



UNIVERSIDAD NACIONAL AUTÓNOMA DE MÉXICO

POSGRADO EN CIENCIA E INGENIERÍA DE LA COMPUTACIÓN

TOMA DE DECISIONES GUIADA POR EMOCIONES DETECTADAS EN
SEÑALES DE ELECTROENCEFALOGRAMA MEDIANTE REDES
CONVOLUCIONALES

T E S I S

QUE PARA OPTAR POR EL GRADO DE:

MAESTRO EN CIENCIA E INGENIERÍA DE LA COMPUTACIÓN

PRESENTA:

DIEGO GONZÁLEZ CHÁVEZ

DIRECCIÓN:

DR. GIBRÁN FUENTES PINEDA

INSTITUTO DE INVESTIGACIONES EN MATEMÁTICAS APLICADAS Y EN SISTEMAS

CODIRECCIÓN: DRA. ALICIA MONTSERRAT ALVARADO GONZÁLEZ

UNIVERSIDAD AUTÓNOMA METROPOLITANA

Ciudad de México, México

Julio, 2023



Universidad Nacional
Autónoma de México



UNAM – Dirección General de Bibliotecas
Tesis Digitales
Restricciones de uso

DERECHOS RESERVADOS ©
PROHIBIDA SU REPRODUCCIÓN TOTAL O PARCIAL

Todo el material contenido en esta tesis esta protegido por la Ley Federal del Derecho de Autor (LFDA) de los Estados Unidos Mexicanos (México).

El uso de imágenes, fragmentos de videos, y demás material que sea objeto de protección de los derechos de autor, será exclusivamente para fines educativos e informativos y deberá citar la fuente donde la obtuvo mencionando el autor o autores. Cualquier uso distinto como el lucro, reproducción, edición o modificación, será perseguido y sancionado por el respectivo titular de los Derechos de Autor.

Agradecimientos

Por medio del siguiente texto quiero expresar mi agradecimiento a los que han participado y me han acompañado en la realización de la tesis, así como el cariño que le tengo a dicho trabajo. Aunque la situación sanitaria mundial puso variedad de obstáculos en el camino, fue uno lleno de aprendizajes y logros, y no habría sido posible sin el apoyo y aliento de cada uno.

La presente tesis es un proyecto multidisciplinario lo que me ha permitido adentrarme en varias áreas, aprender de ellas y conocer gente especializada en cada una de ellas brindándome su conocimiento y apoyo. Es un trabajo que además de formar parte de mi desarrollo profesional también lo es para mi desarrollo de vida. Durante la investigación sobre las emociones, uno de los temas base de la tesis, pude entender mejor su importancia e influencia en nuestro desarrollo lo cual cambió por completo mi forma de ver la vida y de mi mismo.

Todo el tiempo tuve a mi familia a mi lado apoyándome para hacerlo posible. Cada uno a su manera me brindó su aliento para continuar hasta el final, por lo que me siento muy agradecido con ellos y les guardo un profundo cariño. Sin embargo, quiero hacer un reconocimiento a mi padre, aunque la vida no me permitió tenerlo a mi lado desde el inicio de la tesis siempre estuvieron presentes sus enseñanzas y su profundo amor; y a mi hermana que siempre estuvo para apoyarme y levantarme cuando creía no poder más, de la cual siempre estaré agradecido.

Quiero mostrar mi agradecimiento a la Dra. Alicia Montserrat Alvarado González y al Dr. Antonio López Jaimes por haberme invitado al proyecto de investigación con número de registro A1-S-36498 ante el CANACyT, a partir del cual se desarrolla la presente tesis. Su colaboración, dedicación y gran pasión por la investigación fueron piezas fundamentales

para su desarrollo. Ambos profesores investigadores fueron parte de mi proyecto terminal de licenciatura, ahora los considero mi inspiración y admiración para mi desarrollo profesional.

Quiero agradecer a mi tutor el Dr. Gibran Fuentes Pineda y a mi tutora la Dra. Alvarado por ser mi guía durante el proceso del proyecto, su conocimiento, paciencia y orientación fueron fundamentales para mi crecimiento académico. Gracias por motivarme y por brindarme una visión clara en cada etapa de esta investigación.

Quiero agradecer a la Universidad Nacional Autónoma de México (UNAM) por brindarme la oportunidad de llevar a cabo este estudio. Agradezco al Instituto de Investigaciones en Matemáticas Aplicadas y en Sistemas (IIMAS) por proporcionarme los recursos necesarios y por crear un ambiente propicio para el aprendizaje y la investigación. También agradezco a la Universidad Autónoma Metropolitana (UAM) por seguir abriéndome sus puertas, dándome la posibilidad de realizar los experimentos dentro de sus instalaciones; sin pasar por alto agradezco al alumnado de dicha universidad que generosamente compartió de su tiempo para participar en mi estudio.

A mis sinodales la Dra. Katya Rodríguez Vázquez, Dr. Caleb Antonio Rascón Estebané, Dr. López por cada uno de sus comentarios, los cuales me ayudaron a pulir mi trabajo.

Por último, quiero reconocer a todas las personas que de alguna manera han contribuido a mi desarrollo académico y personal. A los expertos en el campo que me brindaron orientación valiosa, a los profesionales que me ayudaron en las distintas etapas de la investigación, a mis compañeros de clase por los comentarios y a cualquier otra persona que haya dejado una huella en el desarrollo de la tesis, mi más sincero agradecimiento.

Índice general

Agradecimientos	I
1 Introducción	1
§1.1 Motivación y justificación	4
§1.2 Objetivos	5
§1.3 Hipótesis	6
§1.4 Organización de la tesis	7
2 Marco Teórico	9
§2.1 Emociones	10
§2.1.1 Las emociones en el cerebro	12
§2.1.2 Las emociones y la toma de decisiones	15
§2.1.3 Respuestas emocionales	18
§2.1.4 Preprocesamiento de las señales de EEG	19
§2.1.5 Detección automática de emociones	20
§2.1.6 Conjuntos de datos de experimentación	26
§2.2 Optimización multiobjetivo	27
§2.2.1 Incorporación de preferencias	30
§2.3 Interacción humano-robot	31
§2.4 Sistemas para la detección emocional y toma de decisiones	32
3 Método propuesto	35
§3.1 Modelo emocional	36
§3.2 Protocolo de entrenamiento	38
§3.3 Interfaz Cerebro-Computadora	39

§3.3.1	Arquitectura de la BCI	43
§3.3.2	Detalles técnicos	44
§3.4	Señales de electroencefalograma	45
§3.5	Simulador	46
§3.5.1	Neurocontrolador: red neuronal artificial	47
§3.5.2	Entorno virtual	48
§3.6	Optimización del neurocontrolador	49
§3.7	Traducción emocional	52
§3.7.1	Redes neuronales convolucionales	52
§3.7.2	Sistema en línea	55
§3.8	Modelo de preferencias emocionales	56
4	Experimentación	60
§4.1	Selección del modelo	60
§4.2	Entrenamiento con los datos del protocolo de estimulación propuesto	62
§4.3	Componentes emocionales	63
§4.4	Preferencias emocionales	64
5	Conclusiones	69
§5.1	Trabajo futuro	72

Índice de figuras

2.1	regiones de Brodmann en la corteza cerebral. Figura tomada de (36).	13
2.2	<i>valence</i> en el cerebro. Figura traducida de (121).	14
3.1	modelo emocional circuplejo.	37
3.2	deslizadores para la captura de las emociones con la BCI.	37
3.3	protocolo de entrenamiento para la evocación de emociones.	38

3.4 diagrama del flujo del sistema. Cada vez que se pasa por el recuadro de Frente de Pareto se inicia la exploración de un nuevo frente. Cuando se realiza la selección de un individuo se pone en marcha el proceso para extraer su emoción: se inicia la adquisición del EEG y la simulación del neurocontrolador; cuando ésta termina el DM da su emoción con SAM y la CNN a partir de las señales de EEG. El proceso se repite con todos los individuos del frente; se almacenan las emociones que fueron extraídas del EEG con la CNN y se ingresan a las preferencias emocionales para determinar el individuo preferido. Se buscan los nuevo individuos de un frente Pareto perteneciente a una generación superior y el proceso se repite. 41

3.5 interfaces gráficas de la BCI. 42

3.6 módulos del sistema BCI y sus conexiones principales. 44

3.7 casco de EEG Ultracortex de OpenBCI. 46

3.8 modelo virtual del robot móvil utilizado para los experimentos. 47

3.9 entrada del dormitorio, posición inicial del robot. 48

3.10 sala que tiene que atravesar el robot para llegar a la mesa que se encuentra en la cocina. 49

3.11 función objetivo. 51

3.12 arquitectura de *EEGNet*. 52

3.13 arquitectura de *ShallowConvNet*. 54

3.14 arquitectura de *DeepConvNet*. 54

3.15 Funcionamiento de PBI. 57

3.16 nuestro espacio de preferencias con PBI, generado a partir de una distribución aleatoria de distintas emociones. 58

4.1 error cuadrático medio usando DEAP. 61

4.2 error absoluto medio usando DEAP. 61

4.3 error cuadrático medio usando datos del protocolo. 62

4.4 error absoluto medio usando datos del protocolo. 62

4.5 Variación de las preferencias emocionales ante las tomas de decisiones durante la evolución del neurocontrolador. Las gráficas de la (a.x) a la (g.x) muestran la variación del usuario 'a' al usuario 'g', respectivamente. Las gráficas (x.1) son las variaciones dados los valores del SAM y (x.2) con las predicciones de *DeepConvNet*. 67

4.6 Desviación de las preferencias para cada sujeto utilizando las dos fuentes emocionales: SAM y la CNN. La figura (a) es la desviación hacia la calma y la figura (b) hacia la felicidad. 68

4.7 Distribución de los neurocontroladores preferidos con SAM y las emociones detectadas con la CNN. Se utiliza la distancia entre los neurocontroladores 68

Capítulo 1

Introducción

Las emociones juegan un papel importante en los seres humanos: han sido parte de nuestra supervivencia (67), forman parte integral de nuestra comunicación (45), nos permiten adaptarnos y reaccionar a distintas situaciones (26). El estudio de las emociones posee un gran potencial de aplicación. Conocer los estados emocionales de los usuarios son parte primordial en distintas áreas. Por ejemplo, en psicología y medicina son importantes en el mejoramiento de las terapias (137), ya que podrían ayudar a la regulación emocional y la comprensión de su influencia en el comportamiento; o en la realidad virtual podría mejorarse la creación de experiencias inmersivas (40). En general, los sistemas que responden a las emociones se pueden usar para mejorar la experiencia del usuario, así como para crear sistemas con mayor facilidad de interacción y uso.

Las emociones son una fuente valiosa de información sobre el ser humano, por lo tanto, debe ser tratada con ética y responsabilidad. Éstas poseen una influencia importante en varias funciones del ser humano, entre ellas, en la toma de decisiones, aspecto fundamental de nuestra existencia. El neurocientífico António Damásio, por medio de su hipótesis de marcadores somáticos (25), presenta una visión conciliadora entre la razón y la emoción; propone que ambas están íntimamente conectadas y que las emociones juegan un papel crucial en la toma de decisiones, nos ayudan a predecir futuros resultados ante ciertos escenarios. Se encuentran presentes en gran parte de nuestro día, como mencionan Neta y Haas (2019) “la emoción es un lente a través del cual percibimos e interactuamos con el mundo, impulsando nuestro comportamiento”(p. 1). Por mencionar unos ejemplos, las

emociones tienen impacto sobre las actitudes políticas (41), ya que afianzan el compromiso con el partido; o si se presenta la oportunidad de una inversión con alto rendimiento donde se tenga que tomar una decisión apresurada, un estado somático negativo ayudará a rechazar la opción (25); su influencia se debe a que “se producen representaciones de estados viscerales que sirven como una señal de sesgo en la toma de decisiones, afectando la valoración de recompensa y comportamiento de riesgo”(Poppa y Bechara, 2018, p. 64). Las emociones introducen cambios en el estado interno del cuerpo, que pueden ser medidos con diferentes técnicas a partir de distintas fuentes fisiológicas. En la detección de estados emocionales se encuentran: los cambios en el ritmo cardiaco (7), cambios en la conductancia de la piel (87) o movimientos de los músculos del rostro evocando rasgos significativos de distintas emociones (101). Una sonrisa se asocia a la felicidad y el ceño fruncido al enojo. Las emociones se generan en el cerebro y se reflejan en la actividad neuronal (133).

En particular, en este proyecto estamos interesados en medir las respuestas emocionales en las señales eléctricas del cerebro, ya que son una fuente confiable en la que no se puede fingir; como sucede con los gestos, por ejemplo, con una sonrisa falsa. Para medir tales respuestas, utilizamos el electroencefalograma (EEG). El EEG es una técnica que nos permite medir la actividad eléctrica neuronal y almacenar las señales para su posterior análisis.

Identificar las emociones de forma automática a partir de la actividad neuronal es una tarea compleja, ya que en el EEG no se observan fácilmente. Sin embargo, existe evidencia que las redes neuronales convolucionales permiten identificar con un muy buen desempeño los estados emocionales embebidos en la señal de EEG (72, 136, 54). Las redes neuronales convolucionales son una clase de métodos que son capaces de obtener información espacial y temporal.

Las señales de EEG pueden ser utilizadas para crear una interfaz de comunicación entre el cerebro y algún dispositivo externo. A este tipo de sistemas se les conoce como Interfaces Cerebro-Computadora (BCI, por las siglas en inglés de *Brain-Computer Interfaces*) y buscan crear una interfaz de comunicación entre el cerebro y algún dispositivo externo. Por mencionar una aplicación, en (86) por medio de su uso se busca mejorar la calidad

de vida de las personas que han perdido la movilidad por la esclerosis lateral amiotrófica, lo que se les dificulta la comunicación con su entorno, así tendrían un mecanismo que les sirva de apoyo a sus cuidadores para el cumplimiento de sus necesidades básicas.

La toma de decisiones es un proceso que conlleva a elegir entre varias opciones o alternativas para alcanzar un objetivo o resolver un problema. Estas alternativas pueden ser soluciones de un problema de optimización, en el cual se busca encontrar la mejor solución. Existe un área de investigación llamada optimización multiobjetivo, la cual se encarga de estudiar los métodos utilizados para la búsqueda de dicha solución o soluciones, tomando en consideración ciertos criterios. Sin embargo, en muchos casos no es posible mejorar todos los criterios de búsqueda simultáneamente, ya que éstos pueden estar en conflicto. Por lo tanto, el algoritmo busca un conjunto de soluciones que posean valores aceptables para los distintos criterios, mientras mejora en uno puede empeorar en otro. Normalmente, necesitamos implementar una única solución de entre todo el conjunto de soluciones igualmente equivalentes. Para ello, una experta o experto, conocido como tomador de decisiones (DM, por las siglas en inglés de *Decision Maker*) debe guiar la búsqueda para un contexto específico.

Como se mencionó anteriormente, las emociones introducen cambios en el estado interno del cuerpo. Nuestro cuerpo reacciona ante los estímulo internos o externos y se ve reflejado en distintas fuentes biológicas como la conductancia de la piel, el ritmo cardíaco, la actividad neuronal, entre otros; estas reacciones emocionales nos dan indicio de la emoción evocada. En el presente proyecto, proponemos una BCI que permita la exploración de un conjunto de soluciones tomando en cuenta las respuestas emocionales en la actividad neuronal del DM. En el caso de estudio que proponemos, dichas soluciones son neurocontroladores generados por un optimizador. Los neurocontroladores consisten en redes neuronales encargadas de conducir un robot móvil dentro de un entorno doméstico virtual. El robot hace uso de sus sensores de proximidad para navegar, predice el ángulo de giro y la velocidad para que el robot pueda andar en las habitaciones. Los objetivos que están en conflicto en el proceso de optimización son tres: minimizar la distancia recorrida para llegar a la meta; minimizar el riesgo, que se define como la cercanía a los objetos; y minimizar la velocidad de llegada a la posición final. Para evocar las respuestas emociona-

les del DM, el robot móvil se desenvuelve dentro de un entorno virtual doméstico en el que hay personas de distintas edades, muchos posibles caminos por los cuales andar, objetos y muebles, algunos de ellos frágiles. La toma de decisiones del DM conduce el proceso de búsqueda, ésta las realiza con base en sus preferencias.

La exploración emocional de los frentes de Pareto abren paso al estudio de las interacciones emocionales Humano-Robot y su influencia en el proceso de optimización. El desarrollo de neurocontroladores que evoquen emociones positivas en el DM es útil en entornos socialmente demandantes. Para lograr una integración del robot en entornos domésticos, es deseable que su uso sea adecuado respecto a los estándares del DM, eso le permitirá mejorar su experiencia.

En el sistema que proponemos, usamos redes convoluciones para la detección de emociones y las soluciones generadas por el optimizador para estimular al DM. Con ello extraemos de las señales de EEG sus emociones. El DM realiza una búsqueda de diferentes frentes de Pareto; el proceso es guiado con la emociones evocadas con las simulaciones asociadas a los individuos seleccionados de cada frente visitado. Las emociones influyen en la toma de decisiones, por tal motivo, las emociones dadas por la red convolucional son procesadas por nuestro sistema para obtener los individuos preferidos. Estos individuos se ajustan a un modelo de preferencias y, con ello, darle dirección a la búsqueda de las nuevas soluciones.

1.1. Motivación y justificación

El desarrollo de sistemas de reconocimiento automático de emociones son de utilidad para múltiples aplicaciones donde es necesario contar con los estados emocionales de los usuarios (véase el capítulo 2). Estos sistemas permitirán avances significativos en distintas áreas del conocimiento; nos permitiría estudiar y entender mejor la emoción. Se pueden incorporar en la medicina, psicología, ingeniería o el entretenimiento, entre otras. Por ejemplo, en la psicología pueden servir para la detección de los estados efectivos en pacientes con síndrome de la consciencia, tales como estado de coma, estado vegetativo, estado de conciencia mínima y estado de conciencia mínima emergente (47); o en aplicaciones no relacionadas con la salud (60), como temas de ingeniería de software: su calidad, usabilidad

o la productividad de los programadores; temas relacionados al aprendizaje: aprendizaje de tareas, la evaluación de recursos para el aprendizaje; el diseño de páginas web o de videojuegos para una experiencia más inmersiva. Las áreas relacionadas con la tecnología sufrirán cambios. Se pueden desarrollar servicios personalizados, como por ejemplo, la recomendación automática de música, vídeos, películas o cualquier otro material audiovisual. Cabe mencionar que ya hay servicios que basan su funcionalidad a partir de estudios de la actividad neuronal. Un ejemplo es www.brain.fm, el cual es un asesor de música cuyo fin es guiar a los usuarios a alcanzar ciertos objetivos, como ayudarlos a focalizarse en una tarea o relajarse.

El reconocimiento automático de emociones también es útil para el desarrollo humano, para Torres P et al. (116) pueden ayudar a las personas a controlar su salud mental, aumentar nuestra comprensión de las emociones para promover la comunicación efectiva y el uso del EEG podría ayudar a enriquecer las relaciones de las personas con su entorno.

El estudio emocional con base en la interacción humano-robot hace falta explorarla más ampliamente. Aunque hay una variedad de trabajos relacionados a la detección automática de emociones, no se ha encontrado evidencia de su aplicación con señales EEG y cómputo evolutivo en la interacción con robots. Las emociones son un medio para obtener una evaluación subjetiva ante una toma de decisiones y el cómputo evolutivo permite generar conjuntos de soluciones que mejoran en cada iteración de los algoritmos, ambas características son llamativas para su uso en conjunto.

1.2. Objetivos

Objetivo general

Desarrollar un sistema que permita obtener las preferencias del DM a partir de sus emociones. El sistema debe mostrar un conjunto de opciones de distintas tomas de decisiones y capturar las que posean mayor preferencia. El caso de estudio es aplicado a la evolución de un neurocontrolador por medio de las soluciones generadas por un algoritmo evolutivo multiobjetivo. De forma iterativa, el sistema debe mostrar automáticamente un subcon-

junto de neurocontroladores de diferentes frentes de Pareto, los cuales se deben presentar en una simulación en tiempo real para estimular al DM y con ello evocar sus emociones. La información de las preferencias debe guiar la búsqueda de los neurocontroladores.

El sistema debe realizar la búsqueda a partir de la detección automática de emociones, que se encuentran embebidas en la señal de electroencefalograma del DM; las señales deben ser capturadas durante las visualizaciones de las simulaciones.

Objetivos específicos

1. Implementar un protocolo de adquisición de señales de EEG para intensificar y diferenciar las emociones en los distintos DMs.
2. Desarrollar una interfaz que permita la interacción entre el usuario y las soluciones de un algoritmo multiobjetivo.
3. Desarrollar un programa para capturar y preprocesar las señales de EEG.
4. Desarrollar y analizar el desempeño de algunas redes neuronales convolucionales del estado del arte para la detección de emociones a partir de las señales de EEG.
5. Desarrollar un modelo de preferencias emocionales que permita explorar los frentes de Pareto con las emociones del DM.
6. Integrar un simulador en tiempo real de un entorno doméstico, el cual permita a los neurocontroladores llevar acabo su tarea.
7. Analizar las variaciones de las preferencias de los DMs a partir de la búsqueda de los frentes de Pareto con las emociones.

1.3. Hipótesis

Al presentarle al DM simulaciones sobre un caso de estudio, se evocarán emociones detectables en las señales de electroencefalograma que podrán ser identificadas mediante el uso de una red neuronal convolucional. Dicho protocolo le presentará al DM varias tomas

de decisiones donde cada una poseerá distintas opciones, las emociones identificadas tras seleccionarlas permitirán obtener las preferencias del DM.

El caso de estudio son las soluciones de un optimizador, el cual genera distintos conjuntos de soluciones que representan un neurocontrolador que conduce un robot móvil. Por lo anterior, se podrían formar subconjuntos de soluciones (opciones en el contexto de toma de decisiones) que podrían ser evaluados con emociones, lo cual permitiría realizar una exploración emocional en el proceso evolutivo y capturar la variación de las preferencias del DM.

La detección emocional podría llevarse a cabo por medio de redes convolucionales entrenadas con señales de EEG, capturadas durante la estimulación con videos relacionados al caso de estudio y videos musicales que intensifiquen sus emociones.

1.4. Organización de la tesis

En los capítulos consecuentes se presenta nuestro trabajo, los fundamentos teóricos, la descripción del método de nuestra investigación, la experimentación y las conclusiones obtenidas.

En el capítulo 2 mostramos los trabajos con los que se fundamenta el desarrollo de la presente tesis. Primeramente presentamos cómo las emociones se hacen presentes en la actividad neuronal y cómo puede ser representada por los componentes emocionales que sustentan el modelo emocional que utilizamos; también se muestran las técnicas y métodos utilizados en el estado del arte para identificar las emociones en los humanos. Mostramos la influencia de las emociones en la toma de decisiones y cómo el proceso de la decisión puede ser medido a partir de la actividad neuronal. Hacemos referencia a los principales algoritmos de optimización multiobjetivo que han puesto las bases y han incentivado el desarrollo del área, así como los métodos para la incorporación de las preferencias para guiar la búsqueda de las soluciones óptimas. Presentamos aplicaciones de BCI para la detección emocional y la toma de decisiones.

En el capítulo 3 se presenta cada parte del método para la extracción de preferencias a partir de las emociones. Mostramos el método emocional que utilizamos para capturar

las emociones del tomador de decisiones; el cual sirve para cuantificar las emociones y así puedan ser utilizadas en nuestro sistema. Se implementa un protocolo para la estimulación del DM con el fin de identificar sus emociones a partir de su evaluación emocional y la actividad neuronal. Presentamos cómo se conforma la interfaz cerebro-computadora propuesta, su funcionamiento y las tecnologías utilizadas para su desarrollo. Se detalla la forma en que interactúa el DM con nuestro sistema y cómo se relaciona con nuestro caso de estudio: la evolución del neurocontrolador dentro de un entorno doméstico. Estamos interesados en las preferencias del DM y cómo extraerlas a partir de sus emociones, presentamos el modelo que proponemos para identificar las emociones de mayor preferencia y cómo lo utilizamos para movernos dentro del conjunto de soluciones.

En el capítulo 4 presentamos los resultados obtenidos en nuestro trabajo. Sustentamos la elección de la red convolucional a utilizar en la BCI; evaluamos las tres redes que poseemos con un conjunto de datos mayor al nuestro, que es comúnmente utilizado en trabajos de detección emocional. La red que fue seleccionada en el proceso anterior, se evalúa con el conjunto de datos generado con nuestros sujetos de prueba. Exploramos la capacidad de la BCI para detectar las emociones, los componentes que conforman la emoción nos dan indicio sobre los fenómenos emocionales: agradable o desagradable, activación o desactivación. Al final del capítulo se tratan las preferencias del DM, sobre nuestro caso de estudio.

En el último capítulo 5 presentamos las conclusiones sobre nuestra investigación y trabajo futuro.

Capítulo 2

Marco Teórico

Las emociones se han estudiado ampliamente, pues tienen gran impacto en los seres humanos y en su desarrollo. En la sección 2.1 presentamos los trabajos con los cuales sentamos la bases para la concepción de la emoción, con el fin de comprender su uso en nuestro trabajo.

Se han propuesto una gran variedad de teorías que buscan explicar la composición estructural de la emoción, sirviendo de base para su captura. Distintos autores han fundamentado su teoría por medio de la actividad neuronal, sin embargo, se pueden utilizar para estudios emocionales con otras fuentes. Estas fuentes pueden ser biológicas: el ritmo cardiaco, la conductancia de la piel, entre otros; o resultantes por el comportamiento: el habla y el texto.

Debido a que las emociones se hacen presentes en distintas fuentes, se han propuesto diferentes métodos para su detección automática. Estos métodos mayormente se han desarrollado en base al aprendizaje de máquina, por lo tanto presentamos en la subsección 2.1.5 el estado del arte de varios métodos para su detección. En la subsección 2.1.6 se presentan conjuntos de datos que han sido utilizados en trabajos de la detección emocional.

Estamos interesados en la influencia de las emociones en la toma de decisiones, en la subsección 2.1.2 se presenta la teoría que lo fundamenta y cómo se expresa en el cerebro.

Nuestro caso de estudio es un problema de optimización multiobjetivo, por tal motivo en la sección 2.2 presentamos algunos de los MOEA representativos del área, que han servido de base para el desarrollo de algoritmos más complejos. Para nuestro trabajo no

es indispensable el uso de un optimizador en específico, puede ser utilizado uno diferente, pudiendo ser los que se mencionan en dicha sección. También se abarcan métodos para la incorporación de preferencias, a través de ellas el DM puede guiar el proceso de generación de nuevas soluciones.

En la sección 2.3 presentamos algunos trabajos relacionados a la interacción humano-robot, la impresión que crean cuando están de por medio emociones. En la última sección 2.4 se muestran trabajos sobre el desarrollo de sistemas que detectan emociones y cómo se relacionan con los que detectan la toma de decisiones.

2.1. Emociones

La noción de estado afectivo es referenciada por los términos: emociones, núcleos afectivos, estados de ánimo y personalidad (14). Las emociones son aquellas reacciones físicas en nuestro cuerpo que suceden en un corto periodo de tiempo, ya sea por un estímulo externo o interno y puede ser generado por una persona, un evento, una memoria, por experiencias imaginarias o por experiencias del pasado. Los núcleos afectivos son un conjunto discreto y finito de emociones básicas, cuya combinación forman emociones de alto nivel (121). El estado de ánimo o humor es un estado que es relativamente prolongado y predominante, “es definido por sentimientos subjetivos que pueden estar relacionados o no a un evento en específico”(Lempert y Phelps, 2014, p. 220). La personalidad es un aspecto subjetivo persistente que codifica las actitudes hacia objetos o conceptos.

La teoría relacionada a los núcleos afectivos se divide en dos enfoques: teoría de la emoción básica y teoría dimensional. A partir de estos enfoques se busca definir y analizar las emociones al dividir las en una serie de componentes emocionales. En el enfoque de la emoción básica, los componentes emocionales se definen a partir de un conjunto discreto y finito de emociones. En (121) utilizan un conjunto básico de tres emociones, las cuáles son: la felicidad, la tristeza y el enojo, y su combinación forma emociones de orden superior. En el enfoque dimensional, las emociones se representan como un sistema de coordenadas de N dimensiones, cada eje de dicho sistema es un componente emocional. En ellos se encuentra el sistema de Russell (104), un ejemplo de un modelo dimensional; las emociones son

tratadas como dimensionalidades afectivas. Dicho modelo toma como base que las emociones están compuestas por dos componentes emocionales llamados valencia y activación (*valence* y *arousal*, respectivamente). Dado que los términos *valence* y *arousal* son terminologías bien definidas y estandarizadas dentro del área de las neurociencias afectivas, se prefiere su uso en el idioma inglés. El valor de *valence* se refiere a qué tanto la emoción evocada fue agradable o desagradable y el *arousal* indica la intensidad de la emoción.

Encontramos que ambas teorías no son contradictorias entre sí, se ha propuesto que estas difieren en la intensidad y el placer (39); las emociones básicas se ubican en los ejes del sistema. Emociones complejas poseen su ubicación en los cuadrantes del sistema bidimensional.

En (125) introducen al *valence* como un modelo psicológico. La positividad y negatividad son vistas como opuestos que forman parte de una sola dimensión afectiva; a la cual se la conoce como la hipótesis de bipolaridad. Con el tiempo se encontró evidencia de que la experiencia emocional afectiva de positividad y negatividad a menudo no están correlacionadas (75), lo que da paso al desarrollo de la hipótesis de bivalencia. En esta hipótesis, el *valence* se constituye por dos componentes afectivos que van de los rangos de positivo a neutro y de negativo a neutro. Plantea la existencia de dos sistemas físicos que generan y representan la positividad y negatividad. Ambas hipótesis buscan interpretar al *valence* dentro de la actividad neuronal. En la hipótesis de bipolaridad se busca darle soporte con la búsqueda de una red que cambia monótonamente a los cambios de afecto positivos, neutro y negativo. Para la hipótesis de bivalencia se busca darle soporte por la búsqueda de dos redes separadas e independientes partícipes en la positividad y negatividad, respectivamente (75).

Ambas teorías pueden usarse para realizar estudios emocionales. En (44) se capturan las evaluaciones emocionales (*valence* y *arousal*) por medio de un cuestionario que utiliza palabras del lenguaje cotidiano y que están relacionadas con las emociones. Se ha encontrado que a nivel individual existe gran variabilidad entre las relaciones de *valence* y *arousal*, con esto se “evidencia una maleabilidad ideográfica en la estructura del afecto”(Kuppens et al., 2013, p. 19). No hay una fuerte relación universal entre ambos valores, lo que imposibilita hacer afirmaciones universales. Para reconocer y tratar las emociones es necesario

contar con un modelo emocional que nos permita cuantificar las emociones. Entre ellos se encuentra (104), un modelo circunplejo que representa las emociones con base en *valence* y *arousal*, valores que representan el eje x y y , respectivamente. Es un modelo ampliamente reconocido para los estudios emocionales, sin embargo, no es el único. En (110) proponen un modelo 3D donde los ejes son: agradable-desagradable, atención-rechazo y *arousal*. En (80) se presenta una extensión del modelo de Russell, agregando la dominancia como un tercer eje.

2.1.1. Las emociones en el cerebro

Nuestro cerebro se compone de dos tipos de células (36): neuronas y gliales. Las células gliales son células de soporte de distintos tipos, intervienen en el mantenimiento del ambiente biológico para que las funciones nerviosas puedan realizarse correctamente, además, proveen soporte estructural. Las células encargadas de llevar a cabo el procesamiento son las células nerviosas o neuronas, constituyen la base para la función mental.

El cerebro humano en promedio posee 10^{11} neuronas. Analizarlas a un nivel individual con el fin de comprender los fenómenos mentales es una tarea complicada ya que el número de sinapsis ronda alrededor de 10^{15} (36). El cerebro humano se divide en tres partes: telencéfalo, mesencéfalo y tronco cerebral. Nosotros estamos interesados en el telencéfalo, lugar donde se encuentra la corteza cerebral, ya que por medio de la técnica de electroencefalograma podemos capturar y analizar su actividad. La corteza cerebral es una hoja plegada dentro del cerebro; está compuesta por cuerpos celulares a los que se conoce como materia gris. La densa serie de axones debajo de la corteza cerebral se llama materia blanca. Por conveniencia, primeramente se dividió el cerebro en cuatro secciones, llamadas lóbulos. Sin embargo, no son subdivisiones funcionales. El nombre de estos lóbulos son parietal, occipital, frontal y temporal.

Se ha encontrado evidencia en varios trabajos sobre la especialización de ciertas regiones dentro del cerebro. En (12), Brodmann propone la división de la corteza cerebral en regiones funcionales, pues encuentra pequeñas diferencias entre ellas. A partir de su estructura celular (citoarquitectura), define un total de 52 regiones.

Se ha encontrado evidencia de la expresividad emocional en el cerebro usando como




Figura 2.1: regiones de Brodmann en la corteza cerebral. Figura tomada de (36).

base las regiones o áreas de Brodmann (114). De hecho, se ha detectado actividad en la parte inferior de la corteza frontal izquierda (región 47 según la teoría) ante la reacción del reconocimiento de expresiones faciales que expresan disgusto, miedo e ira. Las regiones de Brodmann están asociadas a funciones cognitivas específicas: la vista, el habla y la escucha, por mencionar algunas (1), lo que ha servido de base para el estudio de las reacciones emocionales en el cerebro.

Por medio de los estudios de la actividad neuronal, se ha buscado fundamentar las teorías de la emoción básica y la dimensional. A partir de la evaluación subjetiva realizada con el uso de los núcleos afectivos se capturan los valores de los componentes emocionales. Las activaciones varían para las distintas emociones, incluso difieren entre sujetos que reportan la misma emoción. Con las evaluaciones subjetivas dotan de sentido emocional a las activaciones neuronales producidas ante cierto estímulo específico. Se han desarrollado trabajos en los cuales han utilizado la técnica de imagenología fMRI (por las siglas en inglés de *Functional Magnetic Resonance Imaging*) para estudiar las activaciones en el cerebro ante estímulos que provoquen cambios en la actividad neuronal, producto de estimulaciones emocionales. A continuación mostramos un ejemplo de la activación emocional positiva en el cerebro (121).

En la figura 2.2 se observan los grupos de diferentes activaciones emocionales en la corteza orbitofrontal, es un ejemplo del *valence* en el cerebro. Se muestra cómo aumenta la actividad neuronal relacionada a la sensación de placer. Los estímulos no placenteros se

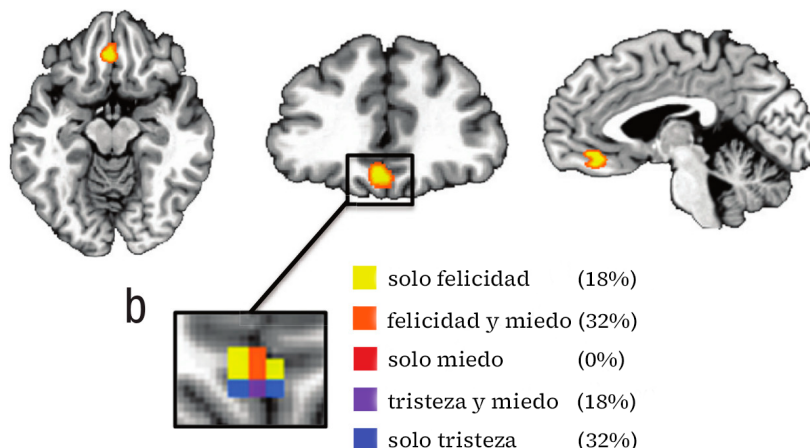


Figura 2.2: *valence* en el cerebro. Figura traducida de (121).

disminuyen, mientras se incrementan los placenteros. En (121) se encuentra una muestra análoga a la activación del *valence* pero relacionada con el *arousal*, cuya zona de activación es la amígdala.

A partir de sus resultados, en (121) sugieren que el *valence* es una propiedad básica de la experiencia emocional humana. El afecto a partir de un conjunto discreto de emociones (núcleo afectivo) es un ingrediente básico de los fenómenos psicológicos. Identificaron que existe correlación neuronal entre la experiencia afectiva definida a partir del núcleo afectivo y la experiencia afectiva de sensaciones simples. Existen trabajos donde definen un núcleo emocional o conjunto discreto de emociones básicas para intentar describir los fenómenos emocionales (39). Incluso hay publicaciones (48) que la defienden ante críticas que proponen desechar completamente tal teoría emocional. En (97) apoyan la teoría dimensional ya que sugieren que el modelo de emociones básicas no es capaz de explicar todas las observaciones empíricas en las neurociencias afectivas.

En (133) se investiga sobre patrones estables en el tiempo inmersos en las señales de EEG. Los patrones están relacionados con la firma neuronal de las emociones en el cerebro. Las emociones se presentan en las regiones del cerebro como circuitos neuronales y no como módulos aislados encargados del procesamiento de las diferentes emociones. Los patrones inmersos en las activaciones neuronales se mantienen relativamente estables en los individuos entre las sesiones y en las regiones cerebrales. Se ha identificado la presencia

de las firmas neuronales para tres emociones: positiva, negativa y neutral. Los rangos de frecuencia *gamma* y *beta* muestran mayor activación ante emociones positivas que negativas dentro de las áreas laterales temporales. La banda de frecuencia *delta* tiene mayor respuesta a la presencia de emociones neutras en las zonas parietal y occipital, en las zonas prefrontales las respuestas altas se producen en *gamma*.

2.1.2. Las emociones y la toma de decisiones

La relación que existe entre la razón y la emoción ha evolucionado a través del tiempo. En el racionalismo clásico (siglo XVII), Descartes señala una separación entre emoción y razón pues para él, el intelecto es necesario para el dominio y comprensión del conocimiento del mundo que nos rodea. Citando una frase de Rene Descartes “primero pienso y luego existo”, se pone en pie la idea de que la emoción es ajena a la razón pues ésta no debe ser estorbada por la pasión. Para el filósofo, la razón es la facultad de distinguir lo verdadero de lo falso. A través del tiempo esta visión ha cambiado pues se ha encontrado evidencia que ambos términos están estrechamente relacionados, no son incompatibles.

Por otro lado, António Damásio muestra a través de distintos casos de estudio que las emociones, los sentimientos y la regulación biológica, juegan un papel en la razón humana (25). Señala que son un puente entre los procesos racionales y no racionales. Para Damásio, el propósito del razonamiento es decidir y la naturaleza de la decisión es la elección de una opción. El razonamiento se produce por medio de distintos sistemas cerebrales que trabajan en conjunto. Estos sistemas se encuentran organizados en distintos niveles neuronales, partiendo desde la corteza cerebral (parte superior) hasta el hipotálamo y el tronco encefálico (parte inferior), cooperan entre sí para la toma de decisiones.

En el trabajo de Damásio se puede ver su visión conciliadora y unificadora de la razón con la emoción, para Damasio (1994) “Las emociones no son un lujo, sin embargo, desempeñan un papel en la comunicación de significados, y pueden también actuar de guías cognitivos”(p. 203). Para desentrañar el papel de las emociones en la toma de decisiones, Damásio menciona dos tipos de emociones: las primarias y las secundarias. Las emociones primarias consisten en aquellas reacciones emocionales inconscientes que surgen ante ciertas características de los estímulos. Por ejemplo, el movimiento de un animal (puede ser

rápido y agresivo como una serpiente), su color (puede ser venenoso, como una rana de color vívido), si tiene garras (puede hacernos daño). Sin embargo, este tipo de reacciones se desarrollan para cumplir un objetivo útil, escapar de un predador, evitar intoxicarse, entre otras. Las sensaciones de la emoción se enlazan con los objetos que la provocan, pues las reacciones pueden ser innatas o debido a la propia experiencia específica con dicho objeto. Las emociones secundarias son aquellas reacciones producidas por imágenes mentales, los cuales son las consideraciones conscientes y deliberadas sobre una persona, objeto o situación. Las señales producidas tras el procesamiento de las imágenes mentales provocan respuestas involuntarias y automáticas en la corteza prefrontal. Damásio señala que las respuestas provienen de representaciones disposicionales, las cuales enlazan las respuestas emocionales con ciertas situaciones, esto a su vez conforma la experiencia emocional individual. Las representaciones disposicionales responden activando los núcleos del sistema nervioso autónomo, envían señales al sistema motor (por ejemplo, genera cambios en los gestos faciales) o activan los sistemas endocrino y peptídico, entre otros.

Las ideas presentadas en esta sección provienen del trabajo de Damásio (25), el cual nos demuestra sus ideas revolucionarias donde apoya el marcador somático. Las emociones juegan un papel importante en la toma de decisiones. La visión antigua de Descartes no es la forma natural en la que los humanos tomamos decisiones. La toma de decisiones consiste en seleccionar una opción entre otras. Si partimos de la visión de Descartes, se tendría que evaluar de manera rigurosa y objetiva para tomar la mejor decisión; si aplicamos el mismo método ante todas las tomas de decisiones a las cuales nos enfrentamos durante el día sería un proceso desgastante. La toma de decisiones, proceso fundamental de nuestra supervivencia, sirve como el medio para evaluar una opción y predecir su resultado con base en nuestra experiencia emocional. Con los resultados de las evaluaciones buscamos predecir el resultado a corto, mediano o largo plazo. Considerar todos los posibles escenarios con todos los posibles resultados no siempre es una tarea fácil pues surgen ocasiones donde la toma de decisiones tiene que ser inmediata y no se dispone del tiempo necesario para evaluar todos los posibles escenarios.

Para afrontar el problema de seleccionar una opción en un espacio de búsqueda enorme, las emociones funcionan como un mecanismo de selección pues las reacciones emocionales son

producto de la experiencia emocional y el conocimiento asociado al problema. Cuando percibimos un estímulo externo el cual nos obliga a afrontar un problema de toma de decisiones, se producen cambios en el estado del cuerpo que son producto de las reacciones emocionales. Las imágenes mentales producen reacciones que despiertan nuestra intuición, la cual nos ofrece el resultado de una elección.

Las sensaciones específicas, producto de la respuesta emocional, son nombrados por Damásio como marcadores somáticos. Estos mejoran la exactitud del proceso de decisión; son las relaciones entre el estímulo y el resultado de seleccionar una opción. Las emociones se pueden enlazar a objetos o eventos y nos permiten obtener retroalimentación acerca del ciclo de interacción. Por tal motivo juegan un papel importante en el cómputo afectivo (14).

Cuando nos presentamos ante una toma de decisiones, se producen cambios en la actividad neuronal que pueden ser detectados a través del EEG. Para estudiar sus efectos en la actividad neuronal del DM, se le somete a una tarea en la cual debe buscar lograr la mayor ganancia o cumplir un objetivo por medio de la selección de una opción o alternativa en cada iteración del experimento. En (23) al DM se le presenta un subconjunto de tres figuras de un total de seis, en cada toma de decisiones. En (112) un tercero le hace propuestas monetarias al DM que debe aceptar o rechazar; estas pueden ser justas donde ambos ganan la misma cantidad de dinero, injustas donde el que la propone gana mayor cantidad o moderadamente justas. En (37) se presentan una serie de celulares al DM, donde tiene que seleccionar si le gusta, no le gusta o si lo compraría. En (122) se le presentan cuatro cartas donde dos de ellas son recompensas monetarias y las restantes un castigo. En dichos trabajos las preferencias son analizadas a través del EEG; se obtienen a partir de diferentes regiones del cerebro utilizando el sistema internacional 10-20. La confianza del DM en su toma de decisiones, típicamente se asocia con las regiones frontales o parietales (117), aunque también se ha encontrado su presencia en la corteza de asociación somatosensorial, la corteza prefrontal dorsolateral y la corteza visual primaria (122). Los intervalos de frecuencia utilizados son, δ , θ , α , β y γ . En los estudios de la detección emocional son los intervalos de frecuencia utilizados.

2.1.3. Respuestas emocionales

Las respuestas emocionales pueden ser identificadas mediante cuestionarios, respuestas fisiológicas y análisis del comportamiento. En el análisis del comportamiento, la detección de emociones se puede realizar por medio de información del rostro, posturas del cuerpo, entonación del habla, entre otros. Las emociones pueden perturbar las funciones básicas en el ser humano, como por ejemplo cambios en la temperatura o en el ritmo cardiaco, y estas se hacen presentes ante estímulos emocionales reales o imaginarios (68). En las señales fisiológicas encontramos la actividad neuronal, la actividad rítmica del corazón, la respuesta galvánica de la piel, por mencionar algunos ejemplos. En el desarrollo de las teorías emocionales, se ha mostrado evidencia sobre la presencia de actividad neuronal asociada a las emociones (121, 75). En el cerebro se hacen presentes patrones emocionales y estos se mantienen relativamente estables sobre el tiempo (133). En el trabajo (133) definen a la emoción a partir de ciertos componentes afectivos básicos y buscan relacionarla con la actividad neuronal del cerebro (55, 39).

La interacción de las neuronas se produce por la transmisión de impulsos eléctricos generados en el cuerpo de la célula, que son conducidos al exterior por medio del axón y recibidos por otra célula por medio de las dendritas (36). Cuando se genera un impulso eléctrico se produce una diferencia de potencial eléctrico, el cual puede ser medido por el electroencefalograma. Nuestro cerebro cuenta con miles de millones de neuronas que interactúan entre sí, lo cual hace que se produzcan los fenómenos mentales.

Las señales de electroencefalograma capturan la actividad neuronal pero estas son muy susceptibles a ser contaminadas por agentes externos, los aparatos electrónicos producen campos electromagnéticos, los cuales son capturados por los sensores del dispositivo de EEG. Los celulares, computadoras, luces y la instalación eléctrica de la habitación, son ejemplo de los dispositivos que pueden contaminar la señales e introducen ruido, lo cual dificulta detectar apropiadamente las emociones expresadas tras el estímulo presentado al sujeto de prueba. A este tipo de ruido se le denomina ruido ambiental y debe ser tomado en cuenta en el diseño del experimento. En (38) el ruido ambiental se elimina por medio de un filtro *notch*.

Un segundo tipo de ruido presente en la señal de EEG es el ruido fisiológico, el cual se produce por fenómenos internos del cuerpo humano, entre ellos podemos encontrar el electrooculograma (EOG) que es la actividad del movimiento de los músculos de los ojos, el electrocardiograma (ECG) la actividad eléctrica del corazón, el electromiograma (EMG) que mide la actividad eléctrica de los músculos y nervios, entre otros. Es importante eliminar o controlar este ruido pues puede complicar la predicción de los estados emocionales. Estos fenómenos físicos se hacen presentes en la señal de electroencefalograma por medio de una serie de componentes, sus rangos de frecuencia son mucho mayores a las frecuencias donde se hacen presente los fenómenos emocionales.

2.1.4. Preprocesamiento de las señales de EEG

Las señales de electroencefalograma son muy susceptibles a ser contaminadas por ruido externo, una de las principales fuentes que insertan ruido en las señales de EEG es el campo electromagnético generado por la instalación eléctrica. La frecuencia de la corriente alterna son 50Hz o 60Hz, dependiendo de la ubicación geográfica donde se realiza el experimento; en México es de 60Hz. Estas frecuencias provocan artefactos en la señal de EEG debido a que generan que un electrodo posea mayor impedancia que el resto de los electrodos respecto a la tierra del amplificador. En consecuencia, la tierra funciona como un nodo activo, produciendo dichos artefactos (103). Adicionalmente, el ruido de baja frecuencia y los armónicos son indeseables, ya que interfieren con las señales de EEG que se producen en esos mismos rangos de frecuencia.

Se pueden aplicar técnicas y estrategias para minimizar los artefactos. En (42), los autores le indican a los sujetos que permanezcan lo más quietos posible y que enfoquen la vista en una cruz cada vez que se presente, con el propósito de minimizar los artefactos producto del movimiento muscular y de los ojos, respectivamente.

El filtro paso banda permite sólo el paso de las frecuencias que guardan información emocional. Los intervalos de las bandas de frecuencia (82) son: *delta* (0-3 Hz), *theta* (4-7 Hz), *low alpha* (8-9.5 Hz), *high alpha* (10.5-12 Hz), *alpha* (8-12 Hz), *low beta* (13-16 Hz), *mid beta* (17-20 Hz), *high beta* (21-29 Hz), *beta* (13-29 Hz), y *gamma* (30-50 Hz); aunque en diferentes trabajos los rangos difieren en cierto grado (73, 1, 54, 71).

Pueden implementarse técnicas como el análisis de componentes independientes (ICA, por las siglas en inglés de *Independent Component Analysis*), la cual está basada en descomposición ciega. El objetivo de ICA es descomponer la señal de electroencefalograma en una serie de componentes, para nuestro caso deseamos separar la señal de EEG en sus componentes emocionales y los artefactos. ICA trabaja bajo el supuesto de que hay en el cerebro un número de componentes igual al número de canales usados en el casco de EEG. Los artefactos se capturan por medio de los componentes, basta con eliminarlos y al momento de reconstruir la señal, esta vendrá limpia y sin la presencia de los artefactos ya que se han eliminado las frecuencias que los componen. La implementación de ICA para la eliminación automática de artefactos no es una tarea trivial, no basta con identificar los componentes que hacen referencia a los artefactos, se debe construir una base de datos extensa de todos los diferentes tipos de artefactos que se desean detectar. Esta técnica necesita desarrollarse por materia especializada, ya que la base de datos debe ser construida por un profesional del área que identifique correctamente cada uno de los artefactos para su correcto etiquetado.

2.1.5. Detección automática de emociones

La detección automática de emociones es un campo de gran interés para muchas áreas que necesitan tener información sobre los estados emocionales del ser humano, por mencionar algunas: el *marketing* para el estudio de la preferencia por productos *premium* (15), la psicología en el estudio de psicopatologías (3) o el cómputo afectivo (91). A partir de la captura de señales de distintas fuentes biológicas o medidas de su comportamiento, como el tono de voz o el texto, se pueden capturar las emociones.

Aprendizaje de máquina

Comúnmente, el flujo de trabajo para la detección automática de emociones se compone de tres etapas. La primera etapa consiste en la adquisición de la señal de electroencefalograma y su preprocesamiento. En esta etapa se busca eliminar las características indeseadas de la señal y, con ello, facilitar el análisis en etapas posteriores. En la segunda

etapa se transforman los datos en una serie de componentes que son equivalentes pero en un dominio diferente. Estos componentes se utilizan para la extracción de las características. En la tercera etapa se utiliza un clasificador, el cual deberá aprender a partir de las características extraídas a predecir emociones con señales que no haya visto. Este es el flujo tradicional de las técnicas artesanales de aprendizaje de máquina destinadas a la detección automática de emociones. En trabajos como (42) hacen un estudio riguroso sobre la utilización de distintos extractores de características con diferentes clasificadores. Las características son extraídas a partir de transformaciones a las señales de EEG y un análisis basado en técnicas de tiempo-frecuencia. En (93) proponen HOC (por las siglas en inglés de *Higher Order Crossings*), una formulación para la extracción de características de las señales de EEG. Los autores de dicho trabajo realizan una comparación entre su método y otros dos, un método estadístico y uno basado en *wavelets*. En el estudio (6), se mencionan otros métodos de extracción de características, por ejemplo, *Common Spatial Pattern* (CSP), *Spectral Power Asymmetry* (ASM), *Higher Order Spectra* (HOS), *Asymmetric Spatial Pattern* (ASP) y *Fractal Dimension* (FD).

Por otro lado, los autores de (133) presentan un estudio sobre las firmas emocionales en el cerebro como patrones de activación; además, proponen un conjunto de datos llamado SEED, el cual está destinado al estudio de dichos patrones. A partir de sus trabajos anteriores, los autores llegan a la conclusión que su método es eficiente al combinar 62 canales, basados en el sistema 10-20, y seis diferentes métodos para la extracción de características: *Power Spectral Density* (PSD), *Differential Entropy* (DE), *Differential Asymmetry* (DASM), *Rational Asymmetry* (RASM), *Asymmetry* (ASM) y *Differential Caudality* (DCAU). Utilizan tres clasificadores: KNN (por las siglas en inglés *K-Nearest Neighbor*), SVM (por las siglas en inglés *Support Vector Machine*), Regresión logística y GELM (por las siglas en inglés de *Discriminative Graph Regularized Extreme Learning Machine*).

La detección automática de emociones con técnicas de aprendizaje de máquina comenzó con la utilización de métodos de aprendizaje poco profundos. En los trabajos de (134), (74) y (120) utilizan SVM, el cual es un tipo de aprendizaje introducido a principios de los 90's. Analizan las emociones como un conjunto discreto de cuatro emociones (74, 120).

Las emociones básicas utilizadas son felicidad, enojo, tristeza y calma; cabe mencionar que dichas emociones las vemos como una forma análoga a los cuadrantes del modelo emocional basado en *valence* y *arousal* (emociones que representan al cuadrante de forma general). En dichos trabajos se observa la comparativa con otros métodos de aprendizaje poco profundo, entre ellos podemos encontrar algoritmos como *K-Nearest Neighbor*, *Bayesian Network*, y redes neuronales completamente conectadas poco profundas. Estos métodos de aprendizaje poco profundo aprenden representaciones menos complejas y sofisticadas de los datos en comparación a algoritmos que poseen más niveles de procesamiento como lo son las redes neuronales con muchas capas. En (2), se realiza un estudio sobre la detección automática de emociones. Los autores analizan una lista de artículos cuya publicación sea entre 2009 y 2016 y muestran cómo las máquinas de vectores de soporte eran el método más utilizado, era poco el uso de redes neuronales y las propuestas eran redes mayormente de complejidad baja, osea, poseían pocas capas. En (6) también encontramos una revisión de artículos; se observa en el trabajo el sobresaliente uso de SVM respecto a otros métodos de aprendizaje de máquina.

Aprendizaje profundo

Las CNN (por las siglas en inglés de *Convolutional Neuronal Network*) han tenido éxito en distintas áreas de aplicación (95). Para mejorar su exactitud, agregan nuevas etapas de procesamiento: cambian el tamaño de las imágenes, recortan ciertas secciones de éstas y agregan ruido, por mencionar algunas.

En (107) se propone el uso de una CNN para aprender los patrones emocionales captados en imágenes de rostros, mientras escuchan una lista de canciones. Este tipo de redes incluso se han utilizado en trabajos multimodales (85); es decir, en conjunto con los datos del rostro se utiliza información de distintos tipos: señales de EEG, seguimiento de los movimientos de los ojos e información del rostro con imágenes RGB y de profundidad. Además, utilizan el modelo de *valence* y *arousal* para realizar el estudio emocional. Existe una gran variedad de trabajos que analizan el rostro humano para la detección de emociones (113, 108, 30). En particular, los autores de (13) presentan desde métodos clásicos hasta trabajos que utilizan redes neuronales.

Por otro lado, podemos encontrar trabajos donde usan el habla para el reconocimiento de emociones. Por ejemplo, en (111) utilizan modelos ocultos de Markov, mientras que en (66) hacen uso de AlexNet, una versión preentrenada de una red neuronal para la clasificación de imágenes. En la detección automática se pueden utilizar múltiples recursos biológicos que contengan información sobre los componentes emocionales del sujeto. En (131), se trata el reconocimiento de emociones con base en el habla por medio de una red de fusión de atención de múltiples cabezas; los autores combinan los datos del habla con los datos de otras fuentes, entre ellas encontramos transcripciones de voz a texto, capturas de movimientos, expresiones faciales cuando el sujeto está hablando, acciones de la mano y rotaciones de la cabeza.

En el área de Procesamiento de Lenguaje Natural investigan la detección automática de sentimientos, la cual está indirectamente relacionada con las emociones. En trabajos como en (50), se observa el interés de los desarrolladores de fármacos para entender los sentimientos de los usuarios. Por medio de reseñas textuales de 100 fármacos se busca la detección automática de sentimientos usando BERT (por las siglas en inglés de *Bidirectional Encoder Representations from Transformers*), la cual es una red neuronal basada en *transformers*.

Por otro lado, la técnica por la cual se captura la actividad rítmica del corazón es llamada electrocardiograma (ECG, por las siglas en inglés de *Electrocardiogram*). Los cambios en las fluctuaciones de la actividad del corazón se encuentran relacionadas con el sistema nervioso central (38), por lo que su análisis es de utilidad para la detección de emociones. En el estudio (38) extraen información emocional del ECG, la cual es generada a partir de la aplicación del paradigma pictórico de evocación de emociones. Utilizan el conjunto de datos *International Affective Picture System*, donde extraen imágenes que caen dentro de cuatro clases de emociones. En (88) proponen una nueva arquitectura de una CNN de siete capas, la cual es utilizada para la detección automática de emociones a partir de los datos de ECG; estos se etiquetan en términos de *valence*, *arousal* y *dominance*.

Se han utilizado diferentes tipos de arquitecturas de redes neuronales para realizar la detección de emociones. En (70) utilizan señales EEG con mecanismos de atención, redes de cápsula (*CapsNet*) y CNN para el aprendizaje basado en múltiples tareas. Tratan la

predicción de alto/bajo *valence*, *arousal* y *dominance* como tareas separadas. Los autores de (72) proponen SFCSAN, una arquitectura que aprovecha las señales de EEG en diferentes bandas de frecuencia. SFCSAN está conformada por capas de redes convolucionales paralelas para la obtención de información espacial de la señal. Las capas de autoatención se utilizan para aprender información de las distintas bandas de frecuencias y el mapeo de banda de infrafrecuencia. En (71) proponen una CNN de nueve capas donde seis de ellas se componen de capas consecutivas de una capa convolucional seguida de una de *max-pooling*, las últimas tres son capas de una red completamente conectada. Las señales de EEG son transformadas a imágenes, las cuales son la entrada de la CNN. En (16) proponen arquitecturas de CNN, estas son comparadas con otros métodos de aprendizaje poco profundo. Las arquitecturas son evaluadas por medio de diferentes extractores de características, aplicados al dominio de la frecuencia, el tiempo y combinadas. Cabe mencionar que los resultados se presentan para *valence* y *arousal* de manera separada, ya que son tratados como problemas de clasificación binaria. Los autores de (46) toman como base de su estudio la asimetría del cerebro, los hemisferios derecho e izquierdo del cerebro tienen distintas respuestas emocionales ante iguales o diferentes emociones.

Por otro lado, Zhou y Feng (135) desarrollaron otro tipo de método de aprendizaje, llamado *Deep Forest*. Este método cambia el enfoque tradicional de la neurona, en el que ésta deja de ser vista como el *perceptron*; es decir, ya no es una suma ponderada cuyo resultado se pasa por una función de activación. En contraste, se propone un reemplazo por el concepto de bosque aleatorio. Un bosque aleatorio está conformado por un conjunto de árboles de decisión. En una capa se encuentran n bosques aleatorios y se pueden ir agregando capas de forma dinámica. El dominio de las características aprendidas entre las capas es el mismo; esto no sucede con el enfoque tradicional. Por ejemplo, en las CNN hay distintos filtros entre capas que provocan que cambie el dominio de las características. *Deep Forest* está diseñado para aumentar su complejidad de forma dinámica, o sea, modifica su arquitectura incrementando el número de capas en tiempo de entrenamiento. El número final de capas de todo el modelo se determina con base en la métrica de exactitud (*accuracy*). Esta propiedad le permite adaptarse al tamaño del conjunto de datos y reduce el problema de establecer el tamaño óptimo de la red neuronal. *Deep Forest* se ha aplicado

con éxito en la tarea de la detección automática de emociones. De hecho, en (17) los autores consiguen una exactitud de 97.69 % y 97.53 % para los valores de *valence* y *arousal*, respectivamente.

Se han realizado estudios de detección de los componentes emocionales independientes del sujeto (98). Este tipo de pruebas consiste en comprobar la efectividad del clasificador con datos de sujetos que no se hayan utilizado durante la etapa de entrenamiento. La detección automática de emociones con una prueba independiente del sujeto es una tarea complicada en las ciencias afectivas, ya que los componentes emocionales para cada sujeto tienden a ser diferentes. Esta problemática no solo se presenta en las señales de EEG, encontramos ejemplos en (30). En dicho trabajo proponen un método para la detección de las emociones a partir de los gestos faciales; la arquitectura aprende los patrones afectivos del rostro a partir de un conjunto de sujetos y con ello realizan predicciones a sujetos desconocidos por la red.

Existen diferentes paradigmas de BCI para extraer cierta información de la actividad neuronal. Se han desarrollado arquitecturas basadas en CNN (109) para decodificar información inmersa en las señales de EEG relacionadas a la tarea bajo análisis. *EEGNet* (65) es una CNN desarrollada para ser usada en múltiples paradigmas BCI; se consideró en el diseño de su arquitectura ser lo más compacta posible. En (109) se proponen *DeepConvNet* y *ShallowConvNet*, arquitecturas con las cuales estudian el aprendizaje de estas redes en distintos problemas de imaginación motora, a través de distintos conjuntos de datos que varían en tamaño, número de electrodos o número de clases, por mencionar algunas.

En trabajos más recientes sobre la detección emocional, se ve una tendencia hacia el uso del aprendizaje profundo. En (82), llevan a cabo una comparación entre arquitecturas de CNN con diferente profundidad. En (10) se muestra cómo las redes completamente conectadas o perceptrón multicapa MLP (por las siglas en inglés de *Multilayer Perceptron*), muestran mejoría en los resultados respecto a SVM y KNN. En (129) se propone una red convolucional multicolumna. En (49) se presenta una CNN donde la última capa son neuronas completamente conectadas, se conectan a una red *Long Short-Term Memory*. Encontramos arquitecturas de CNN que se combinan con un *Sparse Autoencoder* y una red completamente conectada (FCN por las siglas en inglés de *Fully Connected Network*) (76).

La última capa de la CNN es una capa de *max-pooling* cuya salida se pasa al *autoencoder*, con el fin de reconstruir los datos. La salida del *autoencoder* es enviada a la FCN. Sin embargo, la CNN y el *autoencoder* son entrenadas por separado, ya que son vistas como la etapa de extracción de características durante el entrenamiento de la FCN. Finalmente, la red completamente conectada se encarga de realizar la predicción.

2.1.6. Conjuntos de datos de experimentación

Existen diferentes conjuntos de datos que permiten analizar los estados emocionales. Nosotros estamos interesados en aquellos que posean las grabaciones de las señales de electroencefalograma. El conjunto de datos DEAP (59) está dirigido al estudio de los estados emocionales del ser humano. Su protocolo de adquisición consiste en poner a los sujetos de prueba a observar una serie de videos musicales; mientras los videos se reproducen, se graban las señales de EEG. Los videos buscan evocar distintas emociones que posean diferencias remarcadas en sus componentes emocionales. DEAP es ampliamente utilizado para evaluar algoritmos de detección de emociones (129, 46, 82, 133, 129). El conjunto de datos DREAMER almacena señales de EEG y ECG durante varias estimulaciones audiovisuales (88). Existen trabajos donde hacen uso más de un conjunto de datos para su estudio emocional, en (17, 70) hacen uso de DEAP y DREAMER. El conjunto de datos SEED (133) se construye con base en un estudio de patrones estables en el tiempo. Las emociones se asocian con la actividad neuronal por medio de patrones de activación que se mantienen relativamente estables.

Hay trabajos que estudian la emoción pero con distintos modelos emocionales (104). Los modelos emocionales nos permiten cuantificar las emociones, lo que facilita su uso en algoritmos computacionales. En (115) diseñan una base de datos con las evaluaciones de *valence*, *arousal* y *dominance*. La primera hace referencia a si fue agradable o desagradable y en qué grado. La segunda es la intensidad de la emoción. La última se refiere al control de las emociones y las restricciones a causa de barreras sociales o físicas (115).

2.2. Optimización multiobjetivo

Encontrar la mejor solución o soluciones a un problema no siempre es una tarea trivial. Hay una serie de objetivos asociados que se buscan optimizar. Estos pueden encontrarse en conflicto, por lo que, encontrar los mejores valores para dichos objetivos es una tarea compleja. Por ejemplo, en (34) se trata al problema de planeación de trayectorias factibles de un brazo robótico como un problema de optimización, la búsqueda se realiza en base a la optimización de dos objetivos, minimizar la distancia de recorrido de las articulaciones del robot y la distancia cartesiana de la muñeca del brazo robótico desde su punto inicial a su posición final.

Se ha extendido el uso de metaheurísticas en el proceso de optimización de problemas con muchos objetivos, éstos algoritmos se inspiran en procesos en la naturaleza para encontrar la/las soluciones óptimas. Existe el que imita una colonia de hormigas: en (124) se propone su uso con mejoras para realizar la planeación de rutas de un robot móvil o el que determina el suministro eléctrico minimizando su coste operacional (100), por mencionar algunos ejemplos. Existen otros tipos de metaheurísticas, entre ellas encontramos el recocido simulado (58, 24), la búsqueda tabú (31), el enjambre de partículas (43) y los algoritmos evolutivos (29). Algunas de las metaheurísticas mencionadas se utilizan en problemas relacionados a la tecnología, por ejemplo, en el balanceo de recursos para el *cloud computing* (127). Los algoritmos evolutivos multiobjetivo son metaheurísticas que explotan los mecanismos de la evolución para buscar la mejor solución a problemas de optimización multiobjetivo. Estos algoritmos son nombrados MOEA (por las siglas en inglés de *Multi Objective Evolutionary Algorithm*).

Existen trabajos donde se han utilizado técnicas de optimización multiobjetivo en combinación con redes neuronales (118) para resolver problemas complejos, y que son de utilidad en el área de aprendizaje de máquina. Por ejemplo, en (69), con el uso de SPEA2 se busca la mejor topología de una red neuronal; utilizan la complejidad de la red y el *accuracy* como funciones objetivo.

Los MOEA nos permiten encontrar soluciones a problemas muy complejos: las soluciones van mejorando iterativamente durante el proceso de búsqueda. En (94) realizan la

planeación de trayectorias de un brazo robótico; la búsqueda de la mejor ruta se realiza minimizando la distancia recorrida por las articulaciones y la muñeca del robot. Similarmen- te, en (52) podemos encontrar un trabajo de planeación de rutas para un brazo robótico en el que se incorporan más objetivos en la búsqueda; entre ellas podemos encontrar el número de activaciones producidas por una posible colisión, la cual es útil para trabajar en entornos con objetos y evitar colisionar con ellos.

En (21) encontramos una lista de los algoritmos más importantes a finales del siglo XX dentro del área de optimización multiobjetivo. En el trabajo se explican las raíces funcionales de los algoritmos y citan algunos trabajos relacionados a su uso en aplicaciones del mundo real, esto con el fin de incentivar el desarrollo del área. En la lista de los algoritmos podemos encontrar MOGA (*Multiple Objective Genetic Algorithm*), NSGA (*Nondominated Sorting Genetic Algorithm*), NPGA (*Niched-Pareto Genetic Algorithm*) y NPGA2. Forman parte de la primera generación de algoritmos de optimización multiobjetivo (21) y se consideran los esfuerzos iniciales para incorporar la dominancia de Pareto a los algoritmos evolutivos (20).

En la segunda generación de algoritmos evolutivos multiobjetivo se incorpora el elitismo (20). El concepto de elitismo se refiere a la conservación de los individuos no dominados durante el proceso evolutivo. En esta generación encontramos algoritmos como SPEA (por las siglas en inglés de *Strength Pareto Evolutionary Algorithm*) (138) y SPEA2 (57), en los cuales la aptitud de cada individuo se calcula con base en los individuos que la dominan. En SPEA2 se incorporan mecanismos para mejorar la búsqueda realizada por medio del entrecruzamiento; para mantener la diversidad de las soluciones, se guarda la representación de los individuos en el espacios de los objetivos y las variables. En el algoritmo evolutivo NSGA también se incorporan mejoras, con lo que se propone NSGA-II (28, 29). El algoritmo NSGA-II se diseña tomando en cuenta una serie de problemas que salieron a flote con el uso de los MOEA “poseían una complejidad computacional $O(MN^3)$ (donde M y N son el número de objetivos e individuos, respectivamente), falta de elitismo y la necesidad de establecer un parámetro compartido”(Deb et al., 2002, p. 182). Los autores de (29) proponen soluciones para mitigar dichos problemas, su mayor aportación fue su enfoque para el ordenamiento de las soluciones no dominadas, disminuyendo a una complejidad

$O(MN^2)$.

Existe un tipo de algoritmos que convierten un problema multiobjetivo a uno mono-objetivo, descomponen el problema en un conjunto de subproblemas de optimización escalar, son conocidos como algoritmos de descomposición. Los dos grandes exponentes son NSGA-III (27, 51) y MOEA/D (*Multiobjective Evolutionary Algorithm Based on Decomposition*, por sus siglas en inglés) (132). En MOEA/D “los subproblemas se optimizan usando información de varios subproblemas vecinos, dotándolo de una complejidad computacional menor”(Zhang y Li, 2007, p. 712). Existen diferentes enfoques de descomposición, los usados en los estudios experimentales de MOEA/D: suma ponderada, Tchebycheff e intersección de límites (BI, por las siglas en inglés de *Boundary Intersection*). En el algoritmo NSGA-III a partir de una serie de puntos de referencia perfectamente distribuidos, se define un hiperplano, el cual sirve para descomponer el problema multiobjetivo (27). Los puntos forman nichos y son el medio para seleccionar a los individuos de la siguiente generación.

Existen problemas donde el MOEA supera a su versión más reciente. El algoritmo NSGA-II ha demostrado funcionar en problemas multiobjetivo (igual o menor a tres objetivos), superando a su versión más reciente, NSGA-III. En (53) utilizan tres objetivos, por medio de sus resultados experimentales NSGA-II demuestra mayor rendimiento en comparación a su versión más reciente NSGA-III, ya que este último está diseñado para trabajar con muchos objetivos (27). En el área de optimización multiobjetivo, muchos objetivos son comúnmente igual o mayor a cuatro objetivos. El algoritmo NSGA-II sigue teniendo influencia en trabajos recientes, en temas relevantes como lo es la generación de residuos líquidos peligrosos y gases de efecto invernadero (56), se ha mezclado con otras metahurísticas para el desarrollo de planes efectivos de emergencia (62) o el enrutamiento para sistemas de drones de entrega (63). En temas relacionados al aprendizaje de máquina, el algoritmo se ha utilizado en temas de poda de arquitecturas de redes neuronales (83), optimización para algoritmos de clustering (99), en combinación con bosques aleatorios (90), entrenamiento de redes neuronales con el uso del *accuracy* en la función objetivo (130), por mencionar algunos trabajos.

En (33) los autores proponen una taxonomía para los MOEA basadas en indicadores, este tipo de algoritmos optimizan el problema multiobjetivo en base a un indicador de

calidad. Dicho indicador es usado para establecer los mecanismos de selección de los individuos, su optimización se lleva a cabo por medio del proceso evolutivo. El algoritmo más representativo de esta generación es SMS-EMOA (8), utiliza el hipervolumen como indicador de calidad. Pueden combinarse con múltiples indicadores, “la selección del indicador puede ser usado en un momento particular durante la búsqueda”(Falcón-Cardona y Coello, 2018). Estos algoritmos junto con los algoritmos basados en descomposición se han utilizado en problemas con muchos objetivos. En trabajo futuro pueden ser de utilidad para estudiar la optimización de nuestros neurocontroladores con muchos objetivos.

2.2.1. Incorporación de preferencias

Encontrar soluciones con los MOEA que se aproximen al frente de Pareto real no siempre resuelve el problema. La persona encargada de seleccionar la solución del problema es el tomador de decisiones. El tomador de decisiones guía el proceso evolutivo por medio de la incorporación de sus preferencias y así llegar a soluciones con características deseadas. Los métodos para realizar la incorporación de las preferencias (IMO, por las siglas en ingles de *Interactive Multiobjective Optimization*) se dividen en tres (126):

1. A priori: las preferencias se dan antes de realizar la búsqueda.
2. A posteriori: se encuentra una aproximación al frente y selecciona la solución preferida.
3. Interactivo: El DM incorpora las preferencias progresivamente durante el proceso de búsqueda y la guía hacia regiones preferidas.

En (126) proponen una taxonomía de las IMO, éstas se dividen en: expectativa, comparación de funciones objetivo y comparación de soluciones. El método que utilizamos para la incorporación de preferencias cae en la categoría de métodos de expectativa, ya que está basado en un punto de referencia. Hay métodos basados en puntos de referencia que poseen la propiedad de poderse incorporar en otros algoritmos evolutivos multiobjetivo con facilidad, ya que solo se necesitan hacer pequeñas modificaciones en la estructura básica

del algoritmo evolutivo (78). También poseen la propiedad de incorporarse a problemas con muchos objetivos pues implementa una función de logro para tratarlos.

2.3. Interacción humano-robot

El interés por la interacción humano-robot (HRI, por las siglas en inglés de *Human-Robot Interaction*) ha crecido recientemente. Por ejemplo, la HRI, en combinación con la detección de emociones, se ha utilizado en robots que pueden ser de utilidad para mejorar el vocabulario en niños (61). El desarrollo de sistemas que puedan crear una interacción emocional entre humanos y robots aún se enfrenta a retos para su aplicación en entornos reales de trabajo colaborativo (18). Por otro lado, parece haber una mayor preferencia por los robots antropomórficos, cuyas características y expresiones emocionales son parecidas a las humanas, en comparación a un robot con cualquier otra forma (19). En (102) se estudian la familiaridad, simpatía y amenaza hacia un conjunto de robots, los cuales poseen características humanas en diferente grado. Los robots humanoides o andróides fueron los que resultaron más altos en familiaridad y simpatía: “Aumentar la semejanza humana de un agente artificial aumenta sensiblemente la probabilidad de que una contraparte humana confíe en él, así como la respuesta emocional asociada”(Cominelli et al., 2021). “La capacidad de un robot para sentir (experimentar) provoca sentimientos de inquietud más fuertes que la capacidad de un robot para planificar con anticipación, ejercer el autocontrol, moralidad, memoria y reconocimiento de emociones; lo que provoca más inquietud que un robot sin mente (es decir, al usar un robot como una herramienta)”(Appel et al., 2020, p. 274).

Para el desarrollo de la interacción humano-robot, en (128) introducen la noción de atmósfera de comunicación, la cual sirve para estudiar el proceso de comunicación. En (105) se define en base a tres componentes: entorno, comunicativo y emocional; se utilizan para estudiar los eventos comunicativos ya que “la comunicación humana es percibida como un sistema dinámico”(Rutkowski y Mandic, 2007, p. 157).

2.4. Sistemas para la detección emocional y toma de decisiones

Las emociones y la toma de decisiones son fenómenos que suceden en el cerebro. Existen trabajos que hacen uso del EEG para la detección de dichos fenómenos, cuyo fin está destinado al desarrollo de BCI.

Las aplicaciones de BCI se pueden clasificar en la forma en que usan al cerebro: pasivas, activas y reactivas (4, 106); la primera consiste en detectar los estados afectivos o cognitivos no intencionales del cerebro, la segunda involucra la intención voluntaria del usuario y la tercera son las respuestas neuronales generadas por una estimulación externa. En (4) se discute la creación de BCI artísticas para la comprensión de los estados emocionales; son vistas principalmente desde la perspectiva de BCI pasiva. Se han desarrollado juegos por el uso de BCI activas (35), donde el usuario intenta mover un cuadrado a posiciones específicas. Por medio de la estimulación del usuario con videos, se desarrollan BCI reactivas que detecten los estados emocionales (73).

Las BCI emocionales son herramientas que pueden servir para su aplicación en la psicología, como la detección de los estados efectivos en pacientes con síndrome de la conciencia, tales como estado de coma, estado vegetativo, estado de conciencia mínima y estado de conciencia mínima emergente (47). En situaciones donde las personas han perdido la movilidad por la esclerosis lateral amiotrófica, se ha venido investigando la implementación de éstos sistemas para el mejoramiento de la calidad de las personas apoyando a sus cuidadores en su labor (86).

Las aplicaciones de estos sistemas no solo tienen alcance en el área de la salud. Se han desarrollado sistemas para el reconocimiento emocional en tiempo real (77) con múltiples aplicaciones, entre ellas se encuentran la aplicación de terapias musicales, ya sea el manejo del dolor, el estrés, entre otros; para la creación de avatares que muestran la expresión emocional del usuario; y el desarrollo de reproductores de música. En (60) los autores analizan y proponen una serie de posibles escenarios para la aplicación de sistemas de reconocimiento emocional multimodal; abarcan temas de ingeniería de software como su calidad, usabilidad o la productividad de los programadores; temas relacionados al aprendizaje,

como el aprendizaje de tareas, la evaluación de recursos para el aprendizaje; el diseño de páginas web o de videojuegos para una experiencia más inmersiva. En (74) utilizan el EEG para detectar los estados emocionales evocados por la música.

Existe una gran variedad de trabajos que utilizan aprendizaje de máquina para el desarrollo de sistemas que detecten las emociones (71, 129, 73, 17). Se han estudiado y desarrollado diferentes técnicas para la detección emocional, y su relación en el contexto de la interacción emocional (14). Los gestos del rostro son una fuente ampliamente estudiada para el desarrollo de estos sistemas (13); también se encuentra el uso del habla, el EEG o el uso multimodal a partir de las tres fuentes anteriores (79).

El proceso de la toma de decisiones puede reflejarse en la actividad neuronal y ser capturado con el EEG. En (23) estudian los efectos de la toma de decisiones en el cerebro, analizan las bandas de frecuencia δ , θ , α , β y γ ; cabe mencionar que estos intervalos de frecuencia son utilizados para la detección emocional. En dicho trabajo someten al DM a varias tomas de decisiones, en cada una se le presenta un subconjunto de tres figuras de un total de seis, a través del proceso de selección y desecho de figuras debe buscar ganar la mayor cantidad de puntos. En el trabajo comparan diferentes algoritmos de aprendizaje de máquina para comprar la detección automática de la toma de decisiones en el cerebro, dada la tarea impuesta al DM. En el desarrollo de las BCI se ha estudiado la toma de decisiones en tareas de mayor complejidad; en (117) al DM se le presentan un pasillo que simula como si se moviera a través de él, posee puertas a los lados donde cada cierto tiempo salen personajes con gorra y ocasionalmente con casco, el DM debe evaluar su confianza al decidir si uno de los sujetos traía casco. La confianza es la evaluación de nuestro propio desempeño y se refiere a la probabilidad que las decisiones sean correctas. En el trabajo proponen su algoritmo de aprendizaje de máquina para la predicción de la confianza del DM; utilizan señales de EEG y EOC (por las siglas en inglés de *electro-oculogram*). En (9) utilizan una estimulación parecida al trabajo anterior, pero ahora está dirigida a entornos militares y la toma de decisiones grupal; los DM deben decidir si los sujetos que le aparecen usan gorra o casco, a la vez proporcionan su confianza de haber seleccionado correctamente.

La corteza de asociación somatosensorial, la corteza prefrontal dorsolateral y la corteza visual primaria son áreas que juegan un papel en la toma de decisiones (122). Estas áreas

también se han utilizado en la detección emocional (59, 72, 81). El proceso de la toma de decisiones consiste en seleccionar una opción o alternativa que nos permita lograr un objetivo o cumplir con una tarea. Las emociones tienen influencia en la toma de decisiones, pueden sesgar nuestra elección.

Capítulo 3

Método propuesto

En el presente trabajo hemos desarrollado una Interfaz-Cerebro Computadora que nos permite explorar las soluciones generadas por un optimizador, basado en un algoritmo evolutivo multiobjetivo, con el fin de incorporar las preferencias del usuario por medio de la detección automática de emociones inmersas en las señales de electroencefalograma. Las emociones, al ser parte importante en la toma de decisiones, son utilizadas para guiar la búsqueda de los neurocontroladores dentro del espacio de los objetivos. Estas son consideradas como las preferencias del DM.

El neurocontrolador consiste en una red neuronal completamente conectada que conduce un robot móvil dentro de un entorno doméstico virtual. El robot cuenta con sensores de proximidad asociados a las neuronas de entrada de la red neuronal. Y la salida de la red neuronal indica la dirección y velocidad de los actuadores. La búsqueda de posibles soluciones se realiza por medio de un MOEA, en el cual el neurocontrolador es tratado como una serie de individuos que forman parte de una población y los pesos de sus neuronas son codificadas como su cromosoma. Por medio de los operadores genéticos, el MOEA evoluciona la población para encontrar dichos pesos. El proceso evolutivo es guiado con base en una serie de objetivos.

La optimización hace una aproximación al frente de Pareto real. Sin embargo, esto no resuelve del todo el problema, ya que al haber varios objetivos debe haber un compromiso al seleccionar la mejor solución (como se mencionó en el capítulo anterior). Para seleccionar la solución más adecuada para el sujeto, se incorporan sus preferencias para realizar una

búsqueda local en los frentes de diferentes generaciones. El enfoque seleccionado para incorporar las preferencias se basa en un punto de referencia, el cual sirve para seleccionar los individuos de un frente de Pareto posterior (véase la sección 3.8).

Las emociones proporcionan una evaluación subjetiva; nos ayudan a predecir el posible resultado de la selección de una opción ante una toma de decisiones. Las emociones se incorporan al algoritmo evolutivo por medio de la detección automática en las señales de EEG. Por medio de una CNN se predice la emoción evocada dentro de las señales de EEG, lo que nos ayuda a obtener información emocional del DM y con ello, determinar de forma automática el punto de referencia. Utilizamos el modelo emocional de Russell (104) para identificar e incorporar las emociones al sistema. La estimulación para la generación de respuestas emocionales es evocada por la simulación en tiempo real de los neurocontroladores. Las señales de EEG son capturadas mientras el tomador de decisiones está observando la conducción del robot dentro del entorno doméstico virtual.

3.1. Modelo emocional

Las autoevaluaciones emocionales capturadas con el SAM son la base para la interpretación de las señales de EEG, pues las teorías de los núcleos afectivos busca capturar las respuestas emocionales entre la actividad neuronal del sujeto y la estimulación a la cual es sometido. Para tratar el problema de la detección automática de emociones, hemos optado por usar el modelo dimensional de (104), el cual propone un modelo circunplejo bidimensional para la representación de todos los posibles estados emocionales. Como se mencionó en la sección 2.1), los componentes emocionales o estructurales de la emoción son: *valence* y *arousal*. El primer componente se refiere a si la emoción es positiva o negativa. El segundo está relacionado a la intensidad de la emoción, si su expresividad fue alta o baja.

En la figura 3.1 se puede observar el modelo circunplejo, los componentes emocionales son los ejes. El eje horizontal pertenece al *valence* y el vertical al *arousal*; en ambos ejes la representación de las emociones se encuentran en un rango de $[0, 1]$. El conjunto de emociones que se encuentran en cada cuadrante pueden ser referenciadas con una emoción

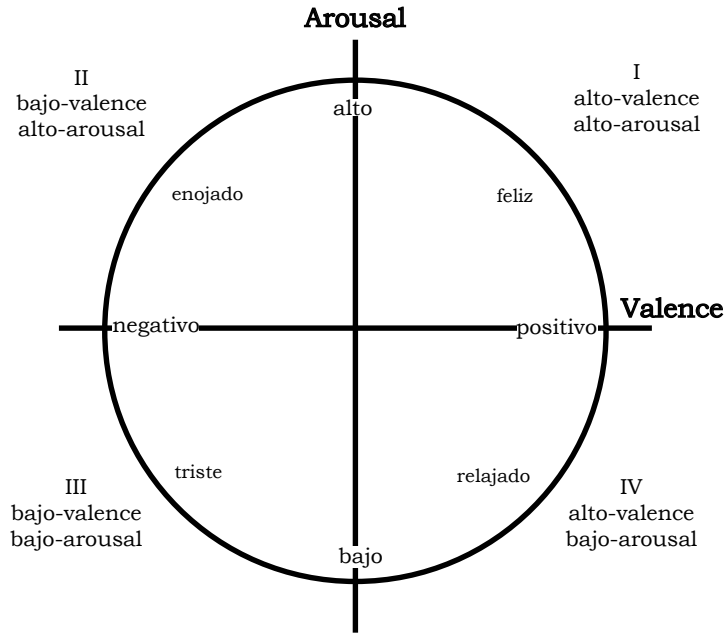


Figura 3.1: modelo emocional circunplejo.

general; en la figura 3.1 cada cuadrante posee su emoción general.

Para reconocer las emociones en los sujetos de prueba se utilizan autoevaluaciones, basadas en *valence* y *arousal*. Tras un estímulo, el sujeto brinda al sistema los valores para ambos componentes, estos se capturan por medio de deslizadores (véase la figura 3.2). Estos valores tienen dos usos: para la etapa de entrenamiento sirven para identificar las respuestas emocionales en la actividad neuronal y en la BCI se almacenan para fines comparativos.

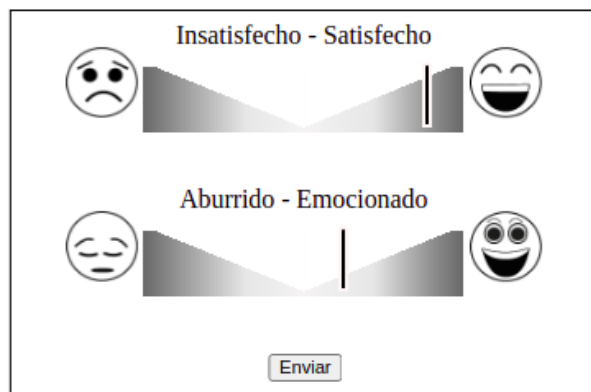


Figura 3.2: deslizadores para la captura de las emociones con la BCI.

En la figura 3.2 se muestran las barras de desplazamiento para capturar las emociones.

La primera se relaciona con el *valence* y la segunda con el *arousal*; contienen íconos que se relacionan con el componente emocional al que hacen referencia. Las barras de desplazamiento son un instrumento comúnmente llamado SAM (por las siglas en inglés de *Self-Assessment Manikin*), es utilizado en diferentes trabajos (11, 85) para medir emociones. Para nuestro proyecto, sustituimos los nombres de *valence* y *arousal* por insatisfecho-satisfecho y aburrimiento-emocionado para adecuarlo a la estimulación presentada en las simulaciones del comportamiento del robot. Para los videos musicales las etiquetas de *valence* y *arousal* son triste-feliz y aburrido-emocionado, respectivamente.

3.2. Protocolo de entrenamiento

Para la utilización de la CNN en la extracción de los estados emocionales es necesario un proceso de entrenamiento. Este proceso tiene como fin que la red aprenda a distinguir las emociones presentes en las señales de EEG de cada sujeto.



Figura 3.3: protocolo de entrenamiento para la evocación de emociones.

En la figura 3.3 se muestra el protocolo de estimulación de emociones para el entrenamiento de la CNN. Inicialmente se le presenta al sujeto un video introductorio donde se le brindan indicaciones y se le explica el experimento. Posteriormente, se muestran 26 videos: 20 de ellos son videos musicales y el resto son simulaciones del robot navegando dentro de un entorno doméstico. La duración de cada video es de 1 minuto y el tiempo transcurrido entre cada uno es de 2 segundos, tiempo durante el cual se captura el estado basal. Los videos musicales fueron seleccionados aleatoriamente del conjunto de datos DEAP (59) y pertenecen a diferentes géneros. Cada uno tiene una duración aproximada de un minuto.

En esta etapa, la navegación del robot se lleva a cabo por medio de un control remoto; se diseña el comportamiento del robot en base a tres objetivos: el riesgo de colisión, la energía

invertida y la trayectoria recorrida. Estos son los objetivos con los cuales se realizan cambios en el comportamiento del robot, lo cual se refleja en su conducción. La tarea asignada al robot consiste en atravesar de extremo a extremo la casa virtual para que se acerque a una mesa que posee encima una jarra de agua, la cual en una supuesta tarea futura será trasladada a otra habitación. En dicha habitación se encuentra una variedad de objetos, algunos de ellos son frágiles, como mesas de vidrio o seres humanos. Al colisionar, se generan sonidos para estimular al DM, ya que se busca intensificar la evocación emocional con efectos especiales.

En el video introductorio se les indica a los sujetos que tomen en cuenta los objetivos antes mencionados. Los sujetos toman el papel del tomador de decisiones ya que guían la optimización a través de la selección de los robots con sus emociones. Los sujetos describen su emoción por medio de la herramienta SAM (véase la sección 3.1). El par de valores obtenidos con el SAM (*valence, arousal*) es la emoción que representan las señales de EEG correspondientes a la estimulación por el video.

3.3. Interfaz Cerebro-Computadora

Los MOEA son una excelente opción para realizar búsquedas de soluciones en problemas de alta complejidad. Este tipo de algoritmos tienen la característica de que en cada generación se van ofreciendo mejores soluciones con el fin de hacer una aproximación al frente real. El frente de Pareto real es aquel en el que ya no se pueden encontrar soluciones no dominadas. Las soluciones generadas (es decir, los neurocontroladores), son mostradas en una gráfica en la BCI para estimular al DM. Las preferencias emocionales son capturadas a partir de la selección de seis individuos de cada frente de Pareto que se visite, a cada uno se le asigna una emoción (*valence* y *arousal*) con las señales EEG capturadas durante su ejecución en el simulador. Al finalizar la simulación uno de los individuos del frente de Pareto actual es seleccionado para ser usado como punto de referencia y darle dirección a la búsqueda. Se convierten las emociones predichas por la BCI al respectivo valor de su preferencia, el que posea el mayor valor es el preferido.

La BCI que proponemos permite explorar diferentes neurocontroladores, guiado por

las respuestas emocionales del DM. Las emociones nos permiten obtener evaluaciones del comportamiento del robot, nos ayuda a predecir el posible resultado de seleccionar un neurocontrolador por parte del DM para realizar la tarea en un entorno real. Tomamos en cuenta la hipótesis de los marcadores somáticos, es decir, las reacciones corporales asociadas entre el estímulo y la emoción, ya que introducen cambios en el estado del cuerpo humano (25) que podemos medir. En nuestro sistema se capturan con el EEG. Esto nos permite determinar la preferencia emocional de cada una de las posibles opciones en la toma de decisiones del DM.

En la figura 3.4 se muestra el flujo del sistema. El proceso inicia con la presentación del frente de Pareto al tomador de decisiones, se le presenta un subconjunto de seis individuos. El frente se explora por la selección de dichos individuos uno a la vez, pues con cada uno se inicia el proceso para identificar de forma automática su emoción. Dicho proceso se realiza a través de la estimulación del DM con la simulación en tiempo real del neurocontrolador, en paralelo se inicia la captura de las señales de EEG. El DM debe prestar atención durante la simulación el comportamiento del robot, se le indica que tome en cuenta los objetivos que se buscan optimizar y cómo se reflejan en su conducción hacia la meta. Al finalizar la simulación, el tomador de decisiones proporciona sus emociones con la herramienta SAM y se detiene la adquisición de las señales de EEG; éstas se preprocesan, se segmentan en ventanas y se introducen a la red neuronal convolucional para extraer la emoción embebida en dicha señal. Las emociones de todos los individuos del frente de Pareto actual, las cuales fueron dadas por la CNN, se utilizan para calcular las preferencias emocionales. El individuo que posea el mayor valor es el preferido y se utiliza para determinar los siguientes individuos del siguiente frente de Pareto a mostrar. El ciclo completo se vuelve a repetir con un nuevo frente de Pareto, el flujo del sistema termina hasta que el DM decide terminar el experimento o si ya no hay más frentes a mostrar. Es importante tomar en cuenta que el NSGA-II se desactivó para su uso con la BCI por motivos de la duración del experimento. La generación de una nueva población era un tiempo considerable por tal motivo se utilizaron soluciones pregeneradas (véase sección 3.6).

Cabe mencionar que debido a aspectos técnicos y de desarrollo, siendo uno de ellos el cambio de optimizador por soluciones pregeneradas, el tiempo entre la aplicación del

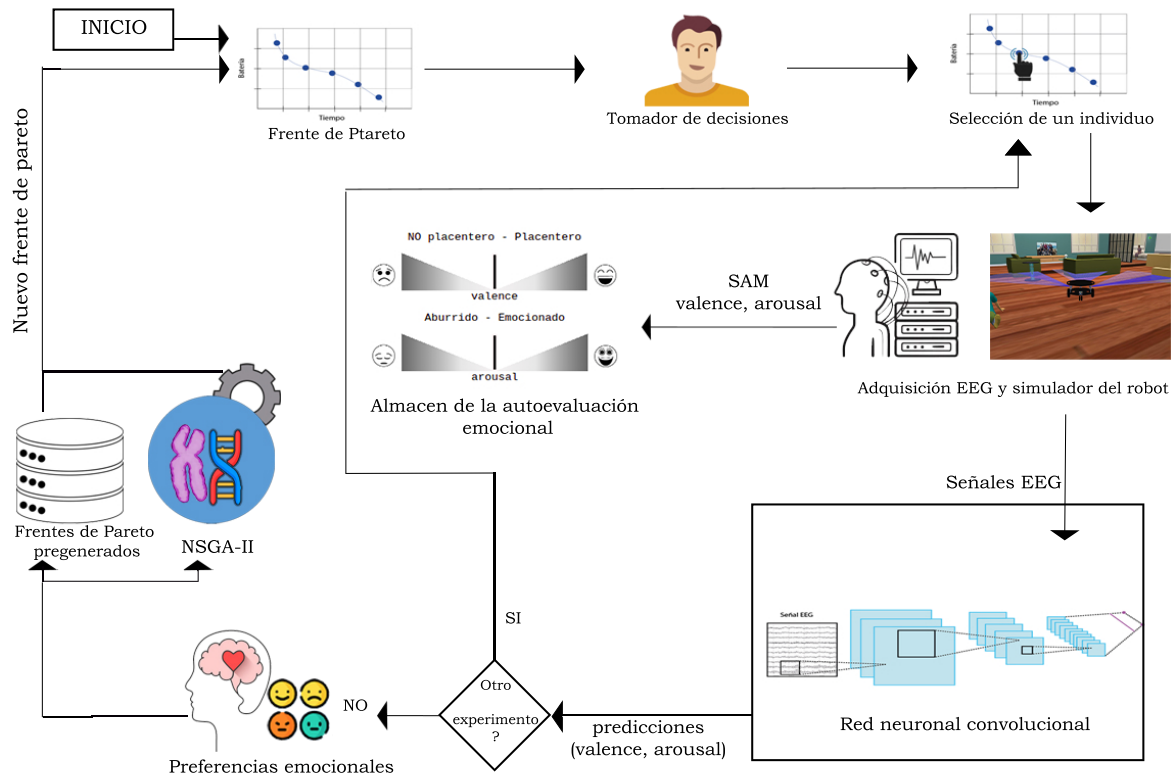


Figura 3.4: diagrama del flujo del sistema. Cada vez que se pasa por el recuadro de Frente de Pareto se inicia la exploración de un nuevo frente. Cuando se realiza la selección de un individuo se pone en marcha el proceso para extraer su emoción: se inicia la adquisición del EEG y la simulación del neurocontrolador; cuando ésta termina el DM da su emoción con SAM y la CNN a partir de las señales de EEG. El proceso se repite con todos los individuos del frente; se almacenan las emociones que fueron extraídas del EEG con la CNN y se ingresan a las preferencias emocionales para determinar el individuo preferido. Se buscan los nuevos individuos de un frente Pareto perteneciente a una generación superior y el proceso se repite.

protocolo de entrenamiento (véase sección 3.2) y la BCI fue considerable, en un aproximado de tres meses y medio.

La BCI consta de dos partes principales con la cual interactúa el tomador de decisiones, la primera es la simulación en tiempo real donde se muestra el neurocontrolador y la segunda es la interfaz de interacción para el DM. Para intensificar la evocación emocional la simulación cuenta con estimulaciones visuales y auditivas. En las estimulaciones visuales tenemos a los distintos objetos dentro del hogar, como por ejemplo: muebles, sillones, mesas de cristal, cajas, niños, adultos, por mencionar algunos. Para los estímulos auditivos, la

simulación cuenta con efectos de sonido: cuando el robot se estrella, suena un efecto de daño; algunos objetos tienen sonidos específicos que intensifican el daño; cuando el robot choca con objetos de cristal, suenan rompiéndose; cuando se estrella con un ser humano, se emite un sonido de grito; para otros objetos se reproduce un golpeteo suave y menos violento. Cuando el experimento se termina, hay dos sonidos que muestran su final: si el neurocontrolador llega a la meta, se reproducen aplausos, y abucheos cuando se quedó atorado o no llega a la posición final durante la simulación. Durante el experimento se emite una música de fondo con la cual se espera aumentar las respuesta emocionales del tomador de decisiones.

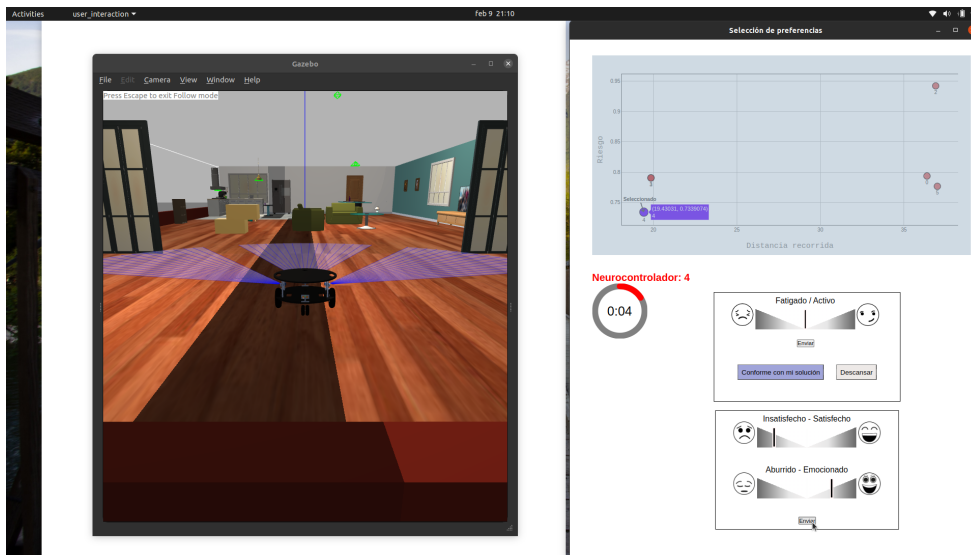


Figura 3.5: interfaces gráficas de la BCI.

La interfaz gráfica (véase la figura 3.5) es el lugar donde el DM recibe retroalimentación e interactúa con el experimento; cuenta con los elementos:

1. Gráfica: lugar donde se muestran los individuos cargados pertenecientes a un frente de Pareto en específico.
2. Indicador del experimento: se muestra el número del neurocontrolador y un contador del tiempo que le resta al robot para llegar a la meta.
3. Control de cansancio: cuenta con una barra de desplazamiento para ingresar si el experimento empieza a causar aburrimiento o emoción. Puede pausar el experimento

por alguna razón, al reanudar debe ingresar los motivos y un botón con el cual puede indicar que ya está conforme con las soluciones encontradas.

4. Autoevaluación emocional (SAM): son dos barras de desplazamiento con las cuales se ingresan los valores de *valence* y *arousal*.

3.3.1. Arquitectura de la BCI

La BCI se compone de varios módulos que realizan una función específica, cada uno se especializa en una parte del problema. En la figura 3.6 se muestran los principales módulos y cómo se comunican. Las señales EEG son altamente susceptibles a ser contaminadas por diferentes fuentes y solo ciertas frecuencias contienen información emocional. Por dichos motivos la señal se debe capturar y preprocesar; los módulos encargados de realizar esas tareas son el Controlador EEG y el Preprocesamiento. Eliminan de la señal las características no deseadas en lo mayor posible (véase la sección 3.4); por mencionar un ejemplo, los artefactos generados por fenómenos internos del cuerpo, uno de ellos es el parpadeo.

En el módulo de Predicción emocional se utilizan las redes neuronales para decodificar los estados emocionales en la señal EEG. Se realiza un procesamiento y un ventaneo para generar las muestras que se ingresarán a la CNN. El módulo utiliza la red que se eligió con el proceso llamado selección de modelos (véase la sección 4.1).

El módulo de Preferencias emocionales almacena las predicciones de la población de neurocontroladores de la generación actual. Las emociones son procesadas por nuestro modelo de preferencias emocionales, elige cuál de los neurocontroladores posee la emoción que se dirige más hacia la felicidad o tranquilidad; en nuestro modelo de preferencias emocionales (véase la sección 3.8) poseen valores altos para su preferencia, ya que son los estados emocionales que se espera que se evoquen en las respuestas emocionales del DM, producto de la interacción humano-robot.

La interfaz gráfica es el medio por el cual el tomador de decisiones interactúa con la BCI, captura las evaluaciones del DM y le brinda información sobre el neurocontrolador actual. La interfaz gráfica y el simulador son los únicos módulos que muestran elementos gráficos, el resto se encuentran ocultos.

El módulo del Neurocontrolador se comunica con el simulador para obtener los datos del robot, calcula sus estados y las velocidades para la conducción. La interfaz gráfica le indica al módulo a qué individuo se le deben cargar sus pesos para interactuar con la simulación.

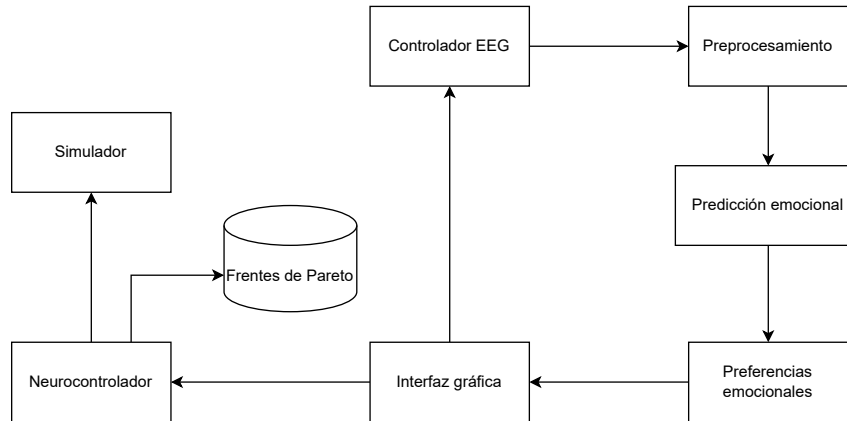


Figura 3.6: módulos del sistema BCI y sus conexiones principales.

3.3.2. Detalles técnicos

Para el desarrollo de la BCI se utilizaron distintas tecnologías. La principal es ROS, el cual es un sistema operativo para robots. Los módulos de nuestro sistema son tratados como nodos y ROS se encarga de gestionar las comunicaciones entre ellos. El simulador permite integrarse con esta tecnología, además permite escalar la BCI para trabajo futuro.

Los módulos se desarrollaron con diferentes tecnologías, lo que nos permite utilizarlas en conjunto para explotar sus capacidades. La integración del casco EEG se realiza con la biblioteca *BrainFlow*, la cual nos permite acceder al bioamplificador para obtener información de los canales de EEG.

Las redes convolucionales se han codificado con el lenguaje *Python*, esto nos abre un vasto ecosistema de bibliotecas y herramientas. Dicho lenguaje tiene soporte para el desarrollo de algoritmos de aprendizaje de máquina. Por medio de *Tensflow-GPU 2.9* se accede a la biblioteca *Keras 2.9* para la creación de la CNN, con *Numpy 1.22* se maneja y procesa la señal para generar las muestras que se ingresan en la red.

La interfaz gráfica se desarrolla en base a tecnologías web. Se hace uso de *NodeJs* para la

ejecución de código *JavaScript* y el *framework Electron* para utilizar *HTML*, *CSS*, así como una plataforma para tecnologías enfocadas al *front-end*. Entre ellas se encuentra *Plotly*, una biblioteca que utilizamos para mostrar la población de neurocontroladores actuales al DM y para generar gran parte de nuestros resultados y conclusiones; posee características que facilitan la lectura e interpretación de los resultados.

El módulo del neurocontrolador se encarga de interactuar con el simulador, en cada instante de tiempo recibe los valores de los sensores y los pasa a través de la red neuronal para predecir los valores de conducción del robot. *Gazebo* posee una herramienta que nos permite conducir el robot y determinar su posición. La herramienta recibe como entrada velocidades lineales y angulares, que son predichas por la red neuronal. Se ha utilizado el simulador *Gazebo* en su versión 11.10. El software cuenta con variedad de herramientas que serían de utilidad para extender las capacidades del robot además, nos permite simularlo en tiempo real dentro entornos físicos realistas.

Se ha utilizado una computadora Acer Nitro con un procesador *core i7 CPU 2.60 Hz* de décima generación. Para el entrenamiento de las redes se utiliza una *GPU Nvidia GeForce RTX 3050*. El sistema operativo sobre el cual se ejecutan las tecnologías mencionadas es *Ubuntu 20.04.5 LTS*.

3.4. Señales de electroencefalograma

Las señales de electroencefalograma son capturadas por medio del casco EEG ultra-cortex (de la compañía OpenBCI), el cual es un casco de electroencefalograma impreso en 3D que utiliza electrodos secos (véase la figura 3.7). La tarjeta encargada de realizar la adquisición de las señales es una tarjeta Cyton que cuenta con el módulo Daisy para adquirir información de 16 canales. Las señales son capturadas a una frecuencia de 125 Hz.

Se elimina el ruido producido por la instalación eléctrica con un filtro *notch*, el cual rechaza las frecuencias a 60Hz. Se elimina la tendencia en la señal. La señal la filtramos con un paso banda que utiliza un filtro Butterworth de cuarto orden; su frecuencia de corte es de 5Hz a 50Hz para extraer las frecuencias de las mencionadas potencias de banda. Antes




Figura 3.7: casco de EEG Ultracortex de OpenBCI.

de ser ingresadas en la CNN se extrae el estado basal con las señales capturadas antes del estímulo. Cabe mencionar que en la BCI los primeros cinco sujetos se diferencian ya que se utilizó un único estado basal antes del experimento.

Para minimizar la producción de artefactos generados por los movimientos del sistema motor del sujeto, se le acomoda en un asiento cuyo respaldo se encuentra a una distancia de 120 cm de la pantalla. Se le indica que se mantenga lo más quieto posible durante las estimulaciones. Se elimina la referencia común para mejorar la calidad de la señal, eliminar el ruido de fuentes comunes y mejorar la relación señal-ruido en las señales EEG.

Aplicamos el protocolo reportado en la sección 3.2 a un total de 11 sujetos, de los cuales 9 son hombres y 2 mujeres. Todos los participantes son estudiantes universitarios de la carrera de Ingeniería en Computación de la Universidad Autónoma Metropolitana Unidad Cuajimalpa.

3.5. Simulador

El robot utilizado para los experimentos es un modelo virtual (véase la figura 3.8) que fue replicado del robot *Arlo Complete Robot System*¹. El modelo fue desarrollado por el Dr. Antonio López Jaimes perteneciente a la Universidad Autónoma Metropolitana unidad Cuajimalpa.

El robot se conforma por placas redondas, la parte baja y la parte alta. Las placas

¹<https://www.parallax.com/product/arlo-complete-robot-system/>



Figura 3.8: modelo virtual del robot móvil utilizado para los experimentos.

están separadas por cuatro barras metálicas. La placa de la parte baja sirve como base del robot, en ella se encuentran montadas los componentes utilizados para que el robot pueda moverse en su entorno de trabajo. En las orillas de la placa se encuentran montadas las ruedas principales. De forma perpendicular se encuentra unas ruedas pequeñas que estabilizan toda la estructura. En la base se encuentran cuatro sensores de proximidad. Tomamos la rueda derecha como punto de referencia y se encuentra en la posición 0° . Así, los sensores están ubicados a los 40° , 90° , 140° y 270° , respectivamente.

La detección de colisiones con el robot, son de utilidad para la generación del audio encargado de estimular a el DM. Se busca intensificar la evocación emocional con efectos especiales. Las colisiones generan retroalimentación de los eventos, por ejemplo colisionar con objetos frágiles o alguna personas que habita la casa.

3.5.1. Neurocontrolador: red neuronal artificial

El neurocontrolador es una red neuronal completamente conectada, los valores de entrada para la red son los valores proporcionados por los sensores de proximidad. Cada sensor proporciona 32 rayos, se utilizan tres sensores lo que equivale a 96 rayos por cada instante de tiempo. El valor de cada rayo es asociado a una neurona, lo que quiere decir que se necesitan al menos 96 neuronas para la capa de entrada.

Los neurocontroladores deben aprender a conducir el robot hasta la posición objetivo,

la cual es una mesa que se encuentra al otro extremo de la casa. Para lograrlo se agregan dos neuronas extra que reciben información relacionada con la posición del robot. La primera recibe la distancia euclidiana desde el robot hacia la mesa, su minimización le permite al optimizador generar neurocontroladores que aprenden rutas con una menor distancia. Para lograr que aprendan generar velocidades angulares y lineales que dirijan la conducción hacia la mesa, la segunda neurona recibe el ángulo necesario para que la orientación del robot en el eje z se encuentre en línea recta hacia la mesa. La minimización de dicho ángulo provoca que los pesos de la red aprendan a generar rutas que contemplen la dirección del robot hacia la mesa.

3.5.2. Entorno virtual

El entorno de trabajo virtual en el cual el robot se desarrolla es un entorno doméstico, en el hay una serie de objetos en el cual el robot tiene que esquivar y evitar colisionar. El neurocontrolador se evalúa en base a los valores objetivo, éstos se calculan en base a la conducción dentro del entorno virtual. *Gazebo* posee una caja de herramientas completa de bibliotecas de desarrollo y servicios en la nube para facilitar la simulación de robots. Permite simular la física y el comportamiento de los robots en entornos realistas. Dado que se cuenta con el robot en físico, en trabajo futuro se desea transmitirle el conocimiento generado con las simulaciones para su uso en aplicaciones del mundo real.



Figura 3.9: entrada del dormitorio, posición inicial del robot.

En las figuras 3.9, 3.10 podemos observar la navegación del robot en su ambiente



Figura 3.10: sala que tiene que atravesar el robot para llegar a la mesa que se encuentra en la cocina.

virtual, en ella se pueden observar variedad de objetos como muebles que son resistentes ante las colisiones del robot sin embargo, también se encuentran objetos delicados como mesas de vidrio grandes y pequeñas en las cuales si el robot colisiona podría causar gran daño. En el ambiente virtual se encuentran humanos, ya que en la realidad son las personas que interactúan con el robot y esperan que se comporte con eficientes pues el tomador de decisiones al tomar el papel de seleccionar el mejor robot, estos pueden tratarse de personas que habitan en su hogar.

3.6. Optimización del neurocontrolador

El entorno de trabajo del robot es un ambiente doméstico virtual, posee una colección de objetos y personas que el robot tiene que evitar colisionar durante la conducción. El neurocontrolador o red neuronal (ANN) busca llegar a la posición objetivo con la menor distancia recorrida, disminuyendo el riesgo de colisionar con objetos que se le atraviesen en su camino y mantener una estabilidad de llegada a la meta. Por medio de un algoritmo evolutivo multiobjetivo se generan neurocontroladores que contemplan dichas características, pues conforman los objetivos que se desean optimizar. Se representa la ANN como una población de individuos. Por medio de los operadores de cruce, mutación y selección se logra que evolucione la población a soluciones mejores. Los individuos más aptos son los que sobreviven, la simulación es el medio para evaluarlos. El neurocontrolador y la

simulación se comunican, comparten información constantemente para hacer posible que el robot interactúe con su entorno. Se pone a prueba las ANN dentro de una simulación en tiempo real, al finalizar son devueltos los valores de los objetivos. Son tres los objetivos que se buscan optimizar en el cumplimiento de la tarea del robot, la cual consiste en conducir hasta la posición objetivo; dichos objetivos se buscan minimizar y son:

- Distancia recorrida: tamaño de la ruta que realizó la ANN.
- Riesgo: cercanía con la que pasa a los objetos, se define como $\frac{1}{d+1}$ donde d es la distancia del robot a un objeto.
- Velocidad de llegada: velocidad con la que llega el robot a la posición destino. El objetivo evita que el robot colisione con la mesa, la cual es la meta que debe llegar el robot.

El problema de optimización posee una restricción, los individuos que se utilizan en el proceso de optimización son aquellos que obtiene una distancia menor a 0.95 de la posición final y el robot. La posición final es una mesa con una jarra de agua sobre ella. Regularmente se utiliza un conjunto de datos etiquetado para calcular los pesos de la red. No se cuenta con un conjunto de datos para entrenar el neurocontrolador; la creación de uno está fuera de los objetivos del proyecto. Para determinar los pesos se utiliza un algoritmo evolutivo de optimización multiobjetivo. El seleccionado fue el algoritmo NSGA-II (28, 29), como se muestra en la sección 2.2 es parte de los algoritmos importantes de su época, propone avances importantes al área de optimización. Es un algoritmo que se sigue utilizando en el estado del arte y ha demostrado tener resultados buenos en problemas multiobjetivo, que no tengan más de tres objetivos; un número superior se considera como un problema de muchos objetivos. Cuando el problema no posee muchos objetivos, el MOEA supera su versión mas reciente NSGA-III. Cabe mencionar que se pueden utilizar otros optimizadores, existen algoritmos que convergen más rápido en problemas de muchos objetivos, sin embargo, el utilizado nos permite realizar una primera aproximación y nos funciona bien ya que no poseemos muchos objetivos.

Por medio del MOEA buscamos optimizar los valores de los objetivos obtenidos con la simulación. Es muy complicado definir una función matemática que nos devuelva los

valores para los objetivos, el problema es de naturaleza compleja, los posibles estados son enormes. La simulación forma parte de nuestra función objetivo, nos permite pasar del espacio de las variables al espacio de los objetivos. Los pesos de la ANN representan la entrada a la función objetivo pues conforman el espacio de las variables, mientras que los valores obtenidos con la simulación conforman el espacio de los objetivos.



Figura 3.11: función objetivo.

Los individuos más aptos son los que prevalecerán y se usarán para la creación de la siguiente generación en el algoritmo evolutivo, se almacenan los individuos para posteriormente ser utilizados en la BCI. En el espacio de las variables se encuentran los neurocontroladores que estimularán al individuo. El modelo de preferencias se mueve en el espacio de los objetivos. Por motivos del tiempo de duración del experimento, las soluciones son generadas antes de su uso en la BCI. El sistema cuenta con una versión del NSGA-II propuesta en (78), posee un método de incorporación de preferencias basada en punto de referencia. El DM modela sus preferencias a través de dicho punto. El tiempo que le toma al optimizador generar un nuevo frente de Pareto es demasiado grande para el experimento; maneja una población de cien individuos. La BCI utiliza un subconjunto de seis individuos para estimular al DM, por lo tanto el optimizador se desactiva para uso en conjunto con la BCI durante la realización de los experimentos, por tal motivo se ejecuta el optimizador sin la incorporación de preferencias con el fin de generar frentes de Pareto que serán utilizados durante la ejecución de la BCI.

La función que sirve para la incorporación de preferencias es una función de escalari- zación de logro; ésta se basa en la distancia de Chevyshev.

$$s_{\infty}(\vec{z}, \vec{z}^{ref}) = \max_{i=1, \dots, k} \{\lambda_i(z_i - z_i^{ref})\} + \rho \sum_{i=1}^k \lambda_i(z_i - z_i^{ref}), \quad (3.1)$$

donde \vec{z}^{ref} es un punto de referencia, $\rho > 0$ es un coeficiente de aumento suficientemente pequeño, y $\lambda = [\lambda_1, \dots, \lambda_k]$ es un vector de pesos tal que $\forall i \lambda_i \geq 0$ y, para al menos una i , $\lambda_i > 0$.

3.7. Traducción emocional

3.7.1. Redes neuronales convolucionales

La detección automática de emociones la realizamos a partir de una red neuronal convolucional (CNN). Este tipo de aprendizaje de máquina es ampliamente utilizado en el estado del arte con respecto a la detección emocional. Comparamos el rendimiento de tres redes para determinar cuál utilizar en la BCI, estas redes son: *EEGNet* (65), *ShallowConvNet* y *DeepConvNet* (109). Los autores de estas redes se basaron en su diseño para ser de arquitectura genérica, con el fin de crear herramientas de uso general para tareas de decodificación de señales cerebrales; su objetivo es obtener rendimientos competitivos con poco conocimiento experto relacionado a la tarea.

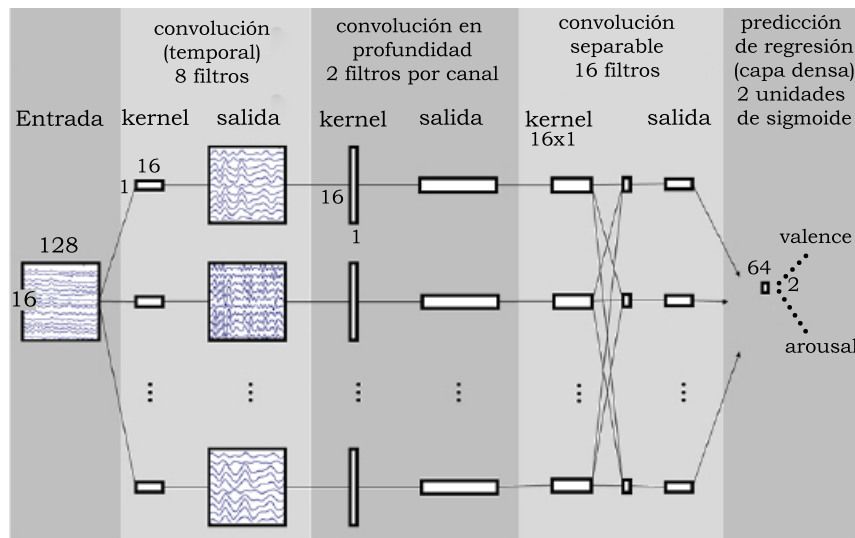


Figura 3.12: arquitectura de *EEGNet*.

La primera propuesta es la red *EEGNet* cuya arquitectura se muestra en la figura 3.12. Cabe mencionar que las imágenes de las arquitecturas presentadas en esta sección se extrajeron de su trabajo original, se tradujeron y se cambiaron por los parámetros utilizados en nuestros experimentos.

En la figura de *EEGNet* el fondo se compone por rectángulos grises de dos tonos diferentes, estos se refieren a diferentes bloques convolucionales, siendo el bloque cero la entrada a la red. El primer bloque contiene una capa convolución sobre el tiempo, seguida de una capa de normalización por lotes. La segunda capa es una convolución en profundidad, tiene el beneficio de reducir el número de parámetros de entrenamiento y en aplicaciones de EEG permite el aprendizaje de filtros espaciales para cada filtro temporal, lo cual habilita la extracción de dichos filtros relacionados a distintas frecuencias. Estos dos bloques se mantienen como convolucionales lineales, lo que quiere decir que no hay una función de activación, pues los autores han encontrado que el uso de una transformación no lineal no mejora significativamente el rendimiento. El tercer bloque es una convolución separable, la cual consiste en una convolución en profundidad seguida de una convolución puntual. Este tipo de convolución, además de reducir los parámetros de entrenamiento, realiza un desacoplo explícito de las relaciones entre y a través de los mapas de características; primero se aprende un *kernel* que resumen las características individualmente y luego se fusionan de manera óptima los resultados. En el último bloque se utiliza una capa densa cuya salida son dos neuronas, la primera predice el valor de *valence* y la segunda el *arousal*.

Al término del segundo y tercer bloque se utiliza una normalización por lotes, seguido de una función de activación ELU (*Exponential Linear Unit*, por sus siglas en inglés), una capa de *average pooling* de tamaño: (1,4) y (1,8), respectivamente para cada bloque; para terminar un *dropout* donde los autores recomiendan una probabilidad de 0.5, ésta última es con el fin de regularizar el modelo y evitar un sobreajuste durante el entrenamiento. La función de activación ELU se define como: $f(x) = x$ para $x > 0$ y $f(x) = e^x - 1$ para $x \leq 0$.

La segunda y tercer propuesta son *ShallowConvNet* y *DeepConvNet*, sus arquitecturas se presentan en la figura 3.13 y 3.14. Sus operaciones convolucionales iniciales son: con-

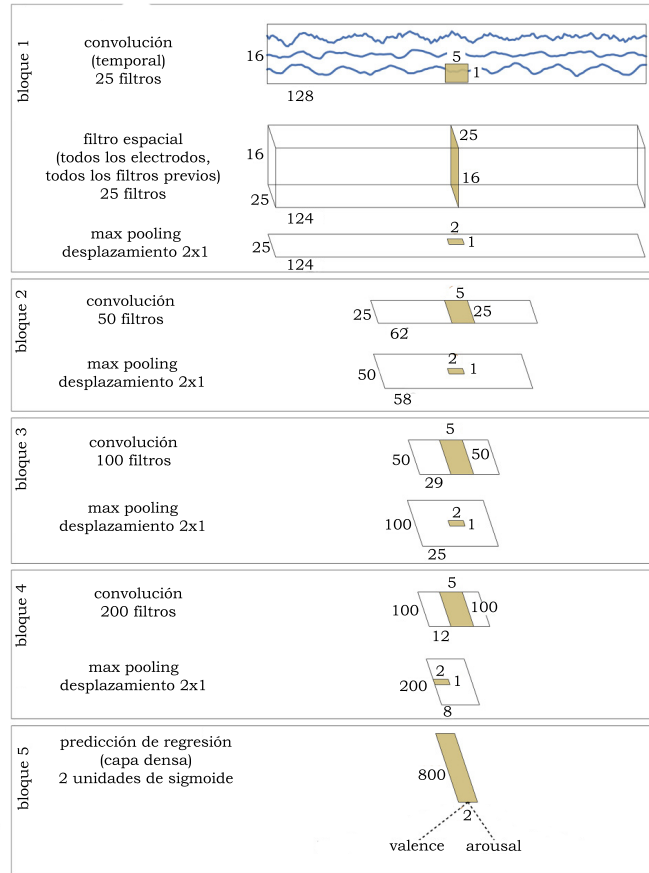
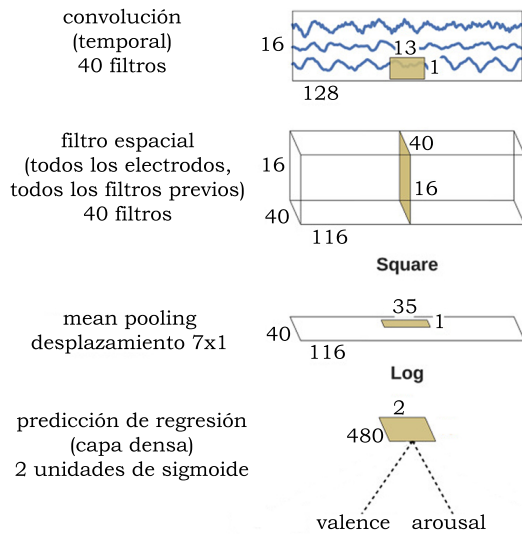


Figura 3.13: arquitectura de *ShallowConvNet*.

Figura 3.14: arquitectura de *DeepConvNet*.

volución temporal y filtro espacial. Estas operaciones se diferencian entre estas dos redes por el tamaño del *kernel* en la convolución temporal y el número de filtros.

En el caso de *ShallowConvNet*, después del filtro espacial se encuentra una capa de normalización por lotes, una no lineal cuadrática, *mean pooling*, una función de activación logarítmica y *dropout*. Para finalizar se encuentra una capa densa con una función de activación sigmoide. Los autores señalan que por medio de la capa de *pooling* en varios mapas de características, la red puede aprender una estructura temporal de los cambios en la potencia de la señal, pues eso ha sido beneficioso en uno de sus trabajos anteriores.

La última propuesta, candidata para ser utilizada en la BCI es *DeepConvNet*; su arquitectura se muestra en la figura 3.14. La convolución temporal y el filtro espacial, en principio pueden combinarse en una capa convolucional, sin embargo los autores señalan que su separación ayuda a la regularización de la convolución; se separa en una combinación

de convoluciones temporales y filtros espaciales.

En la arquitectura de *DeepConvNet*, al final de cada bloque convolucional se encuentra una normalización por lotes, seguido de una función ELU, un *max pooling* y al final un *dropout* con una probabilidad de 0.5.

3.7.2. Sistema en línea

Nosotros contamos con tres redes sin embargo, solo se usa una en la BCI. Para seleccionar la red hacemos uso del conjunto de datos DEAP (véase la sección 4.1).

La emoción es tratada como dimensiones afectivas, ya que seguimos el modelo circunplejo compuesto por *valence* y *arousal*. La decodificación de las emociones en la señal de EEG, son valores continuos que representan puntos dentro de dicho modelo circunplejo, por lo tanto la detección automática de emociones es tratada como un problema de regresión. Cabe mencionar que gran parte del estado del arte sobre la detección emocional es en base a emociones discretas, sin embargo nosotros optamos por emociones continuas ya que de esta forma nuestro modelo de preferencias emocionales puede manejarlas.

Para dejar la señal lista para la CNN, tras haber realizado el preprocesamiento, primero se extrae el estado basal de la señal. Dicha señal es generada durante un periodo de tiempo de 2 segundos sin estimulación alguna al DM, aunque no se haga presente ninguna estimulación aún sigue habiendo actividad neuronal, su extracción ayuda a clarificar los patrones generados durante la estimulación. La señal se estandariza con una media y desviación estándar conocida. La señal antes de ingresar a la CNN es procesada y segmentada por un ventaneo de 128 muestras con un desplazamiento de 32; este proceso genera las ventanas o muestras de entrada para la CNN. Cada ventana tiene como resultado una emoción, por lo tanto la predicción emocional de un estímulo es el centroide calculado a partir de las perdiciones con las ventanas generadas con su señal EEG. La fórmula para el cálculo del centroide es:

$$C(\mathbf{X}) = \left(\frac{\sum^n x_i}{n}, \frac{\sum^n y_i}{n} \right) \quad \mathbf{X} \in \Omega \quad (3.2)$$

Donde C es la predicción emocional o centroide, \mathbf{X} es un conjunto de n emociones que

pertenecen al modelo de Russell Ω y (x_i, y_i) son los componentes de dichas emociones. El conjunto de datos generado con el protocolo de adquisición (véase la sección 3.2) forman parte del entrenamiento de la CNN y las emociones capturadas con SAM son las etiquetas. El proceso de entrenamiento se realiza con el 80 % de la señal de EEG, capturada en cada estimulación, el 20 % final de dicha señal es el conjunto de prueba.

La red después de cada estimulación (simulación) le toma aproximadamente un 1 segundo extraer la emoción embebida en la señal EEG; el cálculo se realiza de forma empírica. Para seleccionar la mayor preferencia emocional, el DM tiene que observar la simulación de todos los individuos del frente actual; en nuestro caso de estudio son seis. El tiempo de respuesta es variado, en el mejor de los casos se realiza en 2 minutos con 6 segundos y en el peor de los casos entre 7 y 8 minutos. Lo anterior es debido a que utilizamos un simulador en tiempo real para robots, no siempre la simulación corre uno a uno con el tiempo real, produciendo retrasos; el hardware tiene que soportar la robustez de nuestro sistema. Se observó que dichos retrasos no presentaron problema crítico en la fluidez de la simulación para el DM.

3.8. Modelo de preferencias emocionales

El modelo de preferencias emocionales es la parte encargada de la toma de decisiones en la evolución del neurocontrolador. Toma información emocional generada en los individuos del frente de Pareto actual, la procesa para decidir cual es el individuo que servirá de punto de referencia para calcular el siguiente frente. El modelo permite moverse entre en el espacio de soluciones del optimizador. Se encarga de decidir cuál será el siguiente frente que se visitará y cuáles serán los individuos que usaremos para continuar la búsqueda.

Al simular un individuo se inicia el flujo *EEG* para la extracción de las emociones del tomador de decisiones. La CNN encargada de dicha tarea predice cuál es la emoción evocada por el neurocontrolador. Se recolectan las predicciones emocionales de los individuos del frente actual, se procesan por medio de un método conocido como PBI (*Penalty Boundary Intersection*, por sus siglas en inglés). El método se ha utilizado en algoritmos de descomposición como *MOEA-D*, pues se ha demostrado en el estado del arte que mejora

su rendimiento (119).

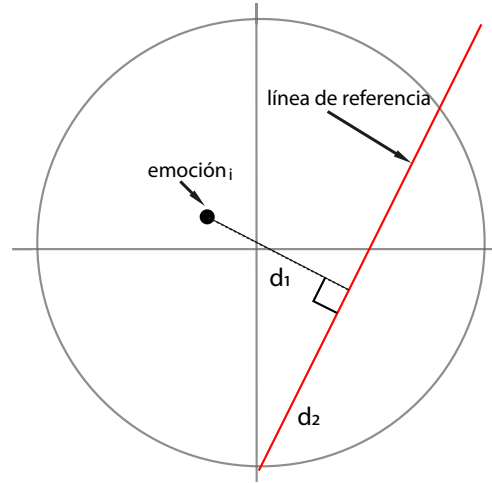


Figura 3.15: Funcionamiento de PBI.

En la figura 3.15 se puede observar como funciona el PBI. En el método se utiliza una línea recta que sirve de referencia (línea roja) y una función de escalarización, la cual nos permite crear una relación con dicha recta y el espacio de trabajo. Las emociones en el sistema circunplejo se intersecan perpendicularmente con la línea de referencia. El punto donde se forma dicha intersección sirve para definir dos distancias. La primera de dicho punto a la emoción y la segunda del mismo punto de intersección al inicio de la línea de referencia. Lo anterior se utiliza para crear un modelo de preferencias emocionales y se establece por medio de la siguiente fórmula:

$$P_{pbi}(\vec{x}|\vec{w}, d^{\vec{ref}}) = \theta_1 d_1 + \theta_2 d_2 \quad \vec{x} \in \Omega \quad (3.3)$$

Donde \vec{x} es una emoción que pertenece al modelo de Russell Ω , mientras $d^{\vec{ref}} = (d_1, d_2)$ son las distancias que se muestran en la figura 3.15 y $\vec{w} = (\theta_1, \theta_2)$ es el vector de pesos, con la restricción de que la suma de sus componentes sea igual uno. Los pesos son parte de los parámetros de entrada de nuestro modelo de preferencias. La función permite transformar una emoción en su respectivo valor de preferencia. Determinar la mejor opción ante una toma de decisiones se resuelve por medio de un problema optimización el cual se define:

$$\max P_{pbi}(\vec{x}), \quad \vec{x} \in \Omega \quad (3.4)$$

Nosotros estamos interesados en los neurocontroladores que evoquen respuestas emocionales positivas, por tal motivo, colocamos la línea de referencia entre el punto $(0.5, 0)$ y $(1, 1)$ el cual hace referencias a las regiones que pertenecen a las emociones relacionadas con la felicidad y la calma; son las emociones preferidas para la selección de los neurocontroladores. Para seleccionar los pesos w nos basamos en las emociones preferidas, se generaron diversos espacios de preferencias emocionales y se seleccionó el que mejor se adaptó a nuestros objetivos. Para generar dichos espacios se utilizaron 10,000 puntos aleatorios, los cuales representan emociones en el sistema circunplejo. Se transforman a sus respectivas preferencias por medio de la fórmula 3.4 y son mapeados a un rango de colores que van de oscuros a claros; los colores claros son los de mayor preferencia.




Figura 3.16: nuestro espacio de preferencias con PBI, generado a partir de una distribución aleatoria de distintas emociones.

En la figura 3.16 se observa el espacio de preferencias emocionales generado con los pesos preferidos para ser usados en la fórmula 3.4. Nosotros lo establecimos con los valores $\vec{w} = (0.45, 0.55)$, fueron los valores que mejor resultaron en nuestras pruebas y se adaptan mejor a nuestros objetivos. Se puede observar en dicha figura que la región perteneciente a la felicidad es la que posee mayor proporción de colores claros, seguido por la región de

la calma.

El método de *PBI* se utiliza para seleccionar el individuo que servirá como punto de referencia, el que obtenga el mayor valor será el seleccionado. El modelo de preferencias utiliza la distancia de Chebyshev para un espacio de 3 dimensiones (véase la fórmula 3.5) lo cual permite moverse entre el espacio de soluciones.

$$D(\vec{p}, \vec{q}) = \max(|p_i - q_i|) \quad \vec{p}, \vec{q} \in \Theta, \quad i \in [1, 3] \quad (3.5)$$

Donde D es la distancia de Chebyshev, p y q son individuos o neurocontroladores cuyos valores se encuentran en el espacio de los objetivos Θ . La selección de la opción con mayor preferencia, calculada a través del uso de *PBI*, es la base para determinar el siguiente frente. Cabe mencionar que dicho punto sirve para la entrada de la fórmula 3.1 para la incorporación de preferencias con el optimizador. En cada conjunto de neurocontroladores, que se le presentan al DM, se determina el de mayor preferencia el cual sirve como punto de referencia; se calcula su distancia con cada uno de los individuos de frentes posteriores, en el espacio de los objetivos y usando la fórmula 3.5. El neurocontrolador que obtenga la menor distancia es el primer individuo seleccionado para mostrar al DM en la siguiente iteración del experimento. El frente de Pareto que posee dicho individuo es el siguiente a visitar y los individuos que pertenecen a ese frente se utilizan para determinar el resto que se le mostrarán al DM pero ahora usando la distancia euclidiana. Para extender la búsqueda entre los frentes de Pareto se utiliza un umbral, el cual define a partir de cuantos frentes en adelante al actual debe iniciarse la búsqueda.

Capítulo 4

Experimentación

4.1. Selección del modelo

Contamos con tres CNN candidatas a ser utilizadas con la BCI: *EEGNet*, *DeepConvNet* y *ShallowConvNet*. Para seleccionar la arquitectura que será utilizada para la detección de emociones de nuestra propuesta, analizamos el desempeño de cada una. Entrenamos y evaluamos las CNN candidatas con el conjunto de datos DEAP (59), ya que es utilizado frecuentemente para evaluar los algoritmos de detección automática de emociones. DEAP cuenta con 40 videos musicales de un minuto de duración cada uno. Las señales de EEG fueron adquiridas con 32 canales usando el sistema internacional 10-20. El género de los participantes está balanceado, es decir hay igual número de hombres y mujeres. Las señales fueron adquiridas a una frecuencia de 512Hz y se submuestrearon a 128Hz. Se les aplicó un filtro de paso banda en un rango de 4 a 45Hz. Los datos se promediaron por una referencia común y se eliminaron los artefactos de electrooculograma. Cabe mencionar que este conjunto de datos solo se utiliza para seleccionar el modelo a utilizar en la BCI, se compara el rendimiento de nuestros modelos con dicho conjunto pues posee un tamaño mayor al nuestro y es ampliamente utilizado en los estudios emocionales.

Para evaluar el modelo, se realizaron cuatro repeticiones de validación cruzada de cinco particiones. El entrenamiento de las redes se realizó para cada sujeto de manera aislada. Es decir, no analizamos la posibilidad de generalizar la red a partir de entrenarla con la información de todos los sujetos, lo cual consideramos que es una tarea que está fuera del

alcance del presente proyecto. Nosotros abordamos la detección automática de emociones como un problema de regresión, ya que para la implementación de nuestro modelo de preferencia necesitamos valores continuos. Las métricas utilizadas para la evaluación de las redes fueron: el error cuadrático medio (MSE, por las siglas en inglés de *mean squared error*) y el error absoluto medio (MAE, por las siglas en inglés de *mean absolute error*).

En las figuras 4.1 y 4.2 se muestran las gráficas del MSE y del MAE, respectivamente. Los valores de dichas métricas nos indican qué tan acertada es la predicción emocional, entre menor sea el valor significa que la emoción predicha se encuentra más cercana al valor real de la emoción. Los valores que obtuvimos para ambas métricas se mantienen bajos, lo que es un indicio sobre un buen comportamiento del modelo. Se presentaron muy pocos valores atípicos, los rangos intercuartiles no se alejan mucho de la mediana, con lo cual se deduce que el aprendizaje de las CNN generadas fue consistente entre los sujetos del conjunto de datos.

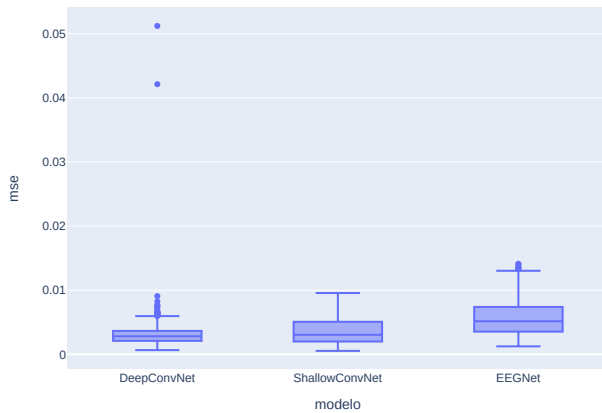


Figura 4.1: error cuadrático medio usando DEAP.

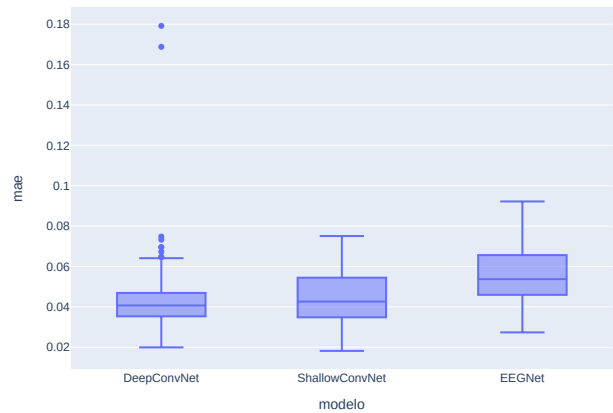


Figura 4.2: error absoluto medio usando DEAP.

El modelo *DeepConvNet* obtiene los errores más bajos tanto en el MSE como en MAE. Además, aunque hay valores atípicos, en general se observa una menor dispersión. Por lo anterior se elige *DeepConvNet* como la arquitectura a utilizar en la BCI.

4.2. Entrenamiento con los datos del protocolo de estimulación propuesto

Para evaluar el desempeño de *DeepConvNet* en un escenario más cercano al esperado, se evalúa su desempeño con los datos generados usando nuestro protocolo de estimulación. Los videos presentados en la sección 3.2 se utilizan para estimular al DM y registrar sus diferentes estados emocionales por medio del almacenamiento de las señales y autoevaluaciones. Cada video musical o del robot simulado, es un ejemplo para la red. Mientras que las autoevaluaciones son el etiquetado.

Las señales de EEG se almacenan y procesan para formar el conjunto de entrenamiento. Para generar más información para el entrenamiento, se genera un ventaneo de 128 muestras con un desplazamiento de 32. De esta forma, *DeepConvNet* toma de entrada las ventanas generadas para traducir las señales de EEG en estados emocionales. Se realiza el entrenamiento con alrededor de 150 épocas y una tolerancia de 15 épocas para que la pérdida mejore, si no lo hace, el entrenamiento se detiene.




Figura 4.3: error cuadrático medio usando datos del protocolo.

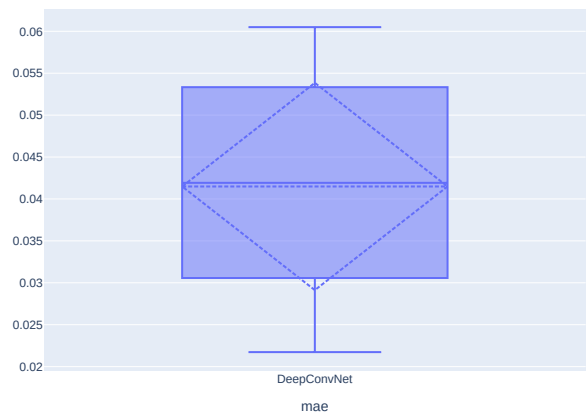


Figura 4.4: error absoluto medio usando datos del protocolo.

En la figura 4.3 y 4.4 se muestran las evaluaciones con MSE y MAE obtenidas con los usuarios del protocolo propuesto. La línea punteada que se encuentra perpendicular a la línea de la mediana representa la media y el rombo punteado representa la desviación

estándar. Los resultados de *DeepConvNet* muestran características deseadas en su desempeño con los sujetos de la prueba. La diferencia de la mediana y la media es pequeña, mostrando que el desempeño se distribuye uniformemente, dirigiéndose a una distribución normal. La longitud de la desviación estándar se encuentra dentro del rango intercuartílico, lo que quiere decir que no hay muchos valores fuera de dicho rango. Estas características nos dan indicio que el desempeño del modelo fue razonablemente bueno.

4.3. Componentes emocionales

En el modelo dimensional (véase la sección 3.1) el *valence* y *arousal* son los componentes que conforman la emoción, pues a partir de sus valores se representa el amplio rango de emociones. La obtención de las emocionales se llevan a cabo por medio de dos métodos: SAM y señales de EEG. Al término de cada simulación, el DM brinda los valores del SAM y a las señales de EEG se le extraen sus respuestas emocionales, utilizando un modelo previamente entrenado con sus señales capturadas en el protocolo de adquisición.

Realizamos una prueba *t-test* con $\alpha = 0.05$ para identificar si la BCI es consistente con los componentes emocionales obtenidos a través del SAM. La prueba utilizada se basó durante el desarrollo del análisis de nuestras evaluaciones experimentales donde se obtuvo que los datos siguen una distribución normal. Se obtienen valores en la prueba de (0.67825725, 0.00871432), respectivamente al *valence* y *arousal*. Los resultados nos indican que en el *arousal* la hipótesis nula es rechazada, pero en el *valence* no. El *arousal* puede haberse influenciado por el audio, ya que se observó durante la experimentación que las estimulaciones auditivas tienen efecto en la emoción capturada con el SAM. En la cuestión fisiológica la música produce cambios en la actividad neuronal, pues se ha evidenciado que el ruido de fondo con un pensamiento prospectivo puede aumentar la carga cognitiva y la excitación emocional (92) además, tiene efecto en nuestra toma de decisiones y riesgos (89),

4.4. Preferencias emocionales

Las preferencias emocionales se calculan con las emociones dadas en términos de *valence* y *arousal*. Sus valores son utilizados para obtener su valor correspondiente de PBI (véase la sección 3.8) el cual representa su preferencia emocional; es un valor escalar que representa su agrado hacia emociones de felicidad y la calma. En términos de nuestra aplicación se desea que las selecciones de las opciones preferidas en las tomas de decisiones sean las que se acerquen más a estados de satisfacción. El PBI se utiliza para seleccionar el individuo preferido emocionalmente, los neurocontrolador participes en una toma de decisiones el que posea el valor de PBI más alto, es el preferido. El cálculo del PBI se lleva a cabo con las emociones capturadas con SAM y con las emociones decodificadas del EEG por *DeepConvNet*. Ambas fuentes emocionales se utilizan para realizar una comparativa entre lo que decía preferir el DM y lo que muestra su actividad neuronal.

En la figura 4.5 se muestran las variaciones de las preferencias emocionales del DM conforme se desarrolla la exploración de los frentes de Pareto o evolución del neurocontrolador. Las emociones pertenecientes a los neurocontroladores que se prefirieron en cada toma de decisiones, son los puntos que la conforman y los números asignados equivalen al orden en el cual fueron capturados.

Dado que los neurocontroladores poseen dos fuentes emocionales: lo que el DM le asigna con el SAM y la predicha por *DeepConvNet*; es posible generar dos versiones. Las gráficas que se encuentran del lado izquierdo de la figura 4.5 muestran las preferencias emocionales de los neurocontroladores usando los valores del SAM, mientras las de la derecha utilizan las emociones dadas por la CNN.

Se puede observar que las preferencias emocionales con el SAM y su respectiva gráfica de preferencias con la CNN, difieren. Se calcula la desviación de las preferencias para ambas fuentes emocionales para capturar su afinidad hacia la satisfacción; dicha desviación se calcula por medio de:

$$\sum_{i=1}^{n-1} \delta(vd(p_i, p_{i+1}), vd(p_i, r)) \quad (4.1)$$

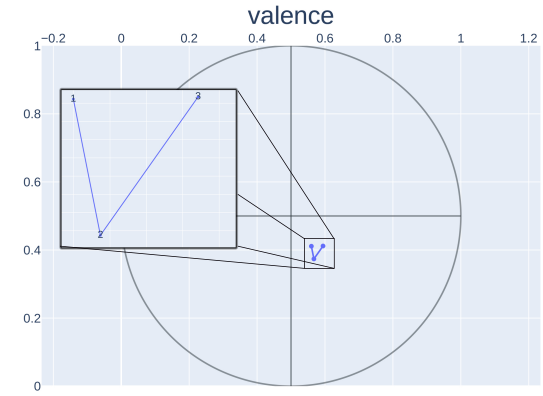
Donde $vd()$ es el vector director, n es el número de toma de decisiones o frentes de pareto

SAM




(a.1)


BCI




(a.2)




(b.1)





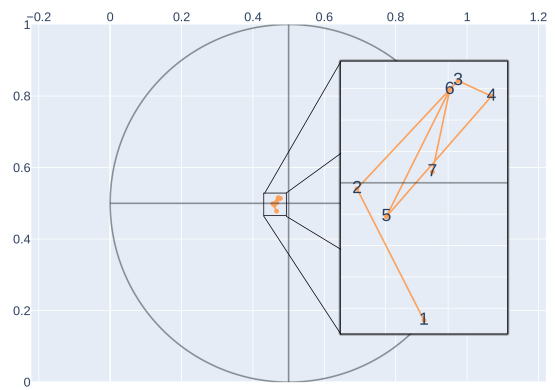

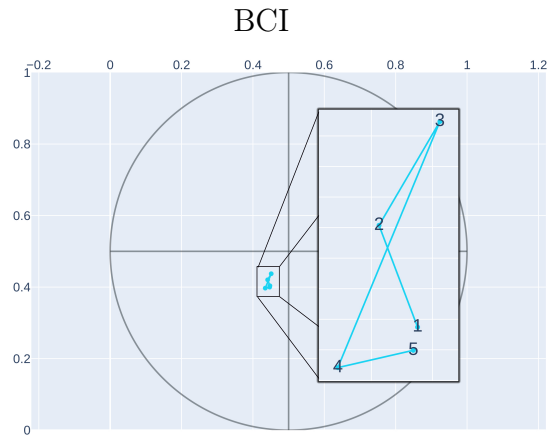
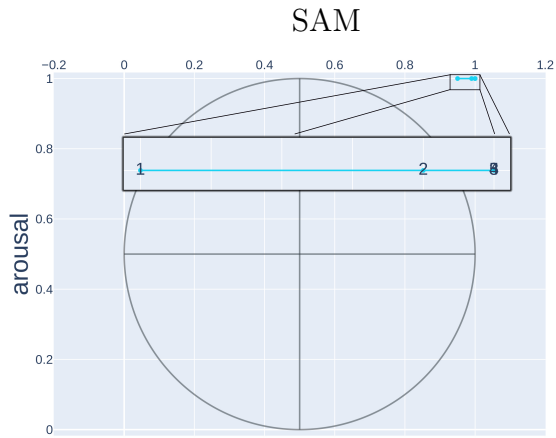
(b.2)



(c.1)



(c.2)



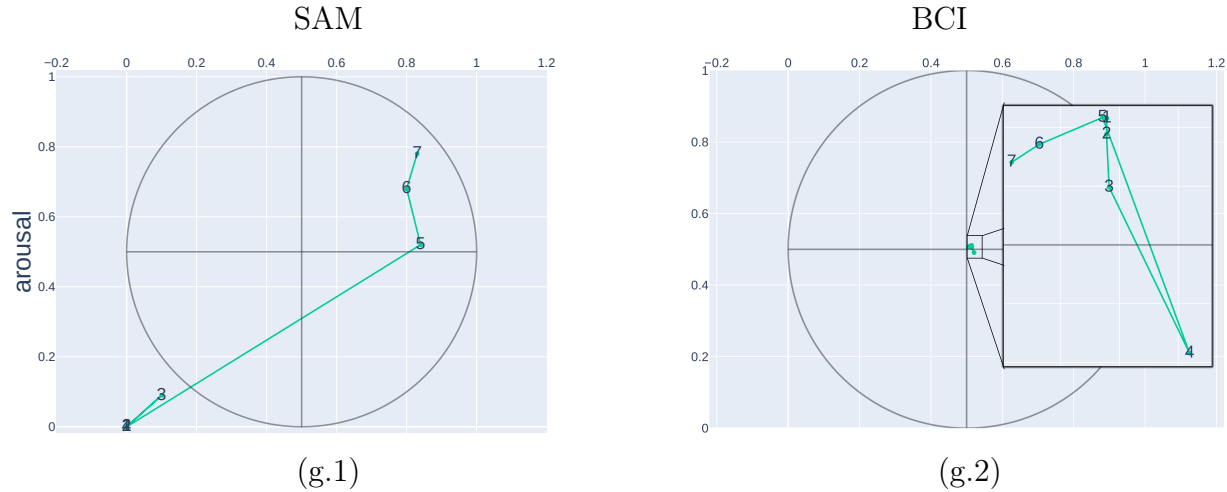


Figura 4.5: Variación de las preferencias emocionales ante las tomas de decisiones durante la evolución del neurocontrolador. Las gráficas de la (a.x) a la (g.x) muestran la variación del usuario 'a' al usuario 'g', respectivamente. Las gráficas (x.1) son las variaciones dados los valores del SAM y (x.2) con las predicciones de *DeepConvNet*.

presentados al DM, r la emoción hacia la cual se desea calcular la desviación, en nuestro caso se representan por los vectores $[1, 1]$ y $[1, 0]$, respectivamente. Dichas emociones son las que mayor representación tienen en el estado de satisfacción, el cual se conforma por todas las emociones que poseen valencia positiva, según el sistema de Russell.

En la figura 4.6 se muestra el grado de desviación total de las preferencias hacia la emoción de felicidad y calma. Dichas emociones son la base para capturar las preferencias, en la figura 3.16 se muestra gráficamente el espacio de preferencias emocionales sobre el modelo emocional: la felicidad y la calma son los estados que representan los valores más alto en la escala de las preferencias. Las desviaciones emocionales entre las dos fuentes emocionales, en la mayoría de los sujetos el tamaño de su diferencia es grande para la emoción de felicidad sin embargo, para la emoción de calma se encuentran más emparejadas.

Para determinar si se capturaron las preferencias sobre los neurocontroladores se utilizaron sus valores en el espacio de los objetivos. Se calcula la distancia entre el individuo seleccionado por cada fuente emocional en cada uno de los frentes de Pareto explorados por el DM. Se normalizan los objetivos con la fórmula:

$$\frac{f_i(x)}{\max f_i - \min f_i}, \quad i \in [1, 3] \quad (4.2)$$




Figura 4.6: Desviación de las preferencias para cada sujeto utilizando las dos fuentes emocionales: SAM y la CNN. La figura (a) es la desviación hacia la calma y la figura (b) hacia la felicidad.

Donde f_i hace referencia a los objetivos y $f_i(x)$ al valor obtenido para el objetivo tras la simulación del neurocontrolador. En la figura 4.7 se presenta la distribución de las preferencias, el eje x es la distancia euclidiana entre el neurocontrolador preferido con SAM y la CNN, el eje y es el conteo de neurocontroladores. Como puede observarse en dicha figura la cantidad de opciones preferidas por las dos fuentes emocionales se cargan hacia el cero, lo que quiere decir que las preferencias emocionales tuvieron efecto parecido en la selección de los neurocontroladores.




Figura 4.7: Distribución de los neurocontroladores preferidos con SAM y las emociones detectadas con la CNN. Se utiliza la distancia entre los neurocontroladores

Capítulo 5

Conclusiones

En este estudio nos planteamos la posibilidad de capturar las preferencias del DM a partir de sus emociones, embebidas en señales de EEG capturadas durante las simulaciones de robots. Las emociones podrían ser detectadas a partir de una red convolucional, entrenada con señales de EEG provenientes de la estimulación con videos. Nuestros resultados, presentados en el capítulo 4, muestran que se consiguió realizar la detección emocional en las etapas de entrenamiento y en línea. En la etapa de entrenamiento, se obtuvieron valores bajos para las métricas de evaluación MSE y MAE. Mientras que en el sistema en línea, debido al tiempo entre su realización y el entrenamiento de la red, las emociones dadas por la CNN y la herramienta SAM difieren. Por lo anterior se realizó un análisis estadístico con la cual se mostró que los efectos de la emoción fueron consistentes entre lo capturado con las dos fuentes emocionales pero solo en un componente emocional: el *arousal*. A pesar de la discrepancia entre las dos fuentes emocionales, se pudieron extraer las preferencias del DM pues sus efectos en la selección de las opciones (neurocontroladores) fue parecida. Por lo anterior, corroboramos nuestra hipótesis, pues nuestro sistema es funcional.

La detección automática de emociones a partir de señales de EEG es un tema de investigación que ha crecido últimamente. Gran parte de su desarrollo se ha debido a los avances en el aprendizaje de máquina, pues principalmente se basa en este tipo de algoritmos. En el presente trabajo utilizamos CNN propuestas en el estado del arte, con las cuales realizamos el reconocimiento emocional con señales de EEG. La teoría y las investigaciones sobre las emociones muestran que éstas se hacen presentes en la actividad

neuronal, lo que hizo posible realizar su reconocimiento. Sin embargo, se enfrenta a varias problemáticas que se fueron identificando durante el desarrollo de nuestros experimentos, entre ellas se pueden encontrar problemas entre las sesiones: el tiempo entre experimentos, la dificultad de obtener con el casco EEG exactamente la misma impedancia; o relacionadas al sujeto: como el uso de redes personalizadas debido a la baja cantidad de sujetos de prueba; más adelante se abordan sus afectos o como se trataron, en la sección de trabajo futuro se hace mención de otras problemáticas.

Las tres propuestas de CNN para su uso en la detección automática de emociones son: *EEGNet*, *DeepConvNet* y *ShallowConvNet*. Debido a que las señales capturadas con nuestro protocolo de entrenamiento no es tan extenso, para comparar el rendimiento de la detección emocional con dichas redes se utilizó DEAP, el cual es un conjunto de datos que se ha utilizado en el estado del arte para realizar la detección emocional. Las tres redes demostraron su capacidad para la detección automática de emociones, pues los valores obtenidos para medir su rendimiento fueron buenos. Cabe mencionar que los rendimientos de las tres redes poseen cierto grado de similitud. Por lo anterior dichas redes son adecuadas para su uso en tareas de detección emocional con señales de EEG.

La CNN seleccionada para su uso en el sistema en línea fue *DeepConvNet*. Se entrenó con los datos del protocolo de entrenamiento y se midió su rendimiento. Los resultados mostraron que la red tiene la capacidad de realizar la detección emocional con las señales de EEG capturadas con el casco Ultracortex. La detección emocional se trató como un enfoque específico del sujeto, es decir, que hay una red diferente por cada sujeto. Este enfoque presenta limitaciones aunque fue el más adecuado para su aplicación en la BCI, pues la tasa de muestreo del equipo de adquisición de EEG es baja y la cantidad de sujetos de prueba no es extensa. La aplicación de métodos más robustos, que sean capaces de realizar la detección emocional para todos los sujetos es necesario de conjuntos de datos más grande al creado con nuestros experimentos.

El tiempo transcurrido entre el protocolo de entrenamiento y la BCI fue largo, lo que provocó un detrimento en la precisión de la detección emocional. El EEG es una señal no estacionaria, es decir, la actividad neuronal capturada ante un mismo estímulo, con condiciones iguales y pertenecientes al mismo sujeto de prueba, no es la misma. Debido a

lo anterior, las emociones dadas con SAM y la CNN no fueron tan parecidas entre sí, caso contrario en la etapa de entrenamiento. Para corroborar la capacidad de la detección se realizó una prueba estadística *t-test*, lo cual resultó que el *arousal* se mantuvo consistente entre lo capturado con SAM y lo dado por la CNN, lo que quiere decir que los efectos de éste componente fueron capturados. Cabe mencionar que la realización de la detección emocional entre diferentes sesiones acarrea problemáticas debido a cuestiones experimentales y fisiológicas: los electrodos no siempre se ubican de manera exacta en la misma posición en cada sesión, la impedancia de los electrodos puede ser distinta y la señal EEG es no estacionaria. Lo anterior se puede ver reflejado en el movimiento de la covarianza de la señal entre las sesiones; con los métodos que permiten realizar la detección emocional para varios sujetos la ajustan en su modelo, para mejorar la predicción.

El sistema propuesto utiliza las emociones para capturar las preferencias emocionales del DM. Esto se logró al someter al DM a varias tomas de decisiones utilizando las soluciones generadas por un optimizador. Las emociones influyen en la toma de decisiones siendo esto útil en nuestro caso de estudio, sin embargo, da paso a un problema complejo de decisión. Regularmente los trabajos que abordan este tema utilizan un conjunto no muy extenso de opciones, con variaciones controladas. Los frentes de Pareto que se presentaron al DM fueron la toma de decisiones donde los individuos seleccionados, cuyo resultado se mostró en la simulación, fueron las opciones o alternativas. El modelo emocional fue el método por el cual se calcularon las preferencias y se llevó a cabo la exploración del proceso evolutivo.

Las soluciones entregadas por el optimizador son soluciones con valores buenos para cada uno de los objetivos, y en cada generación del algoritmo van mejorando; en el contexto de optimización se refiere a que se van generando soluciones no dominadas. Lo anterior quiere decir que los valores de los objetivos cambian, con lo cual las opciones presentadas en las tomas de decisiones no son los mismos. Sin embargo, las opciones durante el desarrollo del experimento guardan un grado de similitud con opciones anteriores y posteriores. Tomando en cuenta lo anterior y los resultados observados en la gráfica 4.6, se puede notar que las variaciones de las preferencias no siempre se dirigen hacia las emociones esperadas, aunque las soluciones mejoren gradualmente. Este fenómeno probablemente puede produ-

cirse por la atención del DM, en diferentes estimulaciones puede darle diferente peso a los objetivos o se presentaron situaciones en la simulación que le dieron la sensación que no eran soluciones mejores con respecto a las anteriores; en otras palabras tenían la sensación que su elección no había sido la correcta. Los resultados experimentales mostraron que la desviación de las preferencias emocionales son menores hacia la calma en comparación a la felicidad, lo que quiere decir que las variaciones entre el SAM y la CNN se encuentran en mayor sintonía hacia la calma. Dichas emociones son los estados que se buscaron dirigir la selección de los neurocontroladores por parte de la DM. Para mostrar que se extrajeron las preferencias, se usó la distancia entre la selección de los neurocontroladores con SAM y la CNN. Los resultados mostraron que ambas selecciones están cargadas hacia el cero, lo que quiere decir que el efecto de las variaciones de las preferencias están en sintonía con lo que decía preferir el DM y lo que mostraba su actividad neuronal.

Las preferencias pueden cambiar con el tiempo, pues entre más experiencia adquirimos sobre el problema, fenómenos como la revaloración, la atención o el aprendizaje pueden influir en nuestra percepción sobre dicho problema, teniendo efecto en las emociones enlazadas a las opciones de la toma de decisiones. Además, el proceso evolutivo posee características estocásticas, teniendo efecto en las soluciones generadas, ya que se pueden producir distintas en diferentes ejecuciones del optimizador. El teorema de *No free lunch* (123) nos dice que no hay algoritmo de optimización superior para todo tipo de problemas, mientras mejora en unos empeora en otros; esta característica tiene implicaciones sobre las soluciones generadas. Por lo anterior, el cambio del optimizador sería otro detonante para producir soluciones distintas. Por lo anterior deducimos que los resultados obtenidos son una instancia de los fenómenos emocionales relacionados con el proceso evolutivo.

5.1. Trabajo futuro

Se observaron ciertos detalles durante los experimentos, sería deseable en trabajo futuro implementar mecanismos para tratarlos para aumentar la precisión de la detección emocional; a continuación se presentan. Las señales de EEG capturadas con el equipo de bajo costo nos permitió detectar las emociones, con buenos resultados durante el entrena-

miento. Los sujetos fueron estimulados con videos relacionados a nuestro caso de estudio y con videos musicales que buscan evocar emociones diversas que se diferencien entre sí. Las condiciones ambientales, indicaciones del experimento y de estimulación fue la misma para todos los sujetos sin embargo, algunos de los usuarios través de la platica de su experiencia durante el protocolo de entrenamiento, se notó que consideraron en su autoevaluación emocional partes fuera de la estimulación, como la calidad del video, la interfaz gráfica y sus gustos musicales. En la aplicación de la BCI, a los sujetos se les indicó dirigir su atención al comportamiento del robot durante su manejo y debían de tener en cuenta los objetivos utilizados en la optimización, con el fin de evolucionar el robot con sus emociones. Se les proporcionó una explicación de los elementos de la interfaz gráfica y que al finalizar cada simulación tendrían que proporcionar la emoción que ellos habían experimentado por medio de SAM. La herramienta SAM no tiene ningún efecto en la BCI, solo fue para fines comparativos sin embargo, se notó un sesgo por algunos sujetos ya que argumentaban que el robot respondía con los valores que ingresaban con la herramienta. Posiblemente se deba a que la BCI es reactiva, pues el sistema responde en base a las emociones detectadas debido a las estimulaciones y el SAM les creó una sensación de control. El efecto es notorio en la ruta emocional del sujeto d.1) de la figura 4.5, sus preferencias dadas con el SAM poseen poca variabilidad. La estructura del casco ultracortex está construido por medio de técnicas de impresión 3D y los electrodos que posee son secos. Dichos electrodos cuentan con pequeñas puntas que hacen contacto con el cuero cabelludo por medio de unos resortes, aunque la fuerza ejercida no es fuerte, se observó que el uso prolongado del casco empieza a ser incómodo; esto impone un límite de tiempo para la duración de los experimentos. En lo relacionado con su estructura notamos que lo hace vulnerable a movimientos bruscos por parte del DM, ya que se corre el riesgo de que se muevan los electrodos de su lugar. Se pudo minimizar dicho efecto al hacerle énfasis a los sujetos que se mantuvieran quietos durante las estimulaciones y que adquirieran una posición cómoda.

La detección emocional también puede ser mejorado por cambios en el método, los cuales se mencionan a continuación. La incorporación de más videos relacionados a los objetivos buscados por el neurocontrolador sería de utilidad para una mejora en la traducción de la actividad neuronal. En nuestro método no se incorporaron técnicas para

la eliminación de artefactos presentes en el EEG, producidos por la actividad interna del cuerpo, los filtros no los eliminan del todo, se observó que dejan rastros en la señal; una técnica comúnmente utilizada es *ICA*. También sería deseable la implementación de métodos multimodales, o sea, que tomen de entrada datos provenientes de distintas fuentes, como pueden ser señales de fuentes biológicas como: el electrocardiograma, la respuesta galvánica de la piel; o de comportamiento: expresiones del rostro, reconocimiento del habla, postura del cuerpo, por mencionar algunas.

Bibliografía

- [1] Adrian Rodriguez Aguiñaga y Miguel Angel Lopez Ramirez. Emotional states recognition, implementing a low computational complexity strategy. *Health Informatics Journal*, 24:146–170, 6 2018. ISSN 17412811. doi: 10.1177/1460458216661862.
- [2] Soraia M Alarcão y Manuel J Fonseca. Emotions Recognition Using EEG Signals: A Survey. *IEEE Transactions on Affective Computing*, 10(3):374–393, 2019. doi: 10.1109/TAFFC.2017.2714671.
- [3] Amelia Aldao, Susan Nolen-Hoeksema, y Susanne Schweizer. Emotion-regulation strategies across psychopathology: A meta-analytic review. *Clinical Psychology Review*, 30(2):217–237, 2010. ISSN 0272-7358. doi: <https://doi.org/10.1016/j.cpr.2009.11.004>. URL <https://www.sciencedirect.com/science/article/pii/S0272735809001597>.
- [4] Marvin Andujar, Chris S Crawford, Anton Nijholt, France Jackson, y Juan E Gilbert. Artistic brain-computer interfaces: the expression and stimulation of the user’s affective state. *Brain-Computer Interfaces*, 2(2-3):60–69, 2015. doi: 10.1080/2326263X.2015.1104613. URL <https://doi.org/10.1080/2326263X.2015.1104613>.
- [5] Markus Appel, David Izydorczyk, Silvana Weber, Martina Mara, y Tanja Lischetzke. The uncanny of mind in a machine: Humanoid robots as tools, agents, and experiencers. *Computers in Human Behavior*, 102:274–286, 2020. ISSN 0747-5632. doi: <https://doi.org/10.1016/j.chb.2019.07.031>. URL <https://www.sciencedirect.com/science/article/pii/S0747563219302742>.

- [6] Asma Baghdadi, Yassine Aribi, y Adel M Alimi. A Survey of Methods and Performances for EEG-Based Emotion Recognition. In Ajith Abraham, Abdelkrim Haqiq, Adel M Alimi, Ghita Mezzour, Nizar Rokbani, y Azah Kamilah Muda, editors, *Proceedings of the 16th International Conference on Hybrid Intelligent Systems (HIS 2016)*, pages 164–174, Cham, 2017. Springer International Publishing. ISBN 978-3-319-52941-7.
- [7] Wiem Mimoun Ben Henia y Zied Lachiri. Embedded Emotion Recognition System Based on Electrocardiogram Attributes. In *2018 41st International Conference on Telecommunications and Signal Processing (TSP)*, pages 1–4, 2018. doi: 10.1109/TSP.2018.8441234.
- [8] Nicola Beume, Boris Naujoks, y Michael Emmerich. SMS-EMOA: Multiobjective selection based on dominated hypervolume. *European Journal of Operational Research*, 181(3):1653–1669, 2007. ISSN 0377-2217. doi: <https://doi.org/10.1016/j.ejor.2006.08.008>. URL <https://www.sciencedirect.com/science/article/pii/S0377221706005443>.
- [9] Saugat Bhattacharyya, Davide Valeriani, Caterina Cinel, Luca Citi, y Riccardo Poli. Anytime collaborative brain–computer interfaces for enhancing perceptual group decision-making. *Scientific Reports*, 11(1):17008, 2021. ISSN 2045-2322. doi: 10.1038/s41598-021-96434-0. URL <https://doi.org/10.1038/s41598-021-96434-0>.
- [10] Adnan Mehmood Bhatti, Muhammad Majid, Syed Muhammad Anwar, y Bilal Khan. Human emotion recognition and analysis in response to audio music using brain signals. *Computers in Human Behavior*, 65:267–275, 2016. ISSN 0747-5632. doi: <https://doi.org/10.1016/j.chb.2016.08.029>. URL <https://www.sciencedirect.com/science/article/pii/S0747563216305945>.
- [11] Margaret M Bradley y Peter J Lang. *International Affective Picture System*, pages 2347–2350. Springer International Publishing, Cham, 2020. ISBN 978-3-319-24612-3. doi: 10.1007/978-3-319-24612-3_42. URL https://doi.org/10.1007/978-3-319-24612-3_42.

- [12] K. Brodmann y Laurence J. Garey. *Brodmann's Localisation in the Cerebral Cortex*. Imperial College Press, 1999. ISBN 1860941761, 9781860941764.
- [13] Felipe Zago Canal, Tobias Rossi Müller, Jhennifer Cristine Matias, Gustavo Gino Scotton, Antonio Reis de Sa Junior, Eliane Pozzebon, y Antonio Carlos Sobieranski. A survey on facial emotion recognition techniques: A state-of-the-art literature review. *Information Sciences*, 582:593–617, 2022. ISSN 0020-0255. doi: <https://doi.org/10.1016/j.ins.2021.10.005>. URL <https://www.sciencedirect.com/science/article/pii/S0020025521010136>.
- [14] Daniel Cernea y Andreas Kerren. A survey of technologies on the rise for emotion-enhanced interaction. *Journal of Visual Languages Computing*, 31:70–86, 2015. ISSN 1045-926X. doi: <https://doi.org/10.1016/j.jvlc.2015.10.001>.
- [15] Sheshadri Chatterjee, Ranjan Chaudhuri, y Demetris Vrontis. Masstige marketing: An empirical study of consumer perception and product attributes with moderating role of status, emotion, and pride. *Journal of Business Research*, 155:113401, 2023. ISSN 0148-2963. doi: <https://doi.org/10.1016/j.jbusres.2022.113401>. URL <https://www.sciencedirect.com/science/article/pii/S0148296322008669>.
- [16] J X Chen, P W Zhang, Z J Mao, Y F Huang, D M Jiang, y Y N Zhang. Accurate eeg-based emotion recognition on combined features using deep convolutional neural networks. *IEEE Access*, 7:44317–44328, 2019. doi: 10.1109/ACCESS.2019.2908285.
- [17] Juan Cheng, Meiyao Chen, Chang Li, Yu Liu, Rencheng Song, Aiping Liu, y Xun Chen. Emotion Recognition from Multi-Channel EEG via Deep Forest. *IEEE Journal of Biomedical and Health Informatics*, 25(2):453–464, 2021. ISSN 21682208. doi: 10.1109/JBHI.2020.2995767.
- [18] Alessandro Chiurco, Jessica Frangella, Francesco Longo, Letizia Nicoletti, Antonio Padovano, Vittorio Solina, Giovanni Mirabelli, y Claudia Citraro. Real-time Detection of Worker's Emotions for Advanced Human-Robot Interaction during Collaborative Tasks in Smart Factories. *Procedia Computer Science*, 200:1875–1884,

2022. ISSN 1877-0509. doi: <https://doi.org/10.1016/j.procs.2022.01.388>. URL <https://www.sciencedirect.com/science/article/pii/S1877050922003970>.
- [19] Prokopis Christou, Aspasia Simillidou, y Maria C Stylianou. Tourists' perceptions regarding the use of anthropomorphic robots in tourism and hospitality. *International Journal of Contemporary Hospitality Management*, 32(11):3665–3683, jan 2020. ISSN 0959-6119. doi: 10.1108/IJCHM-05-2020-0423. URL <https://doi.org/10.1108/IJCHM-05-2020-0423>.
- [20] C. A. Coello Coello. Evolutionary multi-objective optimization: A historical view of the field. *IEEE Computational Intelligence Magazine*, 1(1):28–36, feb 2006. ISSN 1556603X. doi: 10.1109/MCI.2006.1597059.
- [21] Carlos A. Coello Coello. A Comprehensive Survey of Evolutionary-Based Multiobjective Optimization Techniques. *Knowledge and Information Systems*, 1(3):269–308, jul 1999. ISSN 0219-3116. doi: 10.1007/BF03325101.
- [22] Lorenzo Cominelli, Francesco Feri, Roberto Garofalo, Caterina Giannetti, Miguel A Meléndez-Jiménez, Alberto Greco, Mimma Nardelli, Enzo Pasquale Scilingo, y Oliver Kirchkamp. Promises and trust in human–robot interaction. *Scientific Reports*, 11(1):9687, 2021. ISSN 2045-2322. doi: 10.1038/s41598-021-88622-9. URL <https://doi.org/10.1038/s41598-021-88622-9>.
- [23] Pedro Manuel Cortes, Juan Pablo García-Hernández, Fabiola Alejandra Iriburgos, Marisela Hernández-González, Carolina Sotelo-Tapia, y Miguel Angel Guevara. Temporal division of the decision-making process: An EEG study. *Brain Research*, 1769:147592, 2021. ISSN 0006-8993. doi: <https://doi.org/10.1016/j.brainres.2021.147592>. URL <https://www.sciencedirect.com/science/article/pii/S0006899321004492>.
- [24] Li Dai y Zheng Xie. Simulated annealing algorithm for finding the spanning directed trees with many leaves. In *2011 International Conference on Computer Science and Service System (CSSS)*, pages 1688–1690, 2011. doi: 10.1109/CSSS.2011.5974942.

- [25] Antonio R Damasio. *Descartes' error : emotion, reason, and the human brain*. G.P. Putnam New York, 1994. ISBN 0399138943.
- [26] Felipe Nogueira de Carvalho. How shallow is fear? Deepening the waters of emotion with a social/externalist account. *Philosophical Psychology*, 0(0):1–9, 2022. doi: 10.1080/09515089.2022.2160309.
- [27] Kalyanmoy Deb y Himanshu Jain. An Evolutionary Many-Objective Optimization Algorithm Using Reference-Point-Based Nondominated Sorting Approach, Part I: Solving Problems With Box Constraints. *IEEE Transactions on Evolutionary Computation*, 18(4):577–601, 2014. doi: 10.1109/TEVC.2013.2281535.
- [28] Kalyanmoy Deb, Samir Agrawal, Amrit Pratap, y T. Meyarivan. A Fast Elitist Nondominated Sorting Genetic Algorithm for Multi-objective Optimization: NSGA-II. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 1917:849–858, 2000. ISSN 16113349. doi: 10.1007/3-540-45356-3_83.
- [29] Kalyanmoy Deb, Amrit Pratap, Sameer Agarwal, y T. Meyarivan. A fast and elitist multiobjective genetic algorithm: NSGA-II. *IEEE Transactions on Evolutionary Computation*, 6(2):182–197, apr 2002. ISSN 1089778X. doi: 10.1109/4235.996017.
- [30] William Dias, Fernanda Andaló, Rafael Padilha, Gabriel Bertocco, Waldir Almeida, Paula Costa, y Anderson Rocha. Cross-dataset emotion recognition from facial expressions through convolutional neural networks. *Journal of Visual Communication and Image Representation*, 82:103395, 2022. ISSN 1047-3203. doi: <https://doi.org/10.1016/j.jvcir.2021.103395>. URL <https://www.sciencedirect.com/science/article/pii/S1047320321002637>.
- [31] Sherif A Fahmy, Bader A Alablani, y Tamer F Abdelmaguid. A Tabu Search Approach for Designing Shopping Centers. In *2017 9th IEEE-GCC Conference and Exhibition (GCCCE)*, pages 1–9, 2017. doi: 10.1109/IEEEGCC.2017.8447954.

- [32] Jesús Guillermo Falcón-Cardona y Carlos A Coello Coello. A Multi-Objective Evolutionary Hyper-Heuristic Based on Multiple Indicator-Based Density Estimators. In *Proceedings of the Genetic and Evolutionary Computation Conference, GECCO '18*, pages 633–640, New York, NY, USA, 2018. Association for Computing Machinery. ISBN 9781450356183. doi: 10.1145/3205455.3205463. URL <https://doi.org/10.1145/3205455.3205463>.
- [33] Jesús Guillermo Falcón-Cardona y Carlos A Coello Coello. Indicator-Based Multi-Objective Evolutionary Algorithms: A Comprehensive Survey. *ACM Comput. Surv.*, 53(2), mar 2020. ISSN 0360-0300. doi: 10.1145/3376916. URL <https://doi.org/10.1145/3376916>.
- [34] Masoud Fetanat, Sajjad Haghzad, y Saeed Bagheri Shouraki. Optimization of dynamic mobile robot path planning based on evolutionary methods. *2015 AI and Robotics, IRANOPEN 2015 - 5th Conference on Artificial Intelligence and Robotics*, sep 2015. doi: 10.1109/RIOS.2015.7270743.
- [35] Elifsu Filiz y Reis Burak Arslan. Design and Implementation of Steady State Visual Evoked Potential Based Brain Computer Interface Video Game. In *2020 IEEE 20th Mediterranean Electrotechnical Conference (MELECON)*, pages 335–338, 2020. doi: 10.1109/MELECON48756.2020.9140710.
- [36] Paul W Glimcher. Chapter 5 - Introduction to Neuroscience. In Paul W Glimcher y Ernst Fehr, editors, *Neuroeconomics (Second Edition)*, pages 63–75. Academic Press, San Diego, second edi edition, 2014. ISBN 978-0-12-416008-8. doi: <https://doi.org/10.1016/B978-0-12-416008-8.00005-X>. URL <https://www.sciencedirect.com/science/article/pii/B978012416008800005X>.
- [37] Parnaz Golnar-Nik, Sajjad Farashi, y Mir-Shahram Safari. The application of EEG power for the prediction and interpretation of consumer decision-making: A neuromarketing study. *Physiology Behavior*, 207:90–98, 2019. ISSN 0031-9384. doi: <https://doi.org/10.1016/j.physbeh.2019.04.025>.

- [38] A Goshvarpour, A Abbasi, y A Goshvarpour. An emotion recognition approach based on wavelet transform and second-order difference plot of eeg. *Journal of AI and Data Mining*, 5:211–221, 2017. ISSN 2322-5211. doi: 10.22044/jadm.2017.887.
- [39] Simeng Gu, Fushun Wang, Nitesh P Patel, James A Bourgeois, y Jason H Huang. A Model for Basic Emotions Using Observations of Behavior in Drosophila. *Frontiers in Psychology*, 10, 2019. ISSN 1664-1078. doi: 10.3389/fpsyg.2019.00781.
- [40] Kunal Gupta. [DC] Exploration of Context and Physiological Cues for Personalized Emotion-Adaptive Virtual Reality. In *2022 IEEE Conference on Virtual Reality and 3D User Interfaces Abstracts and Workshops (VRW)*, pages 960–961, 2022. doi: 10.1109/VRW55335.2022.00331.
- [41] Ingrid J Haas. The Impact of Uncertainty, Threat, and Political Identity on Support for Political Compromise. *Basic and Applied Social Psychology*, 38(3):137–152, 2016. doi: 10.1080/01973533.2016.1169181.
- [42] Stelios K Hadjidimitriou y Leontios J Hadjileontiadis. Toward an EEG-Based Recognition of Music Liking Using Time-Frequency Analysis. *IEEE Transactions on Biomedical Engineering*, 59(12):3498–3510, 2012. doi: 10.1109/TBME.2012.2217495.
- [43] Honggui Han, Yucheng Liu, Ying Hou, y Junfei Qiao. Multi-modal multi-objective particle swarm optimization with self-adjusting strategy. *Information Sciences*, 629: 580–598, 2023. ISSN 0020-0255. doi: <https://doi.org/10.1016/j.ins.2023.02.019>.
- [44] Robert Hepach, Dorit Kliemann, Sebastian Grüneisen, Hauke R. Heekeren, y Isabel Dziobek. Conceptualizing Emotions Along the Dimensions of Valence, Arousal, and Communicative Frequency – Implications for Social-Cognitive Tests and Training Tools. *Frontiers in Psychology*, 2(OCT), 2011. ISSN 16641078. doi: 10.3389/FPSYG.2011.00266.
- [45] Carolina Herrando y Efthymios Constantinides. Emotional Contagion: A Brief Overview and Future Directions. *Frontiers in Psychology*, 12, 2021. ISSN 1664-1078. doi: 10.3389/fpsyg.2021.712606.

- [46] Dongmin Huang, Sentao Chen, Cheng Liu, Lin Zheng, Zhihang Tian, y Dazhi Jiang. Differences first in asymmetric brain: A bi-hemisphere discrepancy convolutional neural network for EEG emotion recognition. *Neurocomputing*, 448:140–151, 2021. ISSN 0925-2312. doi: <https://doi.org/10.1016/j.neucom.2021.03.105>. URL <https://www.sciencedirect.com/science/article/pii/S0925231221004975>.
- [47] Haiyun Huang, Qiuyou Xie, Jiahui Pan, Yanbin He, Zhenfu Wen, Ronghao Yu, y Yuanqing Li. An EEG-Based Brain Computer Interface for Emotion Recognition and Its Application in Patients with Disorder of Consciousness. *IEEE Transactions on Affective Computing*, 12(4):832–842, 2021. doi: 10.1109/TAFFC.2019.2901456.
- [48] Daniel D Hutto, Ian Robertson, y Michael D Kirchhoff. A new, better bet: Rescuing and revising basic emotion theory. *Frontiers in Psychology*, 9, 2018. ISSN 1664-1078. doi: 10.3389/fpsyg.2018.01217.
- [49] Sunhee Hwang, Kibeom Hong, Guiyoung Son, y Hyeran Byun. Learning cnn features from de features for eeg-based emotion recognition. *Pattern Analysis and Applications*, 23:1323–1335, 2020. ISSN 1433-755X. doi: 10.1007/s10044-019-00860-w.
- [50] Ashok Kumar J, Erik Cambria, y Tina Esther Trueman. Duse: A new benchmark dataset for drug user sentiment extraction. In *2021 International Conference on Data Mining Workshops (ICDMW)*, pages 174–178, 2021. doi: 10.1109/ICDMW53433.2021.00028.
- [51] Himanshu Jain y Kalyanmoy Deb. An Evolutionary Many-Objective Optimization Algorithm Using Reference-Point Based Nondominated Sorting Approach, Part II: Handling Constraints and Extending to an Adaptive Approach. *IEEE Transactions on Evolutionary Computation*, 18(4):602–622, 2014. doi: 10.1109/TEVC.2013.2281534.
- [52] Wilfried Jakob, Martina Gorges-Schleuter, y Christian Blume. Application of Genetic Algorithms to Task Planning and Learning. In *PPSN II*, pages 293–302, 1992.

- [53] Muhammad Abid Jamil, Ahmad Alhindi, Muhammad Arif, Mohamed K Nour, Nor-mi Sham Awang Abubakar, y Tareq Fahad Aljabri. Multiobjective Evolutionary Algorithms NSGA-II and NSGA-III for Software Product Lines Testing Optimization. In *2019 IEEE 6th International Conference on Engineering Technologies and Applied Sciences (ICETAS)*, pages 1–5, 2019. doi: 10.1109/ICETAS48360.2019.9117500.
- [54] Yerim Ji y Suh-Yeon Dong. Deep learning-based self-induced emotion recognition using EEG. *Frontiers in Neuroscience*, 16, 2022. doi: 10.3389/fnins.2022.985709.
- [55] Eric R Kandel. Biology and the future of psychoanalysis: a new intellectual framework for psychiatry revisited. *American journal of Psychiatry*, 156(4):505–524, 1999.
- [56] I Khettabi, L Benyoucef, y M A Boutiche. Sustainable Multi-objective Process Plan Generation in RMS: Dynamic NSGA-II vs New Dynamic NSGA-II. In *2021 IEEE International Conference on Industrial Engineering and Engineering Management (IEEM)*, pages 618–623, 2021. doi: 10.1109/IEEM50564.2021.9672869.
- [57] Mifa Kim, Tomoyuki Hiroyasu, Mitsunori Miki, y Shinya Watanabe. SPEA2+: Improving the Performance of the Strength Pareto Evolutionary Algorithm 2. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 3242:742–751, 2004. ISSN 16113349. doi: 10.1007/978-3-540-30217-9_75. URL https://link.springer.com/chapter/10.1007/978-3-540-30217-9_75.
- [58] S Kirkpatrick, C D Gelatt, y M P Vecchi. Optimization by Simulated Annealing. *Science*, 220(4598):671–680, 1983. doi: 10.1126/science.220.4598.671.
- [59] Sander Koelstra, Christian Mühl, Mohammad Soleymani, Jong Seok Lee, Ashkan Yazdani, Touradj Ebrahimi, Thierry Pun, Anton Nijholt, y Ioannis Patras. DEAP: A database for emotion analysis; Using physiological signals. *IEEE Transactions on Affective Computing*, 3(1):18–31, 2012. ISSN 19493045. doi: 10.1109/T-AFFC.2011.15.

- [60] A Kołakowska, A Landowska, M Szwoch, W Szwoch, y M R Wróbel. *Emotion Recognition and Its Applications*, pages 51–62. Springer International Publishing, Cham, 2014. ISBN 978-3-319-08491-6. doi: 10.1007/978-3-319-08491-6_5. URL https://doi.org/10.1007/978-3-319-08491-6_5.
- [61] Jacqueline M Kory Westlund, Sooyeon Jeong, Hae W Park, Samuel Ronfard, Aradhana Adhikari, Paul L Harris, David DeSteno, y Cynthia L Breazeal. Flat vs. Expressive Storytelling: Young Children’s Learning and Retention of a Social Robot’s Narrative. *Frontiers in Human Neuroscience*, 11, 2017. ISSN 1662-5161. doi: 10.3389/fnhum.2017.00295. URL <https://www.frontiersin.org/articles/10.3389/fnhum.2017.00295>.
- [62] Jialiang Kou, Shengwu Xiong, Hongbing Liu, y Xinlu Zong. Particle swarm and NSGA-II based evacuation simulation and multi-objective optimization. In *2011 Seventh International Conference on Natural Computation*, volume 3, pages 1265–1269, 2011. doi: 10.1109/ICNC.2011.6022332.
- [63] R J Kuo, Evan Edbert, Ferani E Zulvia, y Shih-Hao Lu. Applying NSGA-II to vehicle routing problem with drones considering makespan and carbon emission. *Expert Systems with Applications*, 221:119777, 2023. ISSN 0957-4174. doi: <https://doi.org/10.1016/j.eswa.2023.119777>. URL <https://www.sciencedirect.com/science/article/pii/S0957417423002786>.
- [64] Peter Kuppens, Francis Tuerlinckx, James A. Russell, y Lisa Feldman Barrett. The relation between valence and arousal in subjective experience. *Psychological Bulletin*, 139(4):917–940, jul 2013. ISSN 1939-1455. doi: 10.1037/a0030811.
- [65] Vernon J. Lawhern, Amelia J. Solon, Nicholas R. Waytowich, Stephen M. Gordon, Chou P. Hung, y Brent J. Lance. EEGNet: a compact convolutional neural network for EEG-based brain–computer interfaces. *Journal of Neural Engineering*, 15(5): 056013, jul 2018. ISSN 1741-2552. doi: 10.1088/1741-2552/AACE8C.
- [66] Margaret Lech, Melissa Stolar, Christopher Best, y Robert Bolia. Real-time speech emotion recognition using a pre-trained image classification network: Effects of band-

- width reduction and companding. *Frontiers in Computer Science*, 2, 2020. ISSN 2624-9898. doi: 10.3389/fcomp.2020.00014. URL <https://www.frontiersin.org/article/10.3389/fcomp.2020.00014>.
- [67] Joseph LeDoux. Rethinking the emotional brain. *Neuron*, 73:653–676, 2 2012. ISSN 08966273. doi: 10.1016/J.NEURON.2012.02.004.
- [68] Karolina M. Lempert y Elizabeth A. Phelps. Neuroeconomics of emotion and decision making. *Neuroeconomics: Decision Making and the Brain: Second Edition*, pages 219–236, 1 2014. doi: 10.1016/B978-0-12-416008-8.00012-7.
- [69] Gene Lesinski y Steven Corns. Multi-objective Evolutionary Neural Network to Predict Graduation Success at the United States Military Academy. *Procedia Computer Science*, 140:196–205, 2018. ISSN 1877-0509. doi: <https://doi.org/10.1016/j.procs.2018.10.329>. URL <https://www.sciencedirect.com/science/article/pii/S1877050918320027>.
- [70] Chang Li, Bin Wang, Silin Zhang, Yu Liu, Rencheng Song, Juan Cheng, y Xun Chen. Emotion recognition from eeg based on multi-task learning with capsule network and attention mechanism. *Computers in Biology and Medicine*, 143:105303, 4 2022. ISSN 0010-4825. doi: 10.1016/J.COMPBIOMED.2022.105303.
- [71] Chunbin Li, Xiao Sun, Yindong Dong, y Fuji Ren. Convolutional neural networks on eeg-based emotion recognition. In Hai Jin, Xuemin Lin, Xueqi Cheng, Xuanhua Shi, Nong Xiao, y Yihua Huang, editors, *Big Data*, pages 148–158, Singapore, 2019. Springer Singapore. ISBN 978-981-15-1899-7.
- [72] Dongdong Li, Li Xie, Bing Chai, Zhe Wang, y Hai Yang. Spatial-frequency convolutional self-attention network for EEG emotion recognition. *Applied Soft Computing*, 122:108740, 2022. ISSN 1568-4946. doi: <https://doi.org/10.1016/j.asoc.2022.108740>.
- [73] Zina Li, Lina Qiu, Ruixin Li, Zhipeng He, Jun Xiao, Yan Liang, Fei Wang, y Jiahui Pan. Enhancing BCI-based emotion recognition using an improved particle swarm

- optimization for feature selection. *Sensors (Switzerland)*, 20(11), jun 2020. ISSN 14248220. doi: 10.3390/s20113028.
- [74] Yuan-Pin Lin, Chi-Hong Wang, Tzyy-Ping Jung, Tien-Lin Wu, Shyh-Kang Jeng, Jeng-Ren Duann, y Jyh-Horng Chen. EEG-Based Emotion Recognition in Music Listening. *IEEE Transactions on Biomedical Engineering*, 57(7):1798–1806, 2010. doi: 10.1109/TBME.2010.2048568.
- [75] Kristen A. Lindquist, Ajay B. Satpute, Tor D. Wager, Jochen Weber, y Lisa Feldman Barrett. The Brain Basis of Positive and Negative Affect: Evidence from a Meta-Analysis of the Human Neuroimaging Literature. *Cerebral Cortex*, 26(5):1910–1922, may 2016. ISSN 1047-3211. doi: 10.1093/CERCOR/BHV001.
- [76] Junxiu Liu, Guopei Wu, Yuling Luo, Senhui Qiu, Su Yang, Wei Li, y Yifei Bi. EEG-Based Emotion Classification Using a Deep Neural Network and Sparse Autoencoder. *Frontiers in Systems Neuroscience*, 14, 2020. ISSN 1662-5137. doi: 10.3389/fnsys.2020.00043. URL <https://www.frontiersin.org/article/10.3389/fnsys.2020.00043>.
- [77] Yisi Liu, Olga Sourina, y Minh Khoa Nguyen. *Real-Time EEG-Based Emotion Recognition and Its Applications*, pages 256–277. Springer Berlin Heidelberg, Berlin, Heidelberg, 2011. ISBN 978-3-642-22336-5. doi: 10.1007/978-3-642-22336-5_13. URL https://doi.org/10.1007/978-3-642-22336-5_13.
- [78] Antonio López Jaimes y Carlos Coello. Including preferences into a multiobjective evolutionary algorithm to deal with many-objective engineering optimization problems. *Information Sciences*, 277:1–20, 2014. doi: 10.1016/j.ins.2014.04.023.
- [79] M. Maithri, U. Raghavendra, Anjan Gudigar, Jyothi Samanth, Prabal Datta Barua, Murugappan Murugappan, Yashas Chakole, y U. Rajendra Acharya. Automated emotion recognition: Current trends and future perspectives. *Computer Methods and Programs in Biomedicine*, 215:106646, mar 2022. ISSN 0169-2607. doi: 10.1016/J.CMPB.2022.106646.

- [80] Albert Mehrabian y James A Russell. *An approach to environmental psychology*. The MIT Press, Cambridge, MA, US, 1974. ISBN 0262130904.
- [81] Luis Alfredo Moctezuma, Takashi Abe, y Marta Molinas. Two-dimensional CNN-based distinction of human emotions from EEG channels selected by multi-objective evolutionary algorithm. *Scientific Reports*, 12(1):3523, 2022. ISSN 20452322. doi: 10.1038/s41598-022-07517-5. URL <https://doi.org/10.1038/s41598-022-07517-5>.
- [82] Seong-Eun Moon, Soobeom Jang, y Jong-Seok Lee. Convolutional Neural Network Approach for Eeg-Based Emotion Recognition Using Brain Connectivity and its Spatial Information. In *2018 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, pages 2556–2560, 2018. doi: 10.1109/ICASSP.2018.8461315.
- [83] Yulong Nan, Huichun Zhang, Yong Zeng, Jiaqiang Zheng, y Yufeng Ge. Faster and accurate green pepper detection using NSGA-II-based pruned YOLOv5l in the field environment. *Computers and Electronics in Agriculture*, 205:107563, 2023. ISSN 0168-1699. doi: <https://doi.org/10.1016/j.compag.2022.107563>. URL <https://www.sciencedirect.com/science/article/pii/S0168169922008717>.
- [84] Maital Neta y Ingrid J Haas. *Movere: Characterizing the Role of Emotion and Motivation in Shaping Human Behavior*, pages 1–9. Springer International Publishing, Cham, 2019. ISBN 978-3-030-27473-3. doi: 10.1007/978-3-030-27473-3_1.
- [85] Wang Kay Ngai, Haoran Xie, Di Zou, y Kee-Lee Chou. Emotion recognition based on convolutional neural networks and heterogeneous bio-signal data sources. *Information Fusion*, 77:107–117, 2022. ISSN 1566-2535. doi: <https://doi.org/10.1016/j.inffus.2021.07.007>. URL <https://www.sciencedirect.com/science/article/pii/S1566253521001457>.
- [86] Femke Nijboer, Fabrice O Morin, Stefan P Carmien, Randal A Koene, Enrique Leon, y Ulrich Hoffmann. Affective brain-computer interfaces: Psychophysiological markers of emotion in healthy persons and in persons with amyotrophic lateral sclerosis.

- In *2009 3rd International Conference on Affective Computing and Intelligent Interaction and Workshops*, pages 1–11, 2009. doi: 10.1109/ACII.2009.5349479.
- [87] Khairun Nisa' Minhada, Sawal Hamid Md Ali, Jonathan Ooi Shi Khai, y Siti Anom Ahmad. Human emotion classifications for automotive driver using skin conductance response signal. In *2016 International Conference on Advances in Electrical, Electronic and Systems Engineering (ICAEES)*, pages 371–375, 2016. doi: 10.1109/ICAEES.2016.7888072.
- [88] Sihem Nita, Salim Bitam, Matthieu Heidet, y Abdelhamid Mellouk. A new data augmentation convolutional neural network for human emotion recognition based on ECG signals. *Biomedical Signal Processing and Control*, 75:103580, 2022. ISSN 1746-8094. doi: <https://doi.org/10.1016/j.bspc.2022.103580>. URL <https://www.sciencedirect.com/science/article/pii/S1746809422001021>.
- [89] Ambra Palazzi, Bruna Wagner Fritzen, y Gustavo Gauer. Music-induced emotion effects on decision-making. *Psychology of Music*, 47(5):621–643, 2019. doi: 10.1177/0305735618779224. URL <https://doi.org/10.1177/0305735618779224>.
- [90] Zhenbao Pan y Shuhua Fang. Combined Random Forest and NSGA-II for Optimal Design of Permanent Magnet Arc Motor. *IEEE Journal of Emerging and Selected Topics in Power Electronics*, 10(2):1800–1812, 2022. doi: 10.1109/JESTPE.2021.3049242.
- [91] Jaak Panksepp. *Affective neuroscience: The foundations of human and animal emotions*. Oxford university press, 2004.
- [92] Danni Peng-Li, Patricia Alves Da Mota, Camile Maria Costa Correa, Raymond C K Chan, Derek Victor Byrne, y Qian Janice Wang. "Sound"Decisions: The Combined Role of Ambient Noise and Cognitive Regulation on the Neurophysiology of Food Cravings. *Frontiers in neuroscience*, 16:827021, 2022. ISSN 1662-4548 (Print). doi: 10.3389/fnins.2022.827021.

- [93] Panagiotis C Petrantonakis y Leontios J Hadjileontiadis. Emotion Recognition From EEG Using Higher Order Crossings. *IEEE Transactions on Information Technology in Biomedicine*, 14(2):186–197, 2010. doi: 10.1109/TITB.2009.2034649.
- [94] E. J.Solteiro Pires, P. B. de Moura Oliveira, y J. A.Tenreiro Machado. Manipulator trajectory planning using a MOEA. *Applied Soft Computing*, 7(3):659–667, jun 2007. ISSN 1568-4946. doi: 10.1016/J.ASOC.2005.06.009.
- [95] Diah Anggraeni Pitaloka, Ajeng Wulandari, T Basaruddin, y Dewi Yanti Lilia-na. Enhancing CNN with Preprocessing Stage in Automatic Emotion Recognition. *Procedia Computer Science*, 116:523–529, 2017. ISSN 1877-0509. doi: <https://doi.org/10.1016/j.procs.2017.10.038>. URL <https://www.sciencedirect.com/science/article/pii/S1877050917320860>.
- [96] Tasha Poppa y Antoine Bechara. The somatic marker hypothesis: revisiting the role of the ‘body-loop’ in decision-making. *Current Opinion in Behavioral Sciences*, 19: 61–66, 2018. ISSN 2352-1546. doi: <https://doi.org/10.1016/j.cobeha.2017.10.007>.
- [97] Jonathan Posner, James A. Russell, y Bradley S. Peterson. The circumplex model of affect: An integrative approach to affective neuroscience, cognitive development, and psychopathology. *Development and Psychopathology*, pages 715–734, 2005. ISSN 0954-5794. doi: 10.1017/S0954579405050340.
- [98] Nalini Pusarla, Anurag Singh, y Shrivishal Tripathi. Learning DenseNet features from EEG based spectrograms for subject independent emotion recognition. *Biomedical Signal Processing and Control*, 74:103485, 2022. ISSN 1746-8094. doi: <https://doi.org/10.1016/j.bspc.2022.103485>. URL <https://www.sciencedirect.com/science/article/pii/S1746809422000076>.
- [99] Hongchun Qu y Li Yin. An Automatic Clustering Algorithm Using NSGA-II with Gene Rearrangement. In *2020 IEEE 10th International Conference on Intelligent Systems (IS)*, pages 503–509, 2020. doi: 10.1109/IS48319.2020.9199842.

- [100] N A Rahmat y I Musirin. Differential Evolution Ant Colony Optimization (DEACO) technique in solving Economic Load Dispatch problem. In *2012 IEEE International Power Engineering and Optimization Conference Melaka, Malaysia*, pages 263–268, 2012. doi: 10.1109/PEOCO.2012.6230872.
- [101] Dolly Reney y Neeta Tripathi. An Efficient Method to Face and Emotion Detection. In *2015 Fifth International Conference on Communication Systems and Network Technologies*, pages 493–497, 2015. doi: 10.1109/CSNT.2015.155.
- [102] Astrid M Rosenthal-von der Pütten y Nicole C Krämer. How design characteristics of robots determine evaluation and uncanny valley related responses. *Computers in Human Behavior*, 36:422–439, 2014. ISSN 0747-5632. doi: <https://doi.org/10.1016/j.chb.2014.03.066>. URL <https://www.sciencedirect.com/science/article/pii/S0747563214001940>.
- [103] Vandana Roy. Effective eeg artifact removal from eeg signal. In Vahid Asadpour y Selcan Karakuş, editors, *Biosignal Processing*, chapter 10. IntechOpen, Rijeka, 2022. doi: 10.5772/intechopen.102698. URL <https://doi.org/10.5772/intechopen.102698>.
- [104] James A. Russell. A circumplex model of affect. *Journal of Personality and Social Psychology*, 39(6):1161–1178, 1980. ISSN 00223514. doi: 10.1037/h0077714.
- [105] Tomasz M Rutkowski y Danilo P Mandic. Modelling the Communication Atmosphere: A Human Centered Multimedia Approach to Evaluate Communicative Situations. In Thomas S Huang, Anton Nijholt, Maja Pantic, y Alex Pentland, editors, *Artificial Intelligence for Human Computing*, pages 155–169, Berlin, Heidelberg, 2007. Springer Berlin Heidelberg. ISBN 978-3-540-72348-6.
- [106] Simanto Saha, Khondaker A Mamun, Khawza Ahmed, Raqibul Mostafa, Ganesh R Naik, Sam Darvishi, Ahsan H Khandoker, y Mathias Baumert. Progress in Brain Computer Interface: Challenges and Opportunities. *Frontiers in Systems Neuroscience*, 15, 2021. ISSN 1662-5137. doi: 10.3389/fnsys.2021.578875. URL <https://www.frontiersin.org/articles/10.3389/fnsys.2021.578875>.

- [107] S.k. Sana, G Sruthi, D Suresh, G Rajesh, y G V Subba Reddy. Facial emotion recognition based music system using convolutional neural networks. *Materials Today: Proceedings*, 2022. ISSN 2214-7853. doi: <https://doi.org/10.1016/j.matpr.2022.03.131>. URL <https://www.sciencedirect.com/science/article/pii/S2214785322014547>.
- [108] Ketan Sarvakar, R Senkamalavalli, S Raghavendra, J Santosh Kumar, R Manjunath, y Sushma Jaiswal. Facial emotion recognition using convolutional neural networks. *Materials Today: Proceedings*, 2021. ISSN 2214-7853. doi: <https://doi.org/10.1016/j.matpr.2021.07.297>. URL <https://www.sciencedirect.com/science/article/pii/S2214785321051567>.
- [109] Robin Tibor Schirrmeister, Jost Tobias Springenberg, Lukas Dominique Josef Fiederer, Martin Glasstetter, Katharina Eggenberger, Michael Tangermann, Frank Hutter, Wolfram Burgard, y Tonio Ball. Deep learning with convolutional neural networks for EEG decoding and visualization. *Human Brain Mapping*, 38(11):5391–5420, nov 2017. ISSN 10970193. doi: 10.1002/hbm.23730.
- [110] Harold Schlosberg. Three dimensions of emotion., 1954.
- [111] B. Schuller, G. Rigoll, y M. Lang. Hidden markov model-based speech emotion recognition. In *2003 IEEE International Conference on Acoustics, Speech, and Signal Processing, 2003. Proceedings. (ICASSP '03).*, volume 2, pages II–1, 2003. doi: 10.1109/ICASSP.2003.1202279.
- [112] Yajing Si, Fali Li, Keyi Duan, Qin Tao, Cunbo Li, Zehong Cao, Yangsong Zhang, Bharat Biswal, Peiyang Li, Dezhong Yao, y Peng Xu. Predicting individual decision-making responses based on single-trial EEG. *NeuroImage*, 206:116333, 2020. ISSN 1053-8119. doi: <https://doi.org/10.1016/j.neuroimage.2019.116333>. URL <https://www.sciencedirect.com/science/article/pii/S1053811919309243>.
- [113] Yi Sima, Jizheng Yi, Aibin Chen, y Ze Jin. Automatic expression recognition of face image sequence based on key-frame generation and differential emotion feature. *Applied Soft Computing*, 113:108029, 2021. ISSN 1568-4946. doi:

- <https://doi.org/10.1016/j.asoc.2021.108029>. URL <https://www.sciencedirect.com/science/article/pii/S1568494621009510>.
- [114] R. Sprengelmeyer, M. Rausch, U. T. Eysel, y H. Przuntek. Neural structures associated with recognition of facial expressions of basic emotions. *Proceedings of the Royal Society B: Biological Sciences*, 265:1927, 10 1998. ISSN 14712970. doi: 10.1098/RSPB.1998.0522.
- [115] Tina M Sutton, Andrew M Herbert, y Dailyn Q Clark. Valence, arousal, and dominance ratings for facial stimuli. *Quarterly Journal of Experimental Psychology*, 72(8):2046–2055, 2019. doi: 10.1177/1747021819829012. URL <https://doi.org/10.1177/1747021819829012>.
- [116] Edgar P Torres P, Edgar A Torres, Myriam Hernández-Álvarez, y Sang Guun Yoo. EEG-Based BCI Emotion Recognition: A Survey. *Sensors (Basel, Switzerland)*, 20(18), sep 2020. ISSN 1424-8220 (Electronic). doi: 10.3390/s20185083.
- [117] Christoph Tremmel, Jacobo Fernandez-Vargas, Dimitris Stamos, Caterina Cinel, Massimiliano Pontil, Luca Citi, y Riccardo Poli. A meta-learning BCI for estimating decision confidence. *Journal of Neural Engineering*, 19(4):046009, aug 2022. ISSN 1741-2560. doi: 10.1088/1741-2552/ac7ba8. URL <https://iopscience.iop.org/article/10.1088/1741-2552/ac7ba8>.
- [118] Peilin Wang, Kuangkuang Ye, Xuerui Hao, y Jike Wang. Combining multi-objective genetic algorithm and neural network dynamically for the complex optimization problems in physics. *Scientific Reports*, 13(1):880, 2023. ISSN 2045-2322. doi: 10.1038/s41598-023-27478-7.
- [119] Rui Wang, Hisao Ishibuchi, Yan Zhang, Xiaokun Zheng, y Tao Zhang. On the effect of localized pbi method in moea/d for multi-objective optimization. In *2016 IEEE Symposium Series on Computational Intelligence (SSCI)*, pages 1–8, 2016. doi: 10.1109/SSCI.2016.7850222.

- [120] Xiao-Wei Wang, Dan Nie, y Bao-Liang Lu. EEG-Based Emotion Recognition Using Frequency Domain Features and Support Vector Machines. In Bao-Liang Lu, Liqing Zhang, y James Kwok, editors, *Neural Information Processing*, pages 734–743, Berlin, Heidelberg, 2011. Springer Berlin Heidelberg. ISBN 978-3-642-24955-6.
- [121] Christine D Wilson-Mendenhall, Lisa Feldman Barrett, y Lawrence W Barsalou. Neural evidence that human emotions share core affective properties. *Psychological Science*, 24:947–956, 2013. doi: 10.1177/0956797612464242. PMID: 23603916.
- [122] Grzegorz M Wojcik, Jolanta Masiak, Andrzej Kawiak, Lukasz Kwasniewicz, Piotr Schneider, Filip Postepski, y Anna Gajos-Balinska. Analysis of Decision-Making Process Using Methods of Quantitative Electroencephalography and Machine Learning Tools. *Frontiers in Neuroinformatics*, 13, 2019. ISSN 1662-5196. doi: 10.3389/fninf.2019.00073. URL <https://www.frontiersin.org/articles/10.3389/fninf.2019.00073>.
- [123] D H Wolpert y W G Macready. No free lunch theorems for optimization. *IEEE Transactions on Evolutionary Computation*, 1(1):67–82, 1997. doi: 10.1109/4235.585893.
- [124] Lei Wu, Xiaodong Huang, Junguo Cui, Chao Liu, y Wensheng Xiao. Modified adaptive ant colony optimization algorithm and its application for solving path planning of mobile robot. *Expert Systems with Applications*, 215:119410, 2023. ISSN 0957-4174. doi: <https://doi.org/10.1016/j.eswa.2022.119410>.
- [125] Wilhelm Max Wundt y Charles Hubbard Judd. *Outlines of psychology*. W. Engelmann, 1902.
- [126] Bin Xin, Lu Chen, Jie Chen, Hisao Ishibuchi, Kaoru Hirota, y Bo Liu. Interactive multiobjective optimization: A review of the state-of-the-art. *IEEE Access*, 6:41256–41279, 2018. doi: 10.1109/ACCESS.2018.2856832.
- [127] Arti Yadav, Samta Jain Goyal, R S Jadon, y Rajeev Goyal. Energy Efficient Load Balancing Algorithm through MetaHeuristics Approaches for Cloud-Computing-

- Environment. In *2022 International Mobile and Embedded Technology Conference (MECON)*, pages 130–135, 2022. doi: 10.1109/MECON53876.2022.9752207.
- [128] Fei Yan, Abdullah M Ilyasu, y Kaoru Hirota. Emotion space modelling for social robots. *Engineering Applications of Artificial Intelligence*, 100:104178, 2021. ISSN 0952-1976. doi: <https://doi.org/10.1016/j.engappai.2021.104178>. URL <https://www.sciencedirect.com/science/article/pii/S0952197621000257>.
- [129] Heekyung Yang, Jongdae Han, y Kyungha Min. A multi-column CNN model for emotion recognition from EEG signals. *Sensors (Switzerland)*, 19(21):1–12, 2019. ISSN 14248220. doi: 10.3390/s19214736.
- [130] Abbas Yazdinejad, Ali Dehghantanha, Reza M Parizi, y Gregory Epiphaniou. An optimized fuzzy deep learning model for data classification based on NSGA-II. *Neurocomputing*, 522:116–128, 2023. ISSN 0925-2312. doi: <https://doi.org/10.1016/j.neucom.2022.12.027>. URL <https://www.sciencedirect.com/science/article/pii/S0925231222015260>.
- [131] Junfeng Zhang, Lining Xing, Zhen Tan, Hongsen Wang, y Kesheng Wang. Multi-head attention fusion networks for multi-modal speech emotion recognition. *Computers Industrial Engineering*, 168:108078, 2022. ISSN 0360-8352. doi: <https://doi.org/10.1016/j.cie.2022.108078>. URL <https://www.sciencedirect.com/science/article/pii/S0360835222001486>.
- [132] Qingfu Zhang y Hui Li. MOEA/D: A Multiobjective Evolutionary Algorithm Based on Decomposition. *IEEE Transactions on Evolutionary Computation*, 11(6):712–731, 2007. doi: 10.1109/TEVC.2007.892759.
- [133] Wei-Long Zheng, Jia-Yi Zhu, y Bao-Liang Lu. Identifying Stable Patterns over Time for Emotion Recognition from EEG. *IEEE Transactions on Affective Computing*, 10(3):417–429, 2019. doi: 10.1109/TAFFC.2017.2712143.
- [134] Yun Zhou, Tao Xu, Yanping Cai, Xiaojun Wu, y Bei Dong. Monitoring Cognitive Workload in Online Videos Learning Through an EEG-Based Brain-Computer

- Interface. In Panayiotis Zaphiris y Andri Ioannou, editors, *Learning and Collaboration Technologies. Novel Learning Ecosystems*, pages 64–73, Cham, 2017. Springer International Publishing. ISBN 978-3-319-58509-3.
- [135] Zhi Hua Zhou y Ji Feng. Deep forest. *National Science Review*, 6(1):74–86, 2019. ISSN 2053714X. doi: 10.1093/nsr/nwy108.
- [136] Yuxuan Zhu, Kenji Ozawa, y Wanzeng Kong. EEGNetT: EEG-based neural network for emotion recognition in real-world applications. In *2021 IEEE 3rd Global Conference on Life Sciences and Technologies (LifeTech)*, pages 376–378, 2021. doi: 10.1109/LifeTech52111.2021.9391941.
- [137] Melanie J Zimmer-Gembeck, Jessica L Kerin, Haley J Webb, Alex A Gardner, Shawna Mastro Campbell, Kellie Swan, y Susan G Timmer. Improved Perceptions of Emotion Regulation and Reflective Functioning in Parents: Two Additional Positive Outcomes of Parent-Child Interaction Therapy. *Behavior Therapy*, 50(2):340–352, 2019. ISSN 0005-7894. doi: <https://doi.org/10.1016/j.beth.2018.07.002>.
- [138] Eckart Zitzler y Lothar Thiele. Multiobjective evolutionary algorithms: A comparative case study and the strength Pareto approach. *IEEE Transactions on Evolutionary Computation*, 3(4):257–271, nov 1999. ISSN 1089778X. doi: 10.1109/4235.797969.