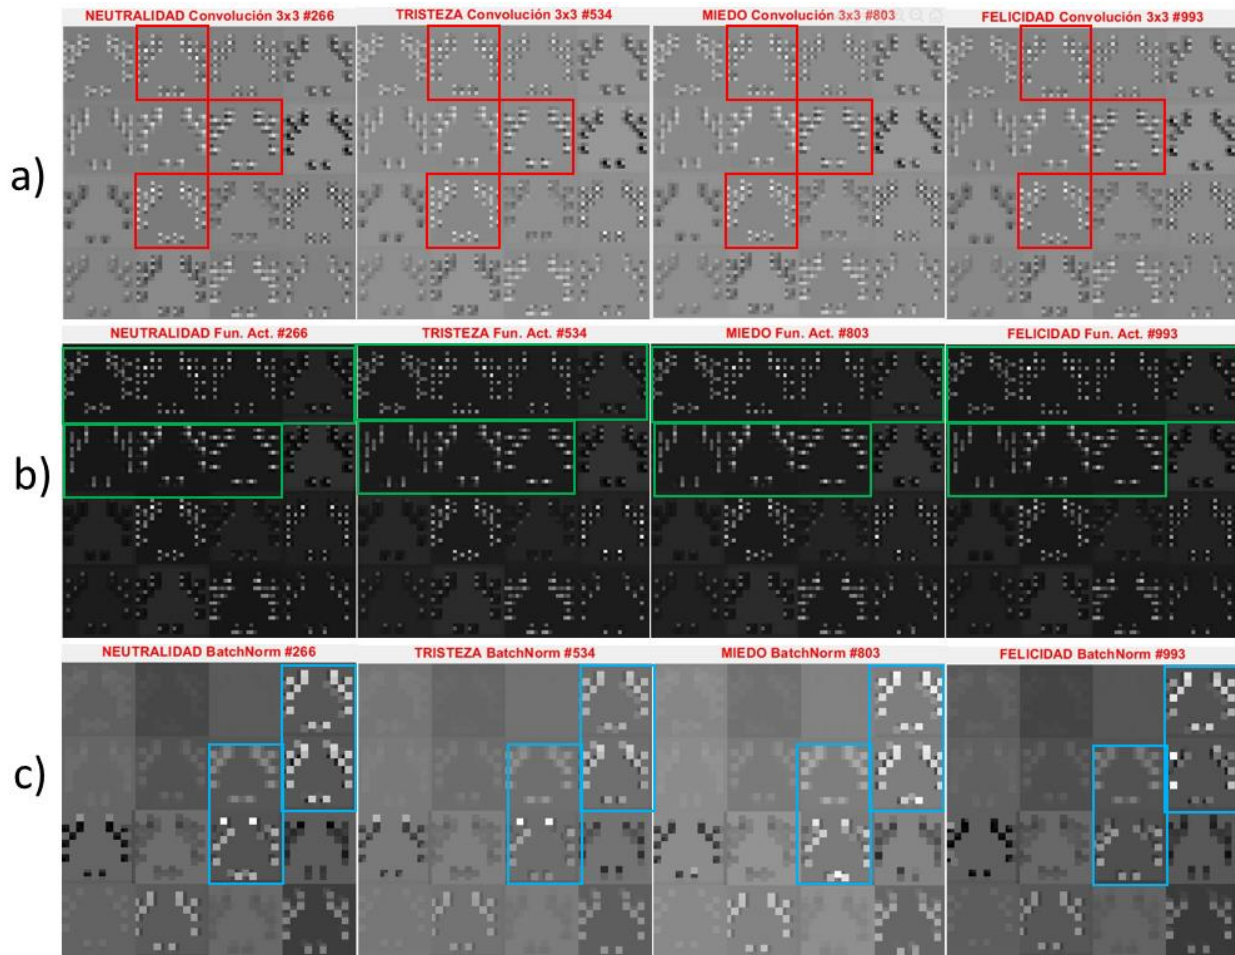


Figura 6.5 Tercera línea de análisis, convolución 3x3 (a), primera función de activación (b) y primera normalización por lote (c)

Al final de las tres líneas de activación, se realiza una concatenación, una función de activación y una normalización exponencial. La última función de activación entrega resultados como los mostrados en la Figura 6.6, donde se aprecia el patrón generado por cada una de las emociones. La figura representa las cuatro clases posibles y la activación de cada una de ellas según la clasificación. De donde se puede inferir que al momento de clasificar la emoción de neutralidad (Figura 6.6 (a)) hay dificultad para realizar la separación entre ellas, mayormente, entre la emoción de neutralidad y miedo (Figura 6.6 (c)). Al momento de clasificar la emoción de tristeza (Figura 6.6 (b)) sigue habiendo cierto grado de confusión entre el miedo y la tristeza. Para clasificar la emoción de miedo, la dificultad de clasificación es aún mayor, pues se confunden las tres primeras clases. Sin embargo, y como ya se ha visto en la precisión del modelo, la clasificación de felicidad (Figura 6.6 (d)) es más certera, no habiendo confusión entre la misma y las otras emociones.




Figura 6.6 Función de activación final

6.4 Análisis sobre el cambio de valores de kernel

En el diseño de redes neuronales, es importante verificar si la red está realmente aprendiendo o solamente memorizando, así como analizar si los valores de los kernels de las capas convolucionales están siendo optimizados. Una forma de realizar este análisis, es revisar la magnitud del cambio de peso de una época a otra para conocer los cambios de los valores. Por ejemplo, si los valores de los pesos son cercanos a cero, la red aprende de manera limitada, o bien, si son valores de los kernels tienen valores diferentes entre sí, significa que el kernel está aprendiendo y se puede llegar a un momento en que los pesos se optimicen. Por ello, se realizó un experimento para conocer cómo fueron cambiando los pesos de los kernels en 500 épocas.

El análisis se realizó con base en la modificación de los pesos de los kernels, no considerando las magnitudes de los kernels. La obtención de los valores se realizó por medio de una resta aritmética, conservando el signo de la magnitud de la diferencia, para observar el cambio del mismo de una época a otra. Considerando que tanto $Conv1_{r,c}^1$, $Conv1_{r,c}^2$ y $Conv1_{r,c}^3$ poseen 32 kernels de convolución cada uno, entonces se realizó el análisis para cada uno. De igual manera se realizó el análisis para $Conv2_{r3,c3}^1$, $Conv2_{r3,c3}^2$ y $Conv2_{r3,c3}^3$ considerando que poseen 16 kernels de convolución cada una. La variación de los valores a lo largo del entrenamiento prueba que la red continúa aprendiendo.

La Figura 6.7 muestra la modificación de pesos en $Conv1_{r,c}^1$, donde se aprecia en los recuadros rojos algunas de las distribuciones muy concentradas en el valor de cero (sin mucha modificación), mientras que en los recuadros de color verde se observan algunos de los kernels con mayor variación de pesos.

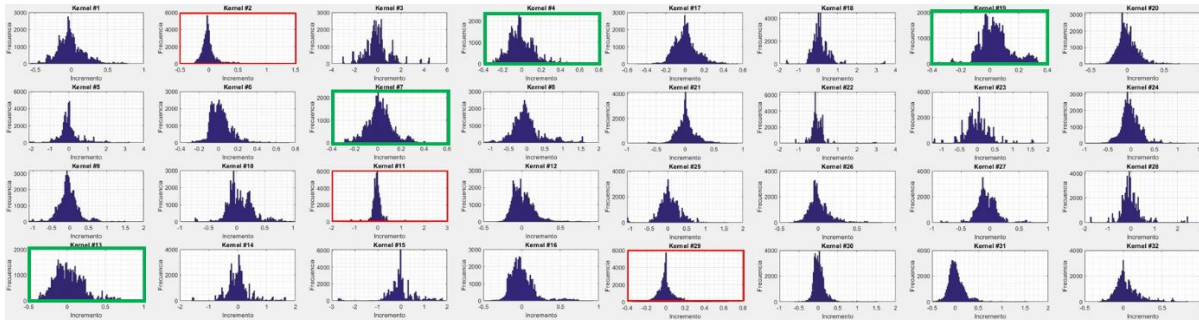


Figura 6.7 Cambio de pesos en $Conv1^1_{r,c}$

La Figura 6.8 muestra los cambios de pesos en cada kernel presente en $Conv1^2_{r,c}$, donde se aprecia que los cambios son variados en la mayoría de los kernels (por ejemplo, los encerrados en recuadro verde), únicamente con un kernel con poca variación (recuadro rojo).

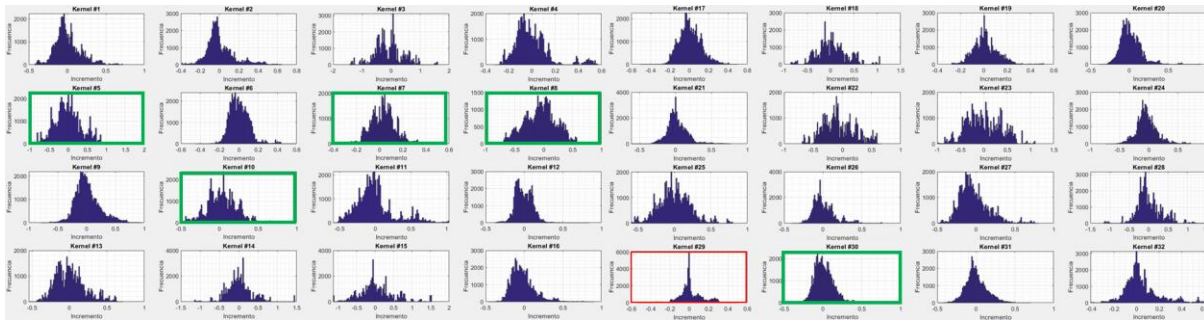


Figura 6.8 Cambio de pesos en $Conv1^2_{r,c}$

En la Figura 6.9 se muestra la modificación de pesos en $Conv1^3_{r,c}$, donde se aprecian los cambios considerables de los pesos (recuadros verdes), mientras que en otros kernels (recuadros rojos) presentan cambios poco significativos en el entrenamiento.

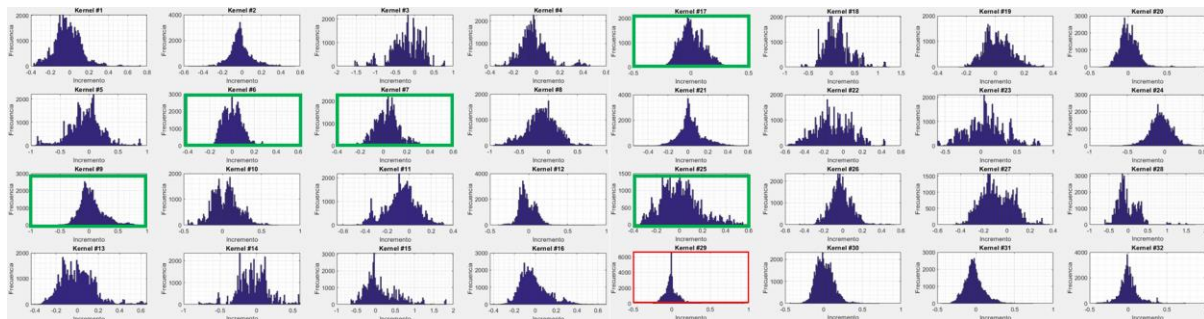


Figura 6.9 Cambio de pesos en $Conv1^3_{r,c}$

RESULTADOS

El siguiente punto de análisis se sitúa en $Conv2_{r3,c3}^1$ mostrado en la Figura 6.10, donde se aprecia en los recuadros rojos aquellos kernels que mostraron variación en sus pesos durante el entrenamiento sin estabilizarse en un solo valor final. La diferencia entre los kernels de $Conv_{r,c}^h$ y $Conv2_{r3,c3}^1$ se encuentra en la cantidad de pesos a actualizar, por eso es tan notable la diferencia de densidad de los datos.

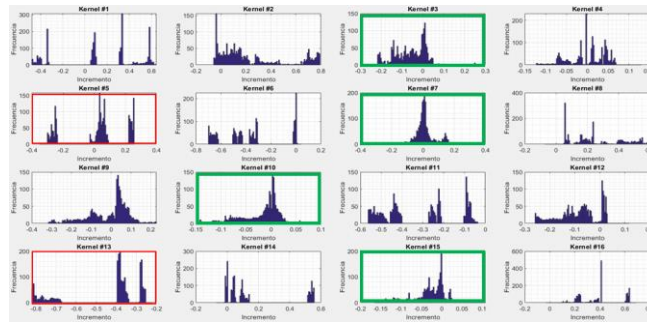


Figura 6.10 Cambio de pesos en $Conv2_{r3,c3}^1$

En la Figura 6.11 se puede observar en recuadro rojo aquellos kernels de $Conv2_{r3,c3}^2$ que estuvieron variando mayormente, mientras que de color verde aparecen aquellos que ajustaron a algún valor con menor variación.

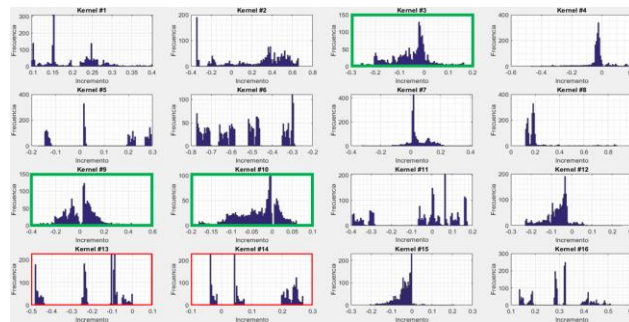


Figura 6.11 Cambio de pesos en $Conv2_{r3,c3}^2$

Finalmente, en la Figura 6.12 se observan los cambios en $Conv2_{r3,c3}^3$, en los recuadros rojos se observan los kernels con menor variación, mientras que en recuadro verde aparecen aquellos kernels con mejor ajuste de valores a lo largo del entrenamiento.

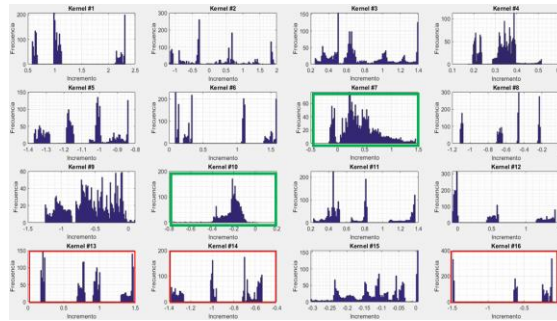


Figura 6.12 Cambio de pesos en $Conv2_{r3,c3}^3$

Puede observarse que en la segunda convolución, la modificación de pesos es menos variada, teniendo incrementos de magnitud proporcionales con algunos kernels donde la variación es bien distribuida.

6.5 Análisis de D-Inception por validación cruzada

La técnica de validación cruzada o *cross-validation* se utiliza para evaluar los resultados de un análisis estadístico para conocer qué tan independiente es el aprendizaje de la red respecto a la partición entre datos de entrenamiento y prueba. Consiste en repetir y calcular la media aritmética obtenida de las medias de evaluación sobre diferentes particiones. El proceso de la validación cruzada que se utilizó en esta tesis es *K-fold* definida en [89]. Esta forma de hacer la validación se seleccionó debido a que consigue una estimación precisa del error de entrenamiento, debido a un mejor balance entre los valores del bias y la varianza. Cuando se utiliza la validación cruzada dejando fuera uno, se utilizan $R - 1$ observaciones para entrenar el modelo (donde R representa la cantidad total de muestras de entrenamiento), lo que es prácticamente todo el set de datos disponible menos uno, maximizando así el ajuste del modelo a los datos disponibles y reduciendo el bias. Sin embargo, para la estimación final del error se promedian las estimaciones de los n modelos entrados con, prácticamente, los mismos datos (sólo hay un dato de diferencia en cada entrenamiento), por lo que están altamente correlacionados. Esto se traduce en un mayor riesgo de sobre-entrenamiento y, por lo tanto, de varianza. En la técnica de K iteraciones, los grupos empleados como entrenamiento son mucho menos solapantes, lo que se traduce en menor varianza al promediar las estimaciones de error

RESULTADOS

El primer experimento se realizó con un valor de $K=10$, con un total de 26 muestras por cada subconjunto de cada clase. Presentando un promedio aritmético de 82.74% en entrenamiento y 52.68% en validación, el cual se puede observar en la Tabla 6.7.

Tabla 6.7 Validación cruzada con $K=10$

Validación cruzada con $K=10$		
Iteración K	Precisión en entrenamiento (%)	Precisión en validación (%)
1	87.50	56.73
2	88.33	52.88
3	70.83	51.92
4	100.0	48.07
5	70.0	50.0
6	75.83	54.80
7	84.16	55.76
8	100.0	49.03
9	83.33	56.73
10	67.50	50.96

Para el caso de implementar la técnica con un valor de $K=5$, se tiene que cada subconjunto de cada clase posee 53 muestras, obteniendo una media aritmética de 85.83% para entrenamiento y 51.77% para validación. Los resultados se pueden ver en la Tabla 6.8.

Tabla 6.8 Validación cruzada con $K=5$

Validación cruzada con $K=5$		
Iteración K	Precisión en entrenamiento (%)	Precisión en validación (%)
1	95.83	49.52
2	70.0	50.94
3	100.0	53.77
4	67.50	50.41
5	95.83	54.24

Se optó por implementar la validación cruzada con un valor de $K=3$, donde cada subconjunto de cada clase posee 89 muestras, con un valor de precisión en entrenamiento de 87.77%, mientras que para validación se tiene un valor de 53.23%. Los resultados se pueden ver en la Tabla 6.9.

RESULTADOS

Tabla 6.9 Validación cruzada con K=3

Validación cruzada con K=3		
Iteración K	Precisión en entrenamiento (%)	Precisión en validación (%)
1	100.0	54.77
2	83.33	52.42
3	80.0	52.52

Finalmente, se implementó la técnica con un valor de K=20, en la cual, cada subconjunto de cada clase posee un total de 13 muestras, presentando un valor de precisión en entrenamiento de 82.54%, mientras que para validación presenta un valor de 53.93% de precisión. Los resultados se pueden ver en la Tabla 6.10.

Tabla 6.10 Validación cruzada con K=20

Validación cruzada con K=20		
Iteración K	Precisión en entrenamiento (%)	Precisión en validación (%)
1	83.33	55.76
2	100.0	53.84
3	85.0	50.0
4	100.0	50.0
5	60.0	55.76
6	60.0	50.0
7	83.33	50.0
8	90.0	50.0
9	85.33	50.0
10	80.0	51.92
11	70.833	57.69
12	58.33	57.69
13	62.50	67.30
14	92.5	50.0
15	100.0	57.69
16	86.66	53.84
17	99.16	59.61
18	100.0	56.61
19	67.50	48.07

RESULTADOS

20	86.66	53.84
----	-------	-------

Los resultados que se obtuvieron en este experimento muestran que la red está aprendiendo de manera independiente a las muestras, entregando resultados similares aún y cuando se varía el subconjunto a utilizar. El resultado presente indica un entrenamiento apropiado de la red, como se muestra en la Tabla 6.11.

Tabla 6.11 Resumen de resultados de validación cruzada

Valor de K	Precisión promedio en entrenamiento	Precisión promedio en validación
20	82.54%	53.93%
10	82.74%	52.68%
5	85.83%	51.77%
3	87.77%	53.23%

CAPÍTULO 7. CONCLUSIONES Y TRABAJO FUTURO

Se diseñó un método de reconocimiento de emociones discretas con EEG basándose en un análisis de los algoritmos presentes en la literatura. El método se divide en tres etapas: preprocesamiento, extracción de características, y clasificación. Para la clasificación se diseñó una Red Neuronal Convolutiva (CNN) que recibe como entrada una muestra bidimensional de tres canales, donde el primer canal corresponde a la característica de ASM_{EDS} de la banda α , el segundo canal corresponde a la SE de la banda β y el tercer canal corresponde a TE de la banda θ . La red utilizada es una variante de *Inception* que se denomina *D-Inception* y consiste en agregar otra capa de convolución, función de activación y normalización por lotes en cada rama jerárquica para finalmente concatenar los resultados e ingresar a otra capa *Fully Connected*. *D-Inception* clasifica 4 emociones discretas: neutralidad, tristeza, miedo y felicidad. Se utilizó la base de datos SEED para entrenamiento, y la base de datos DEAP para validación del modelo. La primera base de datos posee señales clasificadas en 4 emociones discretas, mientras que la segunda base de datos presenta las señales clasificadas en el modelo dimensional, requiriendo un mecanismo de discretización de emociones.

D-Inception fue evaluada en función de precisión de clasificación de las 4 emociones, así como la precisión en la clasificación de emociones positivas-negativas, neutralidad-felicidad y tristeza-miedo. De acuerdo a los resultados, *D-Inception* presenta una precisión de clasificación de 99.81% para la emoción de felicidad, 88.99% para miedo, 87.50% para tristeza y 88.06% para neutralidad.

Se realizó también un análisis de las activaciones de los kernels de la red, con el fin de encontrar la información que se procesa durante la extracción de características. De acuerdo a este análisis, se puede concluir que las características procesadas son suficientes para hacer la clasificación de las emociones discretas. Esto no solo permite generar buenos resultados por emoción, también apoya la concepción de las emociones como elementos únicos e independientes, no meramente dimensionales. También se demuestra que las señales EEG son muy útiles para describir, analizar y clasificar los procesos emocionales del ser humano.

El modelo *D-Inception* se posiciona como el segundo mejor método de reconocimiento de emociones con EEG, cuyo valor de precisión es el más alto entre los modelos de la literatura que

clasifican emociones discretas. El método propuesto reporta un tiempo de procesamiento y complejidad computacional menor que el presente en la literatura debido a que *D-Inception* utiliza 14 electrodos para extraer la información en frecuencia requerida para la clasificación. Además, cuestiona la funcionalidad de aquellos algoritmos basados en el modelo dimensional, ya que éstos involucran en las etiquetas de sus muestras el componente subjetivo en gran manera, utilizando cuestionarios psicológicos para la caracterización de cada señal, mientras que *D-Inception* utiliza las etiquetas de las señales, no según la percepción de cada sujeto, sino la señal obtenida en cada experimento.

Como trabajo a futuro, es necesario formalizar un mecanismo de discretización para realizar la evaluación del modelo propuesto en diferentes bases de datos que usan el modelo dimensional. También, es necesario incrementar la separabilidad de las emociones, como en el caso de la neutralidad, la cual presenta dificultad para ser clasificada correctamente. Otro aspecto a considerar es que se deben crear más bases de datos con emociones discretas para evaluar métodos en el modelo de emociones discretas. Con respecto a *D-Inception*, es necesario el uso de otra base de datos de emociones discretas para validar los resultados, así como simplificar la cantidad de operaciones considerando aquellos kernels que presentan poca activación.

REFERENCIAS

- [1] S. M. Alarcão and M. J. Fonseca, "Emotions Recognition Using EEG Signals: A Survey," in *IEEE Transactions on Affective Computing*, vol. 10, no. 3, pp. 374-393, 1 July-Sept. 2019.
- [2] J. Scheirer, R. Fernandez, J. Klein and R. Picard, "Frustrating the user on purpose: a step toward building and affective computer", *Interacting with computers*, vol. 14, no. 2, pp. 93-118, Feb. 2002.
- [3] E. Cambria, "Affective Computing and Sentiment Analysis", *IEEE Intelligent Systems*, vol. 31, no.2, pp. 102-107, Mar. 2016.
- [4] L. Nicolas-Alonso, J. Gomez-Gil, "Brain Computer Interfaces: A Review", *Sensors (Basel)*, pp. 1211-1279, Jan. 2012.
- [5] P. Podder, T. Khan, M. Khan and M. Rahman, "Comparative Performance Analysis of Hamming, Hanning and Blackman Window", *International Journal of Computer Applications*, vol. 96, no. 18, 2014.
- [6] V. Gandhi, "Brain-computer Interfacing for Assistive Robotics: Electroencephalograms", *Recurrent Quantum Neural Networks and User Centric Graphical Interfaces*, Academic Press, pp. 9-11, 2014.
- [7] N. Fernández, "Manual de laboratorio de fisiología", 6^a ed., McGRAW-HILL INTERAMERICANA EDITORES, 2015. [E-book]
- [8] Van de Laar B., Gurkok H., Plass-Oude B., Poel M. and A. Nijholt, "Experiencing BCI Control in a Popular Computer Game", *IEEE Transactions on Computational Intelligence and AI in Games*, vol. 5, no. 2, pp. 176-184, Mar. 2013.
- [9] V. Gandhi, G. Prasad, D. Coyle, L. Behera and T. McGinnity, "EEG-Based Mobile Robot Control Through an Adaptive Brain-Robot Interface", *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, vol. 44, no. 9, pp. 1278-1285, Apr. 2014.
- [10] A. Vourvopoulos and F. Liarokapis, "Robot Navigation Using Brain-Computer Interfaces", *IEEE 11th International Conference on Trust, Security and Privacy in Computing and Communications*, Jun. 2012.

- [11] Folgieri R., Lucchiari C., Granato M., Grechi D. (2014) Brain, Technology and Creativity. BrainArt: A BCI-Based Entertainment Tool to Enact Creativity and Create Drawing from Cerebral Rhythms. In: Lee N. (eds) Digital Da Vinci. Springer, New York, NY
- [12] K. D. Katyal *et al.*, "A collaborative BCI approach to autonomous control of a prosthetic limb system", 2014 IEEE International Conference on Systems, Man, and Cybernetics (SMC), pp. 1479-1482, 2014.
- [13] Göhring D., Latotzky D., Wang M., Rojas R., "Semi-autonomous Car Control Using Brain Computer Interfaces", Intelligent Autonomous Systems 12, Advances in Intelligent Systems and Computing, vol. 194, Springer, Berlin, Heidelberg.
- [14] D. W. Ng, Y. Soh and S. Goh, "Development of an Autonomous BCI Wheelchair", 2014 IEEE Symposium on Computational Intelligence in Brain Computer Interfaces (CIBCI), pp. 1-4, Jan. 2015.
- [15] M. Bockbrader *et al.*, "Brain Computer Interfaces in Rehabilitation Medicine", vol. 10, no. 2, pp. S233-S243, Sept. 2018.
- [16] P. Aricó, G. Borghini, G. Flumeri, N. Sciaraffa and F. Babiloni, "Passive BCI beyond the lab: current trends and future directions", Aug. 2018.
- [17] B. Mauss and D. Robinson, "Measures of emotion: A review", Cognition & Emotion, vol. 23, no. 2, pp. 209-237, Feb. 2009.
- [18] K. R. Scherer, "What are emotions? And how can they be measured?", Social Science Information, vol. 44, no. 4, pp. 695-729, 2005.
- [19] R. Picard, "Affective Computing", MIT Media Laboratory, Perceptual Computing, Ames St., Cambridge, No. 321, 1997.
- [20] J. Williams, "What is an emotion?", Dartington College of Arts, Mind, 1884, pp. 188-205.
- [21] J. Fernández, E. Ortega, "Los niveles de análisis de la emoción: James, cien años después", Estudios de Psicología, pp. 34-56, 1985.
- [22] J. W. Papez, "A proposed mechanism of emotion", J Neuropsychiatry Clin Neurosci, vol. 7, pp. 103-12, 1937.
- [23] Psicología básica, Licenciatura de humanidades, Universidad de Alicante, Departamento de psicología de la salud, 2007.

REFERENCIAS

- [24] C. Petrantonakis, J. Hadjileontiadis, “A Novel Emotion Elicitation Index Using Frontal Brain Asymmetry for Enhanced EEG-Based Emotion Recognition”, *IEEE Transactions on information technology in biomedicine*, vol. 15, no. 5, pp. 737-746, Sept. 2011.
- [25] D. L. Clark, N. N. Boutros, M. F. Mendez, “*El cerebro y la conducta, Neuroanatomía para psicólogos*”, 2a edición, México D.F., Editorial El Manual Moderno, 2012.
- [26] I. I. Sanz, “Producción de un corpus oral y modelado prosódico para la síntesis del habla expresiva”, Barcelona, 2008.
- [27] P. Ekman, Universals and cultural differences in facial expression of emotion. J. Cole (Ed.), *Nebraska Symposium on Motivation*, no. 19, 207–283, 1972.
- [28] L. Karl-gustav, “El paradigma de las emociones básicas y su investigación. Hacia la construcción de una crítica”, IX Congreso Internacional de Investigación y Práctica Profesional en Psicología XXIV Jornadas de Investigación XIII Encuentro de Investigadores en Psicología del MERCOSUR. Facultad de Psicología - Universidad de Buenos Aires, Buenos Aires, 2017.
- [29] T. Eerola, J. K. Vuoskoski, “A comparison of the discrete and dimensional models of emotion in music. *Psychology of Music*”, 39(1), pp. 18–49, 2011.
- [30] M. Grimm, et al, “Primitives-based evaluation and estimation of emotions in speech”, *Speech Communication*, vols. 49(10-11), pp. 787-800, 2007.
- [31] K. R. Scherer, “Feelings Integrate the Central Representation of Appraisal-Driven Response Organization in Emotion”, in A.S.R. Manstead, N.H. Frijda and A.H. Fischer *Feelings and Emotions: The Amsterdam Symposium*, pp. 136–57, 2004.
- [32] T. Song, W. Zheng, P. Song and Z. Cui, “EEG Emotion Recognition Using Dynamical Graph Convolutional Neural Networks”, *IEEE Transactions on Affective Computing*, Mar. 2018.
- [33] Y. Lin *et al*, “EEG-Based Emotion Recognition in Music Listening”, *IEEE Transactions on Biomedical Engineering*, vol. 57, no. 7, pp. 1798-1806, Jul. 2010.
- [34] K. Guo, H. Mei, X. Xie and X. Xu, “A Convolutional Neural Network Feature Fusion Framework with Ensemble Learning for EEG-based Emotion Classification”, 2019 IEEE MTT-S International Microwave Biomedical Conference (IMBioC), Nanjing, China, pp. 1-4, May 2019.

- [35] Z. Mohammadi, J. Frounchi and M. Amiri, "Wavelet-based emotion recognition system using EEG signal", *Neural Computing and Applications*, vol. 28, pp. 1985-1990, Aug. 2017.
- [36] J. Houtan, H. Sungjoo and L. SangHyun, "EEG-based workers' stress recognition at construction sites", *Automation in Construction*, vol. 93, pp. 315-324, Sept. 2018.
- [37] M. M. Raja, J. L. Hyo, "A novel feature extraction method based on late positive potential for emotion recognition in human brain signal patterns", *Computers and Electrical Engineering*, vol. 53, pp. 444-457, Jul. 2016.
- [38] D. Lacoviello, A. Petracca, M. Spezialetti, G. Placidi, "A real-time classification algorithm for EEG-based BCI driven by self-induced emotions", *Computer Methods and Programs in Biomedicine*, vol. 122, no. 3, pp. 293-303, Dec. 2015.
- [39] Y. Wei, Y. Wu and J. Tudor, "A real-time wearable emotion detection headband based on EEG measurement", *Sensors and Actuators A: Physical*, vol. 263, pp. 614-621, Aug. 2017.
- [40] B. Kaur, D. Singh and P. P. Roy, "EEG based Emotion Classification Mechanism in BCI", *Procedia Computer Science*, vol. 132, pp. 752-758, May 2018.
- [41] T. Chen *et al*, "Emotion recognition using empirical mode decomposition and approximation entropy", *Computers and Electrical Engineering*, vol. 72, pp. 383-392, Nov. 2018.
- [42] D. D. Chakladar, S. Chakraborty, "EEG based emotion classification using 'Correlation Based Subset Selection' ", *Biologically Inspired Cognitive Architectures*, vol. 24, pp. 98-106, Apr. 2018.
- [43] A. Mert and A. Akan, "Emotion recognition based on time-frequency distribution of EEG signals using multivariate synchrosqueezing transform", *Digital Signal Processing*, vol. 81, pp. 106-115, Oct. 2018.
- [44] W. Zheng, J. Zhu and B. Lu, "Identifying Stable Patterns over Time for Emotion Recognition from EEG", *IEEE Transactions on Affective Computing*, vol. 10, no. 3, pp. 417-429, Jul.-Sept. 2019.
- [45] R. Khosrowabadi, H. C. Quek, A. Wahab and K. K. Ang, "EEG-based Emotion Recognition Using Self-Organizing Map for Boundary Detection", *20th International Conference on Pattern Recognition, Istanbul*, pp. 4242-4245, Aug. 2010.

- [46] J. Li, Z. Zhang and H. He, "Hierarchical Convolutional Neural Networks for EEG-Based Emotion Recognition", *Cognitive Computation*, vol. 10, pp. 368-380, Apr. 2018.
- [47] P. Li *et al*, "EEG Based Emotion Recognition by Combining Functional Connectivity Network and Local Activations", *IEEE Transactions on Biomedical Engineering*, vol. 66, no. 10, pp. 2869-2881, Oct. 2019.
- [48] M. Mikhail, K. El-Ayat, J. Coan, J. Allen, "Using minimal number of electrodes for emotion detection using brain signals produced from a new elicitation technique", *Int. J. Autonomous and Adaptive Communications Systems*, vol. 6, no. 1, 2013.
- [49] K. Ko, H. Yang, K. Sim, "Emotion recognition using EEG signals with relative power values and Bayesian network", *International Journal of Control, Automation and Systems*, vol. 7, no. 865, Oct. 2009.
- [50] X. Wang, D. Nie, B. Lu, "Emotional state classification from EEG data using machine learning approach", *Neurocomputing*, vol. 129, pp. 94-106, 2014.
- [51] J. Zhu, W. Zheng, Y. Peng, R. Duan and B. Lu, "EEG-based emotion recognition using discriminative graph regularized extreme learning machine," 2014 International Joint Conference on Neural Networks (IJCNN), Beijing, 2014, pp. 525-532
- [52] Q. Zhang, M. Lee, "Analysis of positive and negative emotions in natural scene using brain activity and GIST", *Neurocomputing*, vol. 72, pp. 1302-1306, Nov. 2018.
- [53] D. Bos, "EEG-based Emotion Recognition", *The Influence of Visual and Auditory Stimuli*, Dec. 2005.
- [54] S. Alhagry, A. Fahmy, R. El-Khoribi, "Emotion Recognition base don EEG using LSTM Recurrent Neural Network", *International Journal of Advanced Computer Science and Applications*, vol. 8. No. 10, 2017.
- [55] L. Brown, B. Grundlehner and J. Penders, "Towards wireless emotional valence detection from EEG," 2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society, Boston, MA, 2011, pp. 2188-2191.
- [56] M. Murugappan. M. Juharia, R. Nagarajan, S. Yaacob, "An investigation on visual and audiovisual stimulus based emotion recognition using EEG", *Int. J. Medical Engineering and Informatics*, vol. 1, no. 3, pp. 342-356, Jan. 2009.

- [57] H. Yoon, S. Chung, “EEG-based emotion estimation using Bayesian weighted-log-posterior function and perceptron convergence algorithm”, *Computers in Biology and Medicine*, vol 43, pp. 2230-2237, 2013.
- [58] A. Bhatti, M. Majid, S. Anwar, B. Khan, “Human emotion recognition and analysis in response to audio music using brain signals”, *Computers in Human Behavior*, vol. 65, pp.267-275, Dec. 2016.
- [59] W. Zheng, B. Lu, “Investigation Critical Frequency Bands and Channels for EEG-based Emotion Recognition with Deep Neural Network”, *IEEE Transactions on autonomous mental development*, pp. 1-14, 2015.
- [60] J. Atkinson, D. Campos, “Improving BCI-based emotion recognition by combining EEG feature selection and kernel classifiers”, *Expert Systems with Applications*, vol. 47, pp- 35-41, Apr. 2016.
- [61] R. Jeneke, A. Peer, M. Buss, “Feature Extraction and Selection for Emotion Recognition from EEG”, *IEEE Transactions on Affective Computing*, vol. 5, no. 3, pp. 327-339, Jul. 2014.
- [62] B. Stefanovic, J. Warnking and G. Pike, “Hemodynamic and metabolic responses to neuronal inhibition”, *NeuroImage*, vol. 22, no. 2, pp. 771-778, Jun. 2004.
- [63] S. Alasadi, W. Bhaya, “Review of Data Preprocessing Techniques in Data Mining”, *Journal of Engineering and Applied Sciences* 12, vol. 16, pp. 4102-4107, 2017.
- [64] M. Rohál'ová, P. Sykacek, M. Koska, G. Dorffner, “Detection of the EEG Artifacts by the Means of the (Extended) Kalman Filter”, *Measurement Science Review*, vol. 1, no. 1, 2001.
- [65] F. Sánchez, A. Hernández, “Modelado autorregresivo de señales electroencefalográficas para simuladores médicos”, *Ingeniería y Desarrollo*, vol. 35, no. 2, Mar. 2017.
- [66] R. A. Alagia Gimeno, “Procesamiento de artefactos en EEG para aplicaciones de comunicación y control”, Feb., 2018.
- [67] D. M. de Yong, “DETECCIÓN, CLASIFICACIÓN Y LOCALIZACIÓN DE EVENTOS DE CALIDAD DE ENERGÍA UTILIZANDO TÉCNICAS AVANZADAS DE PROCESAMIENTO DE SEÑALES E INTELIGENCIA ARTIFICIAL”, tesis doctoral, Facultad de ingeniería, UNRC, Río Cuarto, Argentina, Feb., 2016.

- [68] “La Teoría de Muestreo”, apuntes de clase para Señales y Sistemas II, Facultad de Ingeniería, Escuela de Telecomunicaciones, Universidad Católica Andrés Bello, 2004.
- [69] A. Hernández, E. Trejos, J. Piedrahita, G. Castellanos, “REDUCCIÓN DE DIMENSIONES PARA CLASIFICACIÓN DE DATOS MULTIDIMENSIONALES USANDO MEDIDAS DE INFORMACIÓN”, *Scientia et Technica* Año XII, No. 32, Dic. 2006.
- [70] “ANÁLISIS DE SEÑALES MEDIANTE STFT Y WAVELET. APLICACIÓN A DEFECTOLOGÍA EN RODAMIENTOS”, apuntes de clase para Ingeniería Industrial, Departamento de Ingeniería Mecánica, Universidad Carlos III de Madrid, 2010.
- [71] M. Vopson, S. Robson, “A new method to study genome mutations using the information entropy”, *Physica A: Statistical Mechanics and its Applications*, vol. 584, Dec, 2021.
- [72] D. Hagemann, E. Naumann, G. Becker, S. Maier, “Frontal brain asymmetry and affective style: A conceptual replication”, *Psychophysiology*, vol. 35, no. 4, Jul., 1998, pp. 372-388.
- [73] Terzian, H., Cecotto, C., “Determination and study of hemisphere dominance by means of intracarotid sodium amytal injection in man: II. Electroencephalographic effects”. *Bolletino della Societa Ztaliana Sperimentale* 35, 1626-1630.
- [74] M. Sánchez, “Asimetría cerebral en la corteza prefrontal”, Trabajo de máster, Master psicobiología y neurociencia cognitiva, Sept. 2012.
- [75] E. Harmon-Jones, P. Gable, C. Peterson, “The role of asymmetric frontal cortical activity in emotion-related phenomena: A review and update”, *Biological Psychology*, vol. 84, pp. 451-462, 2010.
- [76] “Tema 5. Clasificadores K-NN”, apuntes para clase Computación e Inteligencia Artificial, Departamento de Ciencias de la Computación e Inteligencia Artificial, Universidad de País Vasco Herriko Unibertsitatea.
- [77] S. T. I. E. O. M. G. F. R. a. M. M. H. R. Bousseta, «EEG Efficient classification of imagined hand movement using RBF kernel SVM,» de 2016 11th Int. Conf. Intell. Syst. Theor. Appl, Mohammedia, 2016.
- [78] Y. Liu, Sourina O., “EEG Databases for Emotion Recognition”, *Proceedings- 2013 International Conference on , Cyberworlds (CW)*, Oct., 2013.

REFERENCIAS

- [79] Wei-Long Zheng, Wei Liu, Yifei Lu, Bao-Liang Lu, and Andrzej Cichocki, EmotionMeter: A Multimodal Framework for Recognizing Human Emotions. IEEE Transactions on Cybernetics, 2018.
- [80] “DEAP: A Database for Emotion Analysis using Physiological Signals”, S. Joelstra, C. Muehl, M. Soleymani, J-S. Lee, A. Yazdani, T. Ebrahimi, T. Pun, A. Nijholt, I. Patras, IEEE Transactions on Affective Computing, vol. 3, no 1. Pp. 18-31, 2012.
- [81] K. Das and R. Pachori, “Biomedical Signal Processing and Control”, Biomedical Signal Processing and Control, vol. 67, May 2021.
- [82] J. Portellano, “*Introducción a la neuropsicología*”, 1ª edición, McGRAW-HILL, Interamericana de España, 2005.
- [83] R. Miikkulainen, J. Bednar, Y. Choe and J. Sirosh, “*Computational Maps in the Visual Cortex*”, 1st edition, Springer, New York, 2005.
- [84] Kingma, Diederik P., and Jimmy Ba. "Adam: A method for stochastic optimization." arXiv preprint arXiv:1412.6980 ,2014, pp. 1-15.
- [85] C. Szegedy, W. Liu, Y. Jia, P. Sermanet, S. Reed, D. Anguelov, D. Erhan, V. Vanhoucke, and A. Rabinovich, Going deeper with convolutions, in Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, Boston, MA, USA, 2015, pp. 1–9.
- [86] M. Guevara, O. Vergara, M. Nandayapa, H. Ochoa, H. Sossa, “Study of the Effect of Combining Activation Functions in a Convolutional Neural Network”, IEEE Latin America Transactions, vol. 19, no. 5, May, 2021.
- [87] M. Narkhede, P. Bartakke, M. Sutaone, “A review on weigth initialization strategies for neural networks”, Artificial Intellifence Review, Jun., 2021.
- [88] V. Luis, (2020, Abr., 26), “Optimizadores en Redes Neuronales profundas: un enfoque práctico”, [Online], Available: <https://medium.com/@velascoluis/optimizadores-en-redes-neuronales-profundas-un-enfoque-pr%C3%A1ctico-819b39a3eb5>

REFERENCIAS

- [89] Y. Jung, “Multiple predicting K-fold cross-validation for model selection”, *Journal of nonparametric statistics*, vol. 30, no. 1, pp. 197-215, 2018.