



Universidad de Pamplona
Programa de Ingeniería Mecatrónica
Facultad de Arquitectura e Ingenierías
Departamento de Mecánica, Mecatrónica
e Industrial

**Algoritmo selector de música basado en el estado
de ánimo del usuario utilizando una interfaz
cerebro-computador**

Autor:

MELISSA CAROLINA PATERNINA JIMÉNEZ

PAMPLONA, NORTE DE SANTANDER
DICIEMBRE DE 2019



Universidad de Pamplona
Programa de Ingeniería Mecatrónica
Facultad de Arquitectura e Ingenierías
Departamento de Mecánica, Mecatrónica
e Industrial

**Algoritmo selector de música basado en el estado
de ánimo del usuario utilizando una interfaz
cerebro-computador**

Autor:

MELISSA CAROLINA PATERNINA JIMÉNEZ

Director: PhD. César Augusto Peña Cortes

Docente de la Universidad de Pamplona

Codirector: MSc. Carlos Eduardo Cañedo Figueroa

Docente de la Universidad Autónoma de Chihuahua

**TRABAJO DE GRADO PARA OPTAR POR EL TÍTULO DE
INGENIERO EN MECATRÓNICA**

PAMPLONA, NORTE DE SANTANDER

DICIEMBRE DE 2019

“A mis padres, a mi novio y a los incontables vasos de Coca-Cola que me han apoyado a lo largo de este camino y continúan haciéndolo al día de hoy”

— Melissa Paternina Jiménez

Agradecimientos

A cada uno de mis docentes que hicieron parte de mi formación a nivel profesional, en especial a mi director y co-director de tesis, el profesor César Peña y Carlos Cañedo, por su paciencia ante mi inconsistencia, por su dedicación, apoyo y ayuda a lo largo del desarrollo de ese proyecto.

A mi familia por darme su confianza, apoyo y motivación a lo largo de esta etapa de mi vida.

A todos mis amigos y compañeros con los que compartí este camino, en especial a mi novio por que siempre creyó en mí y estuvo presente a lo largo de este proyecto.

Índice

Agradecimientos	IV
Índice	V
Índice de tablas	VIII
Índice de figuras	IX
Resumen	XI
Abstract	XII
Introducción	13
1 Problema y justificación	15
2 Delimitación	18
2.1. Objetivos	18
2.1.1. Objetivo General	18
2.1.2. Objetivos Específicos	18
2.2. Acotaciones	18
3 Marco referencial	20
3.1. Estado del arte	20
4 Marco teórico	25
4.1. Música	25
4.2. Género musical	25
4.3. Estado de ánimo	26
4.4. Influencia de la música en el estado de ánimo	26

4.5. Medidas de la actividad cerebral	27
4.6. Electroencefalografía (EEG)	28
4.7. Señales electroencefalográficas (EEG)	29
4.8. Sistema internacional 10 – 20	31
4.9. Interfaz cerebro-computador (BCI)	32
4.10. Tipos de montajes para BCI	34
4.10.1. Montaje bipolar	34
4.10.2. Montaje monopolar	34
4.11. EMOTIV	35
4.12. Selector de música	38
4.13. Teoría de control	38
4.14. Algoritmo	39
4.15. Inteligencia artificial	39
4.16. Aprendizaje automático (<i>Machine learning</i>)	40
4.16.1. Aprendizaje supervisado	41
4.16.2. Aprendizaje no supervisado	41
5 Metodología	42
5.1. Tipo de investigación	42
5.2. Descripción general	42
5.2.1. Selección de BCI	44
5.2.2. <i>MyEmotiv App</i>	46
5.2.3. Datos	48
5.2.3.1. Fuentes primarias	49
5.2.3.2. Fuentes secundarias	49
5.3. Descripción de los experimentos	49
5.3.1. Participantes	49
5.3.2. Lista de canciones	49
5.3.3. Bases de datos	50
5.3.3.1. Base de datos No. 1	53
5.3.3.2. Base de datos No. 2	54
5.4. Determinación del estado de ánimo	55
5.5. Algoritmo selector de música	57

5.5.1. Algoritmo selector de música basado en el método heurístico (Algoritmo básico)	57
5.5.2. Algoritmo basado en Máquinas de Soporte Vectorial, SVM	60
6 Resultados	67
6.1. Implementación del algoritmo basado en el modelo matemático (Algoritmo básico)	68
6.2. Implementación del algoritmo basado en Máquinas de Soporte Vectorial (Algoritmo SVM)	72
7 Conclusiones	76
Bibliografía	77
A Formato de consentimiento	84
B Formato de las pruebas	85
C Base de datos No. 1	86
D Base de datos No. 2	91
E Algoritmo selector de música basado en método heurístico (Algoritmo básico)	96
F Tablas de pruebas de validación	101
F.0.1. Algoritmo básico	101
F.0.2. Algoritmo SVM	102
G Datos para el algoritmo SVM	103

Índice de tablas

4.1. Clasificación de las señales EEG.	30
5.1. Especificaciones técnicas del <i>ASUS ZenFone 3 ZE552KL</i> . Fuente: [44]	44
5.2. Variaciones totales de la varianza para cada estado de ánimo.	57
6.1. Parámetros de dispersión de la Tabla de Anexo F.0.1.	70
6.2. Parámetros de análisis de la Tabla del Anexo F.0.2.	74

Índice de figuras

- 4.1. Ejemplo de dispositivo para el registro de la actividad cerebral. *Fuente: NeuroSky, “MindWave Mobile 2” (2015). Disponible en: <https://store.neurosky.com/>* 28
- 4.2. Capas que cubren el cerebro. *Fuente: Adaptada de B. Blaus, “Medical gallery of Blausen Medical” (2014). Disponible en: <https://n9.cl/wbva0>* 29
- 4.3. Sistema internacional 10 – 20. *Fuente: Angélica Reyes Rueda, “Interfaz cerebro computador mediante la clasificación de señales electroencefalográficas” (2013).* 31
- 4.4. Vista frontal y de perfil de la relación de distancia del Sistema internacional 10 – 20. *Fuente: J. J. Jasper, “The ten-twenty electrode system of international federation in electroencephalography and clinical neurophysiology” (1958).* 32
- 4.5. Estructura de una Interfaz Cerebro-Computador. *Fuente: Angélica Reyes Rueda, “Interfaz cerebro computador mediante la clasificación de señales electroencefalográficas” (2013).* 33
- 4.6. Montaje bipolar. *Fuente: Angélica Reyes Rueda, “Interfaz cerebro computador mediante la clasificación de señales electroencefalográficas” (2013).* 34
- 4.7. Montaje monopolar. *Fuente: Angélica Reyes Rueda, “Interfaz cerebro computador mediante la clasificación de señales electroencefalográficas” (2013).* 35
- 4.8. Sensores de la diadema Emotiv INSIGH en el sistema internacional 10 – 20. *Fuente: Emotiv, “Emotiv INSIGHT”. Disponible en: <https://www.emotiv.com/insight/>* 36
- 4.9. Diadema Emotiv INSIGHT. *Fuente: Emotiv, “Emotiv INSIGHT”. Disponible en: <https://www.emotiv.com/insight/>* 36

4.10. Sensores de la diadema Emotiv EPOC+ en el sistema internacional 10 – 20. <i>Fuente: Emotiv, “Emotiv EPOC+”. Disponible en: https://www.emotiv.com/epoc/</i>	37
4.11. Diadema Emotiv EPOC+. <i>Fuente: Emotiv, “Emotiv EPOC+”. Disponible en: https://www.emotiv.com/epoc/</i>	38
5.1. Características principales de <i>MyEmotiv App</i> . <i>Fuente: Elaboración propia.</i>	47
5.2. Estados de ánimos/emotivos dados por <i>MyEmotiv App</i> . <i>Fuente: Adaptado de EMOTIV Company, “MyEmotiv” (2012). Disponible en: https://www.emotiv.com/myemotiv/</i>	48
5.3. Preparación del dispositivo Emotiv Insight. <i>Fuente: Elaboración propia.</i>	51
5.4. Verificación de la calidad de contacto (electrodos - cuero cabelludo). <i>Fuente: Elaboración propia en base a MyEmotiv App.</i>	52
5.5. Esquema general de los experimentos para la obtención de la base de datos. <i>Fuente: Elaboración propia.</i>	53
5.6. Diagrama de flujo del algoritmo selector de música basado en el método heurístico (Algoritmo básico). <i>Fuente: Elaboración propia.</i>	59
5.7. SVM Multiclase (<i>one against the rest</i>). <i>Fuente: Cristian Olivares, “Diseño y construcción de una interfaz cerebro computadora para el control de una silla de ruedas como ayuda a personas con discapacidad motriz” (2017).</i>	62
5.8. Comportamiento de gamma. <i>Fuente: Elaboración propia.</i>	64
6.1. Esquema general del sistema implementado. <i>Fuente: Elaboración propia.</i>	67
6.2. Lista de música (<i>playlist</i>) arrojada por el Algoritmo básico. <i>Fuente: Elaboración propia.</i>	68
6.3. Gráficas del comportamiento del compromiso en tres pruebas diferentes. <i>Fuente: Elaboración propia.</i>	69
6.4. Interfaz gráfica del algoritmo básico. <i>Fuente: Elaboración propia.</i>	71
6.5. Interfaz gráfica del algoritmo básico para 20 canciones. <i>Fuente: Elaboración propia.</i>	71
6.6. Resultados del algoritmo SVM. <i>Fuente: Elaboración propia.</i>	72

- 6.7. Diagrama de flujo del experimento para el algoritmo selector de música basado en SVM (Algoritmo SVM). *Fuente: Elaboración propia.* 73
- 6.8. Gráfica del comportamiento del compromiso en las pruebas realizadas con el Algoritmo SVM. *Fuente: Elaboración propia.* 75
- 6.9. Interfaz gráfica del algoritmo SVM. *Fuente: Elaboración propia.* 75

Resumen

En el presente proyecto de investigación se proponen dos estrategias para la elaboración de un algoritmo selector de música basado en el estado de ánimo del usuario por medio de señales electroencefalográficas (EEG). Estas señales son adquiridas con ayuda de una Interfaz Cerebro-Computador (BCI) denominada EMOTIV Insign, que posterior a su recopilación son procesadas y cuantificadas presentándose como un promedio de señales ponderadas a través de seis métricas de estados de ánimo. Como resultado de la realización de experimentos preliminares, detallados en la sección 5.3., se determinó como objeto de estudio la métrica de compromiso (*engagement*), la cual presentó la mejor respuesta ante diferentes géneros musicales, con base a esto se realizaron dos tipos de algoritmos selectores de música que tuvieron como objetivo el aumento y/o estabilidad de este parámetro; el primero basado en un método heurístico del cual se obtuvo una lista de canciones o *playlist* la cual aumentaba la métrica compromiso a un nivel significativo (51/100 con una desviación estándar de 4) que se mantenía de manera constante a lo largo de la duración de ésta. El segundo algoritmo consistió en una Máquina de Soporte Vectorial (SVM), la cual ofrecía la predicción de una canción específica basada en el estado actual y estado anterior de los promedios ponderados de la métrica “compromiso”, como respuesta se obtuvo una señal con una tendencia incremental de manera general con excepción de dos géneros que obtuvieron respuestas menores a las esperadas por el sistema.

Palabras clave: señales electroencefalográficas (EEG), música, EMOTIV, estado de ánimo, Interfaz Cerebro-Computador (BCI), algoritmo, selector de música, Máquina de Soporte Vectorial (SVM).

Abstract

In this research project two strategies are proposed for the elaboration of a music selection algorithm based on the user's mood by means of (EEG) electroencephalographic signals. These signals are acquired with the help of a Brain-Computer Interface (BCI) called EMOTIV Insign, which after their collection are processed and quantified, presenting as an average of signals weighted through six mood metrics. As a result of conducting preliminary experiments, detailed in section 5.3., The engagement metric was determined, which presented the best response to different musical genres, based on this performed two types of music selection algorithms that aimed to increase and/or stability of this parameter; the first one based on a heuristic method from which a list of songs or *playlist* was obtained which increased the metric commitment to a significant level (51/100 with a standard deviation of 4) that was constantly maintained at throughout its duration. The second algorithm consisted of a Vector Support Machine (SVM), which offered the prediction of a specific song based on the current state and previous state of the weighted averages of the "engagement" metric, in response a signal was obtained with an incremental tendency in a general way with the exception of two genders that obtained lower responses to those expected by the system.

Keywords: (EEG) electroencephalographic signals, music, Emotiv, Brain-Computer Interface (BCI), algorithm, music selector, Vector Support Machine (SVM).

Introducción

La música siempre ha sido parte fundamental y crucial en el desarrollo integral de la humanidad [1], su contribución como herramienta comunicativa e integradora así como su capacidad para generar identidad individual y colectiva se haya en su capacidad de influir y modificar comportamientos y emociones [2], esta capacidad de influir en el estado del ánimo general hace parte de los tantos efectos culturales y sociales que configuran a la música como una forma de transmisión emocional universal.

La universalidad en la comunicación de sentimientos viene dada por la misma estructura musical, que guarda en ella patrones que exaltan o reflejan emociones presentes en la concepción de cada pieza, los cuales pretenden de una manera u otra establecer una comunicación cercana y amena cuya finalidad sea la de establecer lazos emocionales entre el compositor y sus oyentes [3].

Las emociones hacen parte de la mente humana y juegan un papel importante en muchos aspectos de nuestra vida diaria, ya sea para la resolución de problemas, la toma de decisiones y la manera de percibir el entorno e interactuar con otros seres humanos, por tanto el reconocimiento de estas emociones durante la ejecución de diferentes actividades puede ofrecer una mayor comprensión y mejor desempeño de los sistemas cerebro-computadoras a la hora de ofrecer soluciones que se adapten a las distintas situaciones cotidianas que se puedan presentar [4].

El uso de la inteligencia artificial se ha venido introduciendo poco a poco en aplicaciones de uso cotidiano del hombre como lo son las plataformas de *streaming*, las redes sociales y los grandes sitios web de compras en línea, así como también un elemento indispensable para la creación de nuevas tecnologías y dispositivos para usos médicos, esto ha permitido comprender la necesidad e impor-

tancia de las emociones de los usuarios a la hora de utilizar tales herramientas al proporcionar información para fortalecer la toma de decisiones y la interacción de los sistemas hombre-máquina [4].

Los sistemas de adquisición de señales EEG llamados interfaces cerebro-computador (BCI) fueron en un principio desarrollados como instrumentos para fines médicos, siendo utilizado por personas con discapacidad física para que pudieran controlar sus extremidades a través de las ondas cerebrales, sin embargo el alcance de estos sistemas abarca una amplia gama de posibilidades que incluye la identificación de emociones, estados emotivos y expresiones faciales dado la aplicabilidad del reconocimiento de estos patrones, no obstante la gran cantidad de electrodos utilizados en el cuero cabelludo y la complejidad para la autoaplicación limita el alcance de estos sistemas.

Hoy en día se pretende disminuir los inconvenientes antes mencionados reduciendo la cantidad de canales y electrodos utilizados sin alterar significativamente la calidad de las señales obtenidas, por lo cual en la última década se ha popularizado de manera comercial diademas BCI para la adquisición de estas señales con el menor número de electrodos posible [5].

Bajo esta premisa, en este proyecto de investigación se realiza el diseño de un algoritmo seleccionador de música para cambiar el estado de ánimo de un usuario, basándose en señales electroencefalográficas adquiridas por medio de la diadema EMOTIV INSIGHT y haciendo uso de *machine learning*.

Problema y justificación

Con el acelerado ritmo de vida del mundo moderno, el estrés se ha convertido en uno de los síndromes más frecuentes en la sociedad como consecuencia de la presión debido a la alta competitividad y producción económica de un mundo globalizado neurótico y cambiante, amenazando la salud de uno de cada cinco trabajadores en el mundo [6]. De acuerdo a un estudio realizado por la Organización Mundial de la Salud (OMS), México es el país con el mayor porcentaje de estrés relacionado con el trabajo, debido a que de los 75000 infartos registrados al año, el 25% son provocados por el estrés laboral. Además, según los datos de la OMS, el 75% de los trabajadores mexicanos padecen de este síndrome, seguido de China con el 73% y Estados Unidos con el 59% [7]. Por su parte, en Colombia, en los resultados de la Primera Encuesta Nacional sobre Condiciones de Trabajo y Salud del Sistema General de Riesgos Profesionales de 2007, casi un 25% de los hombres y un poco más del 28% de las mujeres manifestaron sentir estrés laboral [8].

La música puede desempeñar un papel importante como herramienta terapéutica, a través de ésta, el ritmo cardíaco puede lograr valores normales (de 60 a 80 latidos por minuto) y disminuir la presión arterial, además se puede mejorar la concentración, normalizar la tensión muscular y la respiración, aliviar el dolor, mejorar el manejo del estrés, la depresión y la ansiedad [9]. Se ha documentado la utilidad de la música como medicina puesto que, en algunas personas puede ser empleada como estrategia terapéutica en procesos de recuperación física y mental [10]. Según un estudio del Centro de Investigación de las Artes y de la Calidad de Vida en la Universidad de Temple en Filadelfia escuchar música podría beneficiar a pacientes que sufren de estrés y ansiedad asociados con la enfermedad coronaria y su tratamiento; concretamente se encontró que la práctica

de escuchar música puede reducir la presión sanguínea, la frecuencia cardíaca y los niveles de ansiedad en personas con problemas del corazón [11].

El comportamiento de una persona, por causa de la música, puede ser influenciado por los sonidos fuertes, súbitos y cambios rápidos de patrones temporales musicales, así como también por algún episodio del pasado, puesto que la emoción inducida por la música podría ayudarle a evocar memorias personales de algún evento específico en su vida, pudiendo ser recuerdos con fuertes conexiones emocionales [12], por lo que se puede intuir que existe una relación entre estado de ánimo y el género musical que se escucha.

Asimismo, la música repercute en las relaciones sociales de las personas, debido a que puede crear sensaciones de unidad y de pertenencia a grupos o conglomerados, es así como se utiliza la música como herramienta de inducción en grupos sociales para conservar la calma o inducir un estado de alerta, ejemplos como los grupos religiosos y sus cánticos para relajar, y el ejército y sus bandas de guerra para motivar y exaltar el estado de alerta, evidencian el uso de este instrumento para moldear la actitud de los individuos hacia un estado de ánimo idóneo tanto para el momento como para la finalidad del grupo social [13].

En este sentido, se puede expresar que la música se ha constituido en un canal para liberar las presiones sociales, ya sea por el poder terapéutico de ésta sobre el estado de ánimo o su influencia sobre el comportamiento social. De esta manera, la música podría tener un efecto de reforzamiento para ciertas conductas dependiendo del estado de ánimo inicial y del género o ritmo de música que se escuche.

En virtud de lo señalado anteriormente, la realización de este proyecto de investigación tiene como finalidad el desarrollo de un selector de música que por medio de una estrategia de control escoja una canción de un conjunto de canciones pre-seleccionadas para la realización de las pruebas que sea adecuada para estimular un estado de ánimo determinado y generar una respuesta deseada del individuo mejorando su desempeño y bienestar emocional, partiendo

de que éste se encuentra en un estado no deseado.

Delimitación

2.1. Objetivos

2.1.1. Objetivo General

Desarrollar un algoritmo selector de música basado en el estado de ánimo del usuario utilizando una interfaz cerebro-computador de la empresa EMOTIV.

2.1.2. Objetivos Específicos

- Verificar que la interfaz cerebro-computador desarrollada por la empresa EMOTIV permita detectar cambios de estados anímicos bajo la influencia de diferentes géneros musicales.
- Clasificar un conjunto de canciones de acuerdo a los cambios emotivos que se produzcan en un usuario.
- Elaborar un algoritmo de control que permita seleccionar los tipos de música de acuerdo al estado de ánimo y/o pueda provocar cambios positivos en el usuario.
- Validar el funcionamiento del algoritmo realizando pruebas en un usuario.

2.2. Acotaciones

- Para la adquisición de las señales EEG originadas por el cerebro se planea usar una de las diademas desarrollada por la empresa EMOTIV, ya sea su versión EMOTIV EPOC+ o EMOTIV INSIGHT las cuales poseen sensores

utilizados para detectar expresiones faciales, movimiento, sentimientos y pensamientos.

- El algoritmo presentado se verificará a través de un usuario controlando un estado de ánimo específico.
- El tamaño y tipo del conjunto de canciones a seleccionar serán preestablecidas.
- El algoritmo de control hace referencia al algoritmo selector de música.
- El algoritmo de control está proyectado para producir cambios positivos en el usuario partiendo de un estado anímico negativo.

Marco referencial

3.1. Estado del arte

A continuación, se contemplan algunas de las investigaciones más relevantes de la bibliografía disponible sobre el tema de estudio, que permite recopilar diversos puntos de vista conceptuales y metodológicos con el propósito de garantizar un proceso analítico, comparativo y constructivo en este proyecto.

Qi Zhang y Norikazu Yoshimine. “*A study on human brain activity during music listening using EEG measurement*” (2015). En este trabajo se llevaron a cabo diferentes pruebas para medir la actividad cerebral de un grupo de personas por medio de la captura de señales EEG mientras los individuos escuchaban música agradable y sonido desagradable. Luego de adquiridas y procesadas cada una por separado, se calcularon sus ERP (*Event-related potentials*). Las diferencias de ERP entre la música agradable y el ruido fueron observadas y comparadas en varias sesiones. Los resultados obtenidos no fueron los deseados debido a la limitación del sistema de captura de señales EEG que utilizaron, por lo cual hacen énfasis en que harán un plan para mejorar la configuración del experimento y el análisis de datos más avanzados [14].

F. Mulla, Eya Eya, E. Ibrahim, A. Alhaddad, R. Qahwaji y R. Adb-Alhameed. “*Neurological assessment of music therapy on the brain using Emotiv Epoc*” (2017). Esta acta de conferencia abarca un estudio transversal realizado para comprender cómo la musicoterapia puede afectar o influir en pacientes que sufren pérdida de memoria. Para esto, se llevó a cabo un estudio comparativo entre cuestionarios musicales y no musicales para hallar patrones e indicios de cómo la música puede contribuir al recuerdo de la memoria. En este experimento se usó

una diadema EMOTIV EPOC y un software llamado Test Bench con el que se obtuvieron y registraron los datos de las señales EEG del cerebro percibidas por la diadema. Aunque la hipótesis no se demostró por completo, hubo seis pacientes estudiados que obtuvieron un promedio alto de alrededor de 12.4 haciendo uso de la música en comparación con los que no se les puso música, por lo que las funciones cognitivas de dichos sujetos estaban en funcionamiento [15].

Folgieri Raffaella y Zichella Matteo. “*A BCI-based application in music: conscious playing of single notes by brainwaves*” (2012). Este artículo propone el desarrollo de una interfaz cerebro-computador de bajo costo y en tiempo real, la cual tendrá como fin potenciar el uso de la música en aplicaciones relacionadas con HCI (interfaz hombre-máquina), tales como videojuegos, realidad virtual y entretenimiento digital. Este trabajo se centra en la posibilidad de hacer que los usuarios puedan tocar conscientemente una nota musical específica, a través de dispositivos BCI de bajo costo que leen las ondas EEG de los sujetos bajo un paradigma de estímulos de audio, gestuales y visuales. Los resultados obtenidos en este proyecto permitieron redefinir la herramienta reduciendo el tiempo de entrenamiento y permitiendo que cualquier usuario pudiera reproducir cualquier nota [16].

Qi Zhang y Norikazu Yoshimine. “*An EEG study on music listening with ICA approach*” (2017). En este documento, se ejecutaron diversos experimentos para medir la actividad cerebral cuando un usuario escucha música clásica, utilizando un sistema portátil EEG (electroencefalograma). Los datos arrojados por este sistema se analizaron haciendo uso del enfoque ICA (Análisis de Componentes Independientes). En los resultados de los experimentos se observó cierta actividad en la banda de frecuencia alpha occipital, theta media frontal y beta frontal, lo que sugiere que el usuario se encontraba en un estado de relajación mientras escuchaban música clásica con los ojos cerrados [17].

Hossan Alamgir y Mahmud Chowdhury A. “*Real time EEG based automatic brainwave regulation by music*” (2016). En esta memoria de congreso, los autores proponen un nuevo enfoque para controlar de manera autónoma el estado

de ánimo de personas con parálisis, discapacidad sensorial o con enfermedades mentales, para ello desarrollaron un algoritmo en el software MATLAB para llevar a cabo el análisis de las señales eléctricas del cerebro correspondientes a diversos estados de ánimo del usuario, las cuales fueron obtenidas mediante un sistema de adquisición de datos de EEG a tiempo real. El programa se encargó de realizar toda la parte de pre-procesamiento y procesamiento de las señales EEG para convertirlas en comandos con los que se seleccionaban y reproducían canciones apropiadas de acuerdo al estado de ánimo de la persona. Estas canciones, seleccionadas en función a las señales de la persona objetivo, ejercieron a su vez como una retroalimentación para ajustar el estado de ánimo del sujeto al deseado [18].

Yanguas Leyes Javier. *“Influencia de la música en el rendimiento deportivo”* (2006). Este artículo habla sobre la influencia de ciertos tipos de música en el rendimiento deportivo, siendo una revisión de muchos trabajos relacionados con el tema. Se evidencia que el papel “ergogénico” de la música se halla si a ésta se evoca una asociación extramusical, como es el caso de la banda sonora de la película Rocky ante un ejercicio intenso o la música de *Carros de fuego*, de Vangelis, a un evento olímpico. Comentan que existe una predisposición innata e inconsciente del hombre a sincronizar el ritmo de la música con el ritmo de ejercicio que se está realizando. El autor finaliza explicando que hay una menor sensación de esfuerzo percibido en ejercicios submáximos y es el efecto más notorio en individuos con un estilo de vida sedentario, de tal forma que la música ejerce en ellos un papel euforizante y retardador de la fatiga [19].

Hassan Hasmindia, Haji Murat Zunairah, Ross Valerie y Buniyamin Norlida. *“A preliminary study on the effects of music on human brainwaves”* (2012). Esta memoria de congreso presenta un estudio de la reacción de un usuario cuando se expone a música de violín en vivo. Para esto se utilizó una máquina de EEG y una computadora donde se observaba y registraba las actividades de las señales cerebrales del usuario en tres etapas: antes, durante y después de escuchar el violín, todo esto con el fin de comparar la reacción de las diferentes señales EEG durante estas tres etapas. En base al experimento, se concluyó que existe

la posibilidad de que en un momento durante un concierto en vivo, la frecuencia y potencia del violín atrajeran la señal eléctrica del cerebro y la alinearan para inducir un efecto positivo equilibran las ondas cerebrales izquierda y derecha, lo que sugiere que escuchar tocar un violín en vivo ayuda a mejorar el equilibrio entre ambos hemisferios cerebrales [20].

Gómez Gallego M. y Gómez García J. *“Musicoterapia en la enfermedad de Alzheimer: efectos cognitivos, psicológicos y conductuales”* (2015). Con esta publicación se pretendía conocer el perfil de mejoría clínica que experimentan los pacientes que padecen de Alzheimer con la intervención de musicoterapia, para ello se aplicó un tratamiento con musicoterapia durante seis semanas a 42 pacientes en estado leve-moderado. Se estudiaron cómo iban evolucionando con las puntuaciones obtenidas de un mini examen del estado mental, tomando en cuenta el inventario de síntomas neuropsiquiátricos, la escala hospitalaria de ansiedad y depresión, y el índice de Barthel. Se obtuvo una mejoría significativa de la memoria, depresión, orientación y ansiedad en los pacientes leves y moderados; de ansiedad en pacientes leves; mejoría de los delirios, alucinaciones, agitación, irritabilidad y trastornos del lenguaje en los pacientes moderados. Todo esto fue apreciable a partir de la cuarta semana [21].

Fernández Isabel. *“Disminución del gasto energético en prematuros a través de la música de Mozart”* (2014). Este trabajo es el resultado de un ensayo clínico controlado prospectivo aleatorizado sobre el efecto de la música de Mozart sobre el gasto energético de neonatos, fue realizado en la unidad de cuidados intensivos neonatal del hospital de Maternidad Lis, Tel Aviv Medical Centro (Tel Aviv, Israel), en donde seleccionó una muestra de 18 neonatos con estabilidad clínica y térmica sin complicaciones y con una edad gestacional corregida de entre 30 y 37 semanas, 5 de ellos fueron expuestos a música de Mozart treinta minutos durante dos días consecutivos, los restantes fueron tomados como grupo de control, los resultados sobre este estudio arrojaron que el gasto energético de los neonatos expuesto a la música se redujo de un 10 a un 13% frente al grupo de control y que este efecto se inicia luego de diez minutos de exposición, las mediciones sobre el gasto energético se realizaron cada diez minutos y bajo condiciones controladas

de sonoridad [22].

López Natividad, Ruiz de Casas Andrés, Morales Macarena, Moreno David y Camacho Francisco. *“Aspectos socioculturales de la influencia de la música sobre el personal sanitario que trabaja en el quirófano”* (2015). El artículo mencionado consiste en la elaboración de un análisis estadístico de los resultados de una encuesta específica realizada en tres hospitales de la provincia de Sevilla durante el año 2014: el Hospital Universitario Virgen Macarena, el Hospital Universitario Virgen del Rocío y el Hospital Comarcal de la Merced a 67 profesionales de la salud, dirigido fundamentalmente a cirujanos, anestesiistas y enfermeros, con preguntas acerca de los distintos aspectos que puede suponer escuchar música mientras realizan los procedimientos quirúrgicos, con los resultados se pudo inferir que la fue música tiene un efecto positivo sobre el personal sanitario que trabaja en quirófano, al igual que sobre el paciente, la mayoría de los participantes pensaron que la comunicación no se ve afectada, de hecho, se sienten más tranquilos cuando trabajan escuchando música, especialmente los médicos residentes [23].

Marco teórico

Dado que la mira central de este proyecto de investigación estará puesta en los efectos de la música en el estado de ánimo de las personas y en crear un seleccionador que escoja la música adecuada para la persona estudiada, se hace indispensable aclarar algunos conceptos o fundamentos teóricos esenciales para comprender a cabalidad las consecuencias de este trabajo y vislumbrar el impacto de las propuestas aquí planteadas.

4.1. Música

La música es una manifestación artística, un medio para expresar ideas, emociones y vivencias de una sociedad o cultura, es el arte y la ciencia de combinar los sonidos y silencios ajustados a la medida del tiempo bajo una coordinación de notas musicales que, según su composición como la armonía, ritmo y melodía, tiene como fin agrandar al oído de quien la escucha, sin perder su característica de influir en los sentimientos del oyente. La música no solo se produce por medio del uso de instrumentos musicales, sino que también puede ser generada por las cuerdas vocales, y de acuerdo a la intención con que se cante se puede experimentar sensaciones y estados de paz, tranquilidad, alegría y felicidad, aunque también de rabia y odio, entre muchos otros [24].

4.2. Género musical

Fabian Holt en su libro *Genre in popular music* (2007), formula una definición de género bastante amplia, entendido como una práctica cultural, de carácter fluido y pragmático, asociado a un “trabajo cultural” complejo, que no solo se identifica con la música sino también con rituales, territorios, tradiciones y gru-

pos de personas. Para Holt, los géneros pueden ser entendidos como una cultura con características o funciones sistemáticas, aunque no constituyen sistemas en un sentido estricto ni entidades delimitadas y mecánicas. Los elementos individuales que los conforman adquieren significado a través de sus conexiones y su organización en contextos simbólicos con ciertos procesos de regulación y mecanismos generales [25].

De esta manera, es posible afirmar que la determinación de un género es (aunque no sea explícita ni inmediata), básicamente, resultado de la escucha por parte de un oyente.

4.3. Estado de ánimo

El estado de ánimo es la respuesta o disposición emocional, agradable o desagradable, que acompaña a una idea o situación y se mantiene en un determinado tiempo. Es un estado, una manera de permanecer o estar, que expresa matices afectivos y con mayor duración, más global. Los estados de ánimos pueden surgir por una experiencia emocional densa, siendo esta una emoción intensa y repetida [26].

4.4. Influencia de la música en el estado de ánimo

Hace 2500 años, Pitágoras usaba ciertas escalas y acordes para lograr el equilibrio mental, recetaba a sus pupilos determinadas melodías para armonizar estados de ánimo negativos o aliviar las preocupaciones, el desánimo o la ira. Aristóteles descubrió que las melodías y los ritmos de la flauta fortalecían el cuerpo, la mente, y el espíritu, y Platón sostenía que la música cumplía para el alma lo que la gimnasia y el ejercicio para el cuerpo. Mientras que Descartes consideraba que el sonido de la música tenía como objetivo el deleite y la provocación de diferentes pasiones. Consecuentemente, se puede afirmar que desde tiempos de antaño la música ha venido mostrando los beneficios que ofrece sobre la salud

mental y su gran capacidad de influir en la vida de un individuo mejorando su estado de ánimo [10].

La música ha intervenido considerablemente en el desarrollo y aprendizaje del ser humano, dándose el caso de que desde la infancia, en la mayoría de instituciones educativas, se imparte la clase de artística cuyo fin es favorecer el desenvolvimiento de la expresión personal de los niños para aumentar su creatividad así como para desinhibirles, fortalecer su autoestima y fomentar la expresión afectiva. El contacto con la música desde temprana edad hace que los infantes intensificando sus capacidades de concentración, abstracción, escucha, expresión y potencializando su memoria, permitiendo una integración al mundo interno, sensorial, afectivo y cognitivo [10].

Igualmente, la música actualmente es utilizada como terapia para tratar ciertos trastornos o mejorar la calidad de vida de pacientes, a esta actividad se le llama musicoterapia. Entonces, la musicoterapia vendría siendo el uso de la música en la consecución de objetivos terapéuticos, siendo estos la restauración, el mantenimiento y la garantía de la salud tanto física como mental provocando cambios positivos en el comportamiento del paciente y promoviendo la comunicación, las relaciones, el aprendizaje, el movimiento, la expresión y la organización para satisfacer las necesidades físicas, emocionales, mentales, sociales y cognitivas del paciente [27].

4.5. Medidas de la actividad cerebral

Las herramientas modernas de la neurociencia cognitiva: el electroencefalograma (EEG) de alta resolución, el magnetoencefalograma (MEG), las imágenes de resonancia magnética funcional y anatómica (fMRI, RM) y la estimulación magnética transcraneal (TMS), junto con las aportaciones de la neuropsicología al estudio de la música y el cerebro, son muy relevantes en la construcción sistemática de la base neural y correlaciona los procesos musicales [28].

En la bibliografía se encuentran numerosos estudios que han utilizado los registros de actividad cerebral para examinar las respuestas emocionales ante la música. La Figura 4.1 muestra un dispositivo de bajo coste para el registro de la actividad cerebral.



Figura 4.1: Ejemplo de dispositivo para el registro de la actividad cerebral. Fuente: NeuroSky, “MindWave Mobile 2” (2015). Disponible en: <https://store.neurosky.com/>

4.6. Electroencefalografía (EEG)

La electroencefalografía es una técnica de exploración funcional del sistema nervioso central (SNC), no invasiva, por medio la cual se obtiene el registro y evaluación de los potenciales eléctricos generados por la actividad eléctrica cerebral en tiempo real [29], obtenidos mediante electrodos situados sobre la superficie del cuero cabelludo o corteza cerebral (espacio subdural, Figura 4.2). Dichos registros poseen formas bastante complejas que varían mucho con la localización de los electrodos y entre individuos. Esto se debe al gran número de interconexiones que presentan las neuronas y por la estructura no uniforme del encéfalo [30].

El origen de la señal eléctrica se encuentra en las células piramidales de la corteza cerebral. Cada una de estas neuronas constituye un diminuto dipolo eléctrico, cuya polaridad depende de que el impulso a la célula sea inhibitorio o excitatorio. Para poder recoger y registrar una señal de la actividad eléctrica en cada

región cerebral a través de la superficie craneal se colocan electrodos que captan la diferencia de potencial entre ellos. La EEG realiza el estudio y análisis de los campos eléctricos cerebrales (topografía, polaridad y su variación espacial temporal) mediante la amplificación de la diferencia de potencial entre los electrodos receptores de la señal [29].

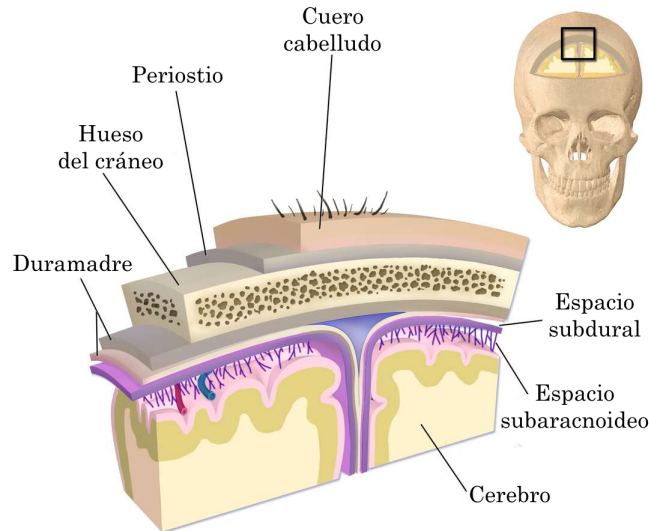


Figura 4.2: Capas que cubren el cerebro. Fuente: Adaptada de B. Blaus, “Medical gallery of Blausen Medical” (2014). Disponible en: <https://n9.cl/wbva0>

4.7. Señales electroencefalográficas (EEG)

Las señales EEG se caracterizan por poseer amplitudes desde los 10 mV (registros sobre la corteza cerebral) a 100 μV (registros sobre el cuero cabelludo), igualmente tienen forma irregular y son aperiódicas, y se encuentran concentradas en el espectro de 0 a 100 Hz. Debido a la irregularidad de estas se han clasificado en ritmos u ondas dependiendo de la banda de frecuencia en la que se encuentre (Tabla 4.1) [30].

Tabla 4.1: Clasificación de las señales EEG.

Tipos	Frecuencia (Hz)	Ubicación	Características
Alfa (α)	8 a 13	Occipital y frontal	Amplitud $>20 \mu V$. Asociadas a relajación y actividad mental leve.
Beta (β)	12 a 30	Parietal y frontal	Amplitud entre 5 a $30 \mu V$. Asociadas a estados de concentración, alerta y resolución de problemas. En casos de extrema concentración puede alcanzar hasta los 50 Hz.
Gamma (γ)	>30	—	Asociadas a procesos de comunicación y realización de actividades mentales complejas.
Delta (δ)	0.5 a 4	—	Amplitud variable. Asociadas a sueño profundo y estados de meditación.
Tetha (θ)	4 a 7	Parietal y temporal	Amplitud $>20 \mu V$. Asociadas a estrés y frustración.
Mu (μ)	8 a 13	Zona sensorio-motora (unión lóbulo parietal y frontal)	Manifiestan atenuación durante el movimiento o intento de movimiento de extremidades. Son ondas espontaneas.

4.8. Sistema internacional 10 – 20

El sistema más utilizado a día de hoy para el posicionamiento de electrodos superficiales es el llamado Sistema internacional 10 – 20 (Figura 4.3). Este método fue desarrollado para garantizar un estándar y repetitividad de tal forma que los estudios realizados a un individuo puedan ser comparados en el transcurso del tiempo, de igual manera permite comparar los resultados entre diferentes sujetos [30].




Figura 4.3: Sistema internacional 10 – 20. Fuente: Angélica Reyes Rueda, “Interfaz cerebro computador mediante la clasificación de señales electroencefalográficas” (2013).

Este sistema se basa en la relación entre la ubicación de un electrodo y el área subyacente de la corteza cerebral. Los números 10 y 20 se refieren al hecho de que las distancias entre los electrodos adyacentes representan el 10% o el 20% de la distancia total frontal-posterior o derecha-izquierda del cráneo (Figura 4.4). Se utilizan cuatro puntos de referencia anatómicos para el posicionamiento esencial

de los electrodos: primero, el *nación*, que es el punto entre la frente y la nariz; segundo, el *inión*, que es el punto más bajo del cráneo desde la parte posterior de la cabeza y normalmente está indicado por una protuberancia prominente; y por último los puntos pre-auriculares anteriores al oído [31].

Cada punto de contacto posee una letra para identificar el lóbulo y un número para identificar la ubicación del hemisferio. Las letras son: F (lóbulo Frontal), T (lóbulo Temporal), P (lóbulo Parietal), O (lóbulo Occipital) y C (usada para identificar la línea horizontal-central). Los números pares indican los electrodos ubicados en el hemisferio derecho y los impares los electrodos ubicados en el hemisferio izquierdo. Los subíndices *z* indican la línea vertical-central de electrodos [31].




Figura 4.4: Vista frontal y de perfil de la relación de distancia del Sistema internacional 10 – 20. Fuente: J. J. Jasper, “The ten-twenty electrode system of international federation in electroencephalography and clinical neurophysiology” (1958).

4.9. Interfaz cerebro-computador (BCI)

Una interfaz cerebro-computador (*BCI, Brain-Computer Interface*) es un sistema que permite la comunicación directa entre un individuo a partir de la actividad eléctrica cerebral (sin necesidad de actividad motora) y un computador. Este sistema detecta la presencia de patrones específicos en la actividad cerebral

y por medio de algoritmos de clasificación traduce estos patrones en comandos de control [30].

La BCI se compone principalmente por dos partes: la adquisición de señales y el procesamiento de la señal que, a su vez, se encuentra dividida en extracción de características y algoritmos de traducción (clasificación de características) y aplicación de los comandos de control [32–34] (ver Figura 4.5).

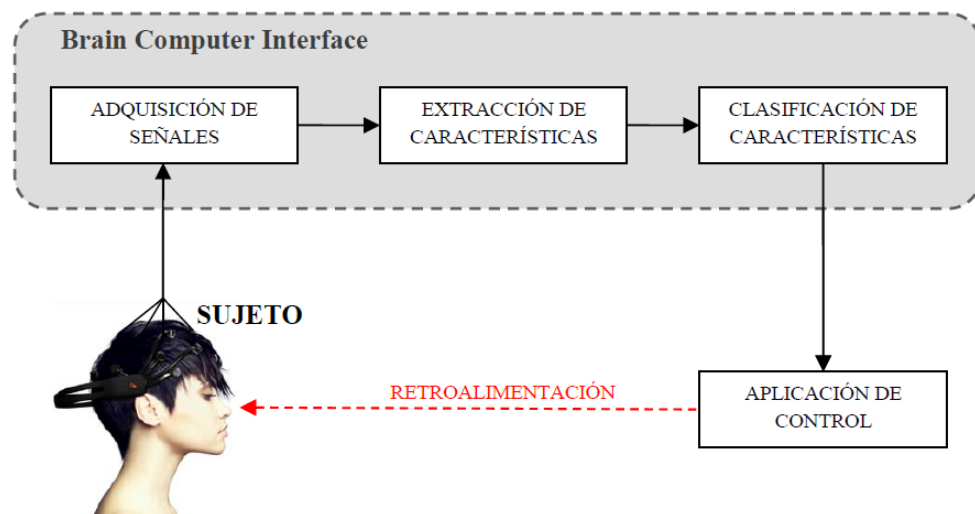


Figura 4.5: Estructura de una Interfaz Cerebro-Computador. Fuente: Angélica Reyes Rueda, “Interfaz cerebro computador mediante la clasificación de señales electroencefalográficas” (2013).

Una interfaz BCI puede ser *dependiente* o *independiente* según el paradigma usado para la toma de decisiones. Se define como **dependiente** cuando las características usadas son producto de la respuesta normal del cerebro. Mientras que las **independientes** no dependen del comportamiento de la respuesta cerebral producida en un momento determinado, sino que requieren de una respuesta voluntaria por parte del individuo [35].

4.10. Tipos de montajes para BCI

Para capturar las ondas EEG, múltiples electrodos se ubican en el cuero cabelludo, sin embargo para realizar este registro es necesario disponer de mínimo dos terminales (electrodos). Existen dos tipos de montajes para realizar este registro, el monopolar y el bipolar.

4.10.1. Montaje bipolar

En el canal de amplificación, una pareja de electrodos registran la actividad cerebral y la diferencia de tensión entre ellos es lo que va al amplificador para su registro (Figura 4.6) [36].




Figura 4.6: Montaje bipolar. *Fuente: Angélica Reyes Rueda, “Interfaz cerebro computador mediante la clasificación de señales electroencefalográficas” (2013).*

4.10.2. Montaje monopolar

Los electrodos exploradores ocupan la posición 1 del amplificador, mientras que la posición 2 está ocupada por un electrodo relativamente inactivo o que sea común para todos los canales (electrodo de referencia). De esta forma se determina la diferencia de tensión entre el electrodo activo y el electrodo de referencia (Figura 4.7) [36].




Figura 4.7: Montaje monopolar. *Fuente: Angélica Reyes Rueda, “Interfaz cerebro computador mediante la clasificación de señales electroencefalográficas” (2013).*

4.11. EMOTIV

EMOTIV es una compañía de neuroingeniería y bioinformática que avanza en la búsqueda de la comprensión del cerebro humano utilizando electroencefalografía (EEG). Fundada en el año 2011 por los empresarios Tan Le (CEO) y el Dr. Geoff Mackellar (CTO), con sede en San Francisco, EE. UU., e instalaciones en Sydney, Hanoi y Ho Chi Minh. Esta compañía desarrolló una revolucionaria interfaz cerebro-computador (BCI) para el consumo popular. La compañía desarrolló dos diademas BCI [37]:

- **EMOTIV INSIGHT**, que cuenta con una electrónica avanzada optimizada para producir señales limpias y robustas en cualquier momento y lugar, posee 5 sensores de polímeros semisecos para la captura de ondas EEG ubicados en las posiciones AF3, AF4, T7, T8 y Pz del sistema internacional 10 – 20 y otros 2 sensores usados como referencia CMS/DRL que se posicionan en el mastoideo izquierdo (Figura 4.8).




Figura 4.8: Sensores de la diadema Emotiv INSIGHT en el sistema internacional 10 – 20. Fuente: Emotiv, “Emotiv INSIGHT”. Disponible en: <https://www.emotiv.com/insight/>

Los sensores de esta diadema operan a una frecuencia de muestreo de 128 sps con un ancho de banda de 0.5 a 43 Hz. El tipo de registro utilizado corresponde a un registro monopolar y se conecta de forma inalámbrica a computadoras o móviles. En la Figura 4.9 se muestra la diadema Emotiv INSIGHT.



Figura 4.9: Diadema Emotiv INSIGHT. Fuente: Emotiv, “Emotiv INSIGHT”. Disponible en: <https://www.emotiv.com/insight/>

- **EMOTIV EPOC+**, que consta de 16 electrodos de contacto con almohadillas (la cual debe ser humedecida con una solución salina para garantizar una buena conducción) y enchapados en oro. Estos electrodos se encuentran sujetos a dos brazos de plástico que garantizan la correcta ubicación según el sistema internacional 10 – 20. Cabe destacar que 14 de los 16 sensores capturan las señales EEG y se encuentran ubicados en las posiciones AF3, F7, F3, FC5, T7, P7, O1, O2, P8, T8, FC6, F4, F8 y AF4 del sistema internacional 10 – 20, los 2 restantes son usados como referencia CMS/DRL y se posicionan en P3 y P4 (Figura 4.10). La implementación de estos electrodos de referencia indica que el tipo de registro utilizado por esta diadema corresponde a un registro monopolar.




Figura 4.10: Sensores de la diadema Emotiv EPOC+ en el sistema internacional 10 – 20. Fuente: Emotiv, “Emotiv EPOC+”. Disponible en: <https://www.emotiv.com/epoc/>

Los electrodos operan a una frecuencia de muestreo de 128 sps o puede configurarse por el usuario a 256 sps y, además, poseen un ancho de banda de 0.16 a 43 Hz. La diadema se conecta de manera inalámbrica por medio de un transmisor bluetooth. En la Figura 4.11 se muestra la diadema Emotiv

EPOC+.



Figura 4.11: Diadema Emotiv EPOC+. Fuente: Emotiv, “Emotiv EPOC+”.
Disponibile en: <https://www.emotiv.com/epoc/>

4.12. Selector de música

La figura selector nació en las radios americanas décadas atrás, como el empleado encargado de seleccionar la música en las estaciones de radio, armando listas de reproducción (*playlist*) y sin manipular con efectos la música, a diferencia del *disk jockey* (DJ), quien acelera o disminuye la velocidad de un *track*, o que incluye efectos al momento de estar realizando un set. Se podría llamar selector a aquella persona que escoge la música sin mezclarla, por lo general esta persona debe estar familiarizada con los temas y debe haber cierta sincronía que genere armonía a la hora de reproducir la música [38].

4.13. Teoría de control

Se basa en el análisis en el dominio temporal de los sistemas de ecuaciones diferenciales. La teoría de control clásica, que se fundamenta en los métodos de respuesta en frecuencia y del lugar de las raíces, conduce a sistemas estables que satisfacen un conjunto más o menos arbitrario de requisitos de comportamiento. Estos sistemas son aceptables pero no son óptimos desde ningún punto de vista. Por otro lado, la teoría de control moderna, basada en el análisis en el dominio del tiempo y la síntesis a partir de variables de estados, se ha elaborado para manejar la complejidad de las plantas modernas y los requisitos de precisión, peso y coste en aplicaciones industriales. Sin embargo, la estabilidad del sistema

depende del error entre el sistema real y su modelo, lo que significa que cuando el controlador diseñado se aplica al sistema real, éste puede no ser estable [39].

4.14. Algoritmo

La palabra algoritmo se deriva de la traducción al latín de la palabra *Alkhô-warîzmi*, nombre de un matemático y astrónomo árabe que escribió un tratado sobre manipulación de números y ecuaciones en el siglo IX. Un algoritmo es un método para resolver un problema mediante una serie de pasos precisos (indica el orden de realización en cada paso), definidos (si se sigue dos veces, obtiene el mismo resultado cada vez) y finitos (tiene fin; un número determinado de pasos), el cual debe producir un resultado en un tiempo estipulado y se pueden expresar por fórmulas, diagramas de flujo o N-S y pseudocódigos. O bien, un algoritmo sería una forma de describir la solución de un problema planteado en forma adecuada y de manera genérica [40].

4.15. Inteligencia artificial

A día de hoy no se ha podido llegar un consenso entre los científicos e ingenieros para definir de manera exacta y concisa lo que es la Inteligencia Artificial. El primer intento de definir la Inteligencia Artificial lo hizo el matemático Alan Turing, considerado el padre de la computación. Este científico inglés es conocido por su máquina de Turing: una máquina conceptual que utilizó para formalizar los conceptos del modelo computacional que se sigue usando hoy día. Él demostró que con las operaciones básicas que podía desarrollar su máquina podía codificarse cualquier algoritmo, y que toda máquina capaz de computar tendría las mismas operaciones básicas que su máquina o un superconjunto de estas [41].

En 1950, publicó un artículo titulado *Computing machinery and intelligence* donde argumentaba que si una máquina puede actuar como un humano, entonces sería propio decir que es inteligente. En este artículo proponía una prueba, llamada Test de Turing, que permitiría afirmar si una máquina es o no inteli-

gente. Para llegar a esa conclusión, un ser humano se comunicaría por medio de un terminal informático con una entidad que se hallaría en una habitación contigua. Esta entidad podría ser un humano o una máquina inteligente. Si tras una conversación la persona no es capaz de distinguir si en la habitación contigua hay un humano o una máquina, entonces, en caso de ser una máquina, se puede considerar inteligente [41].

El Test de Turing exige una capacidad de razonamiento automático. Los humanos son capaces de llegar a conclusiones a partir de una serie de premisas. Un primer intento de conseguir que las máquinas razonaran fue llevado a la práctica a través de los llamados sistemas expertos. Estos sistemas tratan de llegar a conclusiones lógicas a partir de hechos o premisas introducidas a priori en el sistema. Actualmente, se utilizan otras máquinas más versátiles como las redes probabilísticas, que permiten hacer predicciones y llegar a conclusiones incluso cuando hay cierto grado de incertidumbre en las premisas [41].

Frente a la propuesta de Turing de que una máquina será inteligente si actúa como un humano, otros investigadores y autores proponen nuevos paradigmas. Uno de ellos afirma que si una máquina piensa como un humano, entonces será inteligente. Otros, sin embargo, defienden la idea de que una máquina será inteligente si piensa o actúa de forma racional [41].

Se puede considerar, entonces, a la Inteligencia Artificial como un conjunto de técnicas, algoritmos y herramientas que sean capaces de resolver problemas para los que, a priori, sea necesario cierto grado de inteligencia, en el sentido de que son problemas que suponen un desafío incluso para el cerebro humano [41].

4.16. Aprendizaje automático (*Machine learning*)

El *machine learning* es un subcampo de las ciencias de la computación y una rama de la Inteligencia Artificial cuyo objetivo es desarrollar técnicas que per-

mitan a los computadores aprender, es decir, generalizar comportamientos y conocimientos a partir de una información suministrada en forma de ejemplos [42].

El *machine learning* puede verse como un intento de automatizar algunas partes del método científico por medio de métodos matemáticos. Algunos sistemas intentan eliminar toda necesidad de intuición o conocimiento experto de los procesos de análisis de datos, aunque sigue siendo necesario siempre un diseñador del sistema que especifique la forma de representación de datos y los métodos de manipulación. Otros sistemas tratan de establecer un marco de colaboración entre el experto y la computadora [42].

El aprendizaje automático se suele clasificar en dos categorías [42]:

4.16.1. Aprendizaje supervisado

Los datos en estos casos disponen de atributos adicionales que son los que se intentan predecir. Dentro de esta categoría destacan los algoritmos de *clasificación*, en los que las muestras están etiquetadas como pertenecientes a dos o más clases, y se quiere aprender a predecir la clase de datos sin etiquetar.

4.16.2. Aprendizaje no supervisado

Los datos de entrenamiento consisten en un conjunto de vectores de entrada sin ningún valor o etiqueta correspondiente. El objetivo en estos casos puede ser descubrir grupos de ejemplos similares dentro de los datos (*clustering*).

Metodología

5.1. Tipo de investigación

En palabras de Dankhe, “*los estudios descriptivos buscan especificar las propiedades importantes de personas, grupos, comunidades o cualquier otro fenómeno que sea sometido a análisis. Miden o evalúan diversos aspectos, dimensiones o componentes del fenómeno o fenómenos a investigar*” [43].

La presente investigación es un estudio de caso de carácter descriptivo, debido a que se observa y describe el comportamiento del sujeto teniendo en cuenta una serie de indicadores de estado de ánimo según se cambia el género musical escuchado, además es una investigación correlacional donde se medirá el grado de relación existente entre las diferentes variables (estado de ánimo – género musical) con un enfoque cuantitativo, puesto que, se analizan los datos de la prueba obtenidos de manera numérica y estadística.

5.2. Descripción general

El proyecto llevado a cabo para la determinación de un algoritmo capaz de seleccionar la música con base al estado anímico, se dividirá en las siguientes fases:

- **FASE I:** Centrada en la recolección de una base datos por medio de pruebas realizadas a un sujeto. En esta fase se realizan diez pruebas para percibir el estado emotivo ante música variada en un orden específico, y otras diez en un orden aleatorio, tomando los datos de cada prueba día a día.

- **FASE II:** Consiste en el análisis estadístico de los datos obtenidos para la determinación del estado de ánimo con el cual se va a trabajar. El estado seleccionado es aquel que posee un comportamiento con menor varianza entre todas las pruebas realizadas.
- **FASE III:** Determinación de un modelo matemático con el que se construye una *playlist* formada por el número de canciones que desea el usuario de tal forma que estas canciones aumenten el estado de ánimo seleccionado en la Fase II o lo mantenga estable en el tiempo. El modelo está implementado en forma de algoritmo en el software MATLAB y se realiza la respectiva interfaz gráfica para una mejor visualización para el usuario.
- **FASE IV:** Se utiliza las técnicas de inteligencia artificial basadas en el *machine learning*, en particular, las Máquinas de Soporte Vectorial (SVM) puesto que con este algoritmo se podría dar respuesta a las necesidades de la investigación de una manera más robusta y con una predicción de la siguiente canción en el momento. En adición a lo anterior, se realiza la respectiva interfaz gráfica.
- **FASE V:** Ejecución de pruebas sobre el sujeto para validar el correcto funcionamiento de los algoritmos selectores propuestos y comparación entre los resultados de ambos algoritmos.

Por otra parte, cabe destacar que todos los fragmentos musicales que se ofrece al oyente se han reproducido por medio de unos audífonos marca HP H2310 con una intensidad de 3.22 dBm, y además, el dispositivo *smartphone* (ASUS ZenFone 3 ZE552KL) usado como reproductor de música fue el mismo utilizado como receptor de las señales captadas por la diadema seleccionada a través de la aplicación *MyEmotiv App* (para más detalles de la aplicación dirigirse a la Sección 5.2.2). Las características de software y hardware del *smartphone* se detallan en la Tabla 5.1 [44].

Tabla 5.1: Especificaciones técnicas del *ASUS ZenFone 3 ZE552KL*. Fuente: [44]

Especificaciones técnicas del Asus Zenfone 3 ZE552KL		
Red	Tecnología	GSM/HSPA/LTE
Cuerpo	Dimensiones	152.6 x 77.4 x 7.7 mm
	Peso	155 g
Pantalla	Tamaño	5.5 pulgadas
	Resolución	1080 x 1920 pixeles (16:9)
Plataforma	SO	Android 8.0 (Oreo)
	CPU	Octa-core 2.0 GHz Cortex-A53
	GPU	Adreno 506
	RAM	4 GB
	Almacenamiento	64 GB
Sonido	3.5mm jack	24-bit/192kHz audio
Comunicaciones	WLAN	Wi-Fi 802.11 a/b/g/n/ac, Wi-Fi Direct, hotspot
	Bluetooth	4.2, A2DP, EDR, LE
Batería	Li-Ion 3000 mAh	

5.2.1. Selección de BCI

El grupo de investigación de *Automatización y Control* de la Universidad de Pamplona cuenta con dos diademas o *headset* BCI disponibles para su utilización en aplicaciones con fines investigativos y/o académicos. Estas fueron facilitadas gracias al Semillero de Investigación de Automatización, Robótica y Control –SIARC– para la realización del presente proyecto de investigación y de las cuales se tienen la siguientes anotaciones:

1. **EMOTIV EPOC+**: Esta diadema al contar con 16 electrodos de contacto con almohadillas y enchapados en oro requería un exhaustivo cuidado y manejo cada vez que era utilizada, puesto que se debían insertar los electrodos uno a uno junto con su respectiva almohadilla a los compartimientos correspondientes en los brazos de la diadema, además de humedecerlos con una solución salina para obtener una buena conducción. Asimismo, al finali-

zar la prueba se debía extraer cada sensor separándolo de su almohadilla y secándolos para luego almacenarlos en su respectivo estuche. Lo anterior se traducía en un aumento significativo del tiempo de ejecución de las pruebas (tardando alrededor de una hora y cuarenta minutos, tomando 40 minutos para la preparación, verificación de la calidad del contacto y calibración de la diadema, y una hora realizando las pruebas, puesto que se presentaban constantemente diversos errores relacionados con la toma de datos), lo cual constituía para el sujeto un gran desgaste anímico que comprometía el resultado del experimento.

Adicionalmente, esta diadema requería un programa para Windows llamado “Emotiv Xavier” instalado en el PC, que a su vez necesitaba ejecutarse con una muy buena conexión a internet para establecer comunicación con un servidor remoto para procesar las señales EEG adquiridas, este servidor en ocasiones fallaba, por tanto era recurrente perder los datos de una prueba, y por consiguiente, se debía realizar una repetición de la misma, incurriendo a prolongar y alterar la secuencia de ejecución del experimento.

A pesar de que en la página web se describe que la aplicación *MyEmotiv* es compatible para ambas diademas (EPOC+ e Insight), lo cierto es que al momento de probarla se encontraron ciertos problemas de compatibilidad que impidieron su conexión, posterior a esto se realizó una revisión dentro de la Play Store de Android y se observaron comentarios de diferentes usuarios indicando la imposibilidad de conectar esta diadema con la aplicación.

2. **EMOTIV INSIGHT:** Esta diadema al poseer cinco sensores de un material de polímero semiseco, permitía de una manera más fácil y rápida, la obtención de una óptima calidad de contacto entre el electrodo y el cuero cabelludo, debido a su facilidad de implementación y la etapa casi nula de preparación de la diadema.

Asimismo, esta diadema confiere la facilidad de comunicarse por medio del

protocolo *bluetooth* a una aplicación creada por la misma compañía a *tablets* o *smartphones* llamada *MyEmotiv*, la cual es compatible únicamente con la diadema Insight y dispositivos Android y iOS.

Con esta diadema se redujo significativamente los tiempos de ejecución de los experimentos con respecto a la Emotiv EPOC+, durando cada prueba aproximadamente 35 minutos, tomando tan solo 4 minutos para la preparación, verificación de la calidad del contacto y calibración de la diadema y 31 minutos para la realización de las pruebas (5 minutos para la evaluación del estado inicial y 2 minutos por cada canción).

Según lo expuesto anteriormente, el dispositivo que mejor se adecua para la realización de las pruebas es la diadema Emotiv Insight. Para la implementación del algoritmo selector de música propuesto se utilizó un móvil *ASUS ZenFone 3 (ZE552KL)* (especificaciones en la Tabla 5.1) que tenía instalado la aplicación *MyEmotiv* para interactuar con la diadema, puesto que era una forma más práctica de captar las señales EEG adquiridas por la Emotiv Insight.

5.2.2. *MyEmotiv App*

La aplicación *MyEmotiv* es libre y no requiere licencias de ningún tipo. También proporciona información relevante con respecto a seis métricas basadas en el estado de ánimo construidas a partir de las señales EEG adquiridas por la diadema, reduciendo de manera significativa el procesamiento e interpretación de las ondas cerebrales por parte del usuario.

Dentro de las características principales de esta aplicación se encuentra la captura de datos del cerebro, la medida de rendimiento, un visualizador 3D y la opción de ver los informes (Figura 5.1) [45].



Figura 5.1: Características principales de *MyEmotiv App*. Fuente: *Elaboración propia*.

Las métricas de rendimiento de EMOTIV se han desarrollado y probado haciendo uso de métodos científicos rigurosos. Para cada métrica, se diseñaron experimentos basados en métodos validos para evocar un rango de respuestas emotivas y se recopilaron los datos de muchos sujetos voluntarios que utilizaban la diadema EMOTIV, así como también sensores para el corazón, la respiración y la conductancia de la piel. Estos datos fueron pasados a través del canal de procesamiento de señales y aprendizaje automático de la compañía, creando de esta manera los modelos matemáticos detrás de cada medida. Muchas de estas métricas se han evaluado de forma independiente en publicaciones revisadas por pares [45].

Las seis métricas o estados de ánimo/emotivos que maneja EMOTIV son las presentadas en la Figura 5.2.



Figura 5.2: Estados de ánimos/emotivos dados por *MyEmotiv App*. Fuente: Adaptado de *EMOTIV Company*, “*MyEmotiv*” (2012). Disponible en: <https://www.emotiv.com/myemotiv/>

MyEmotiv App proporciona además una cuenta *online* en sus servidores para el almacenamiento de datos personales de cada usuario y perfiles que contienen información sobre las lecturas de las señales cerebrales.

Por último, cabe destacar que las características con las que cuenta la aplicación son suficientes para poder desarrollar el algoritmo selector de música propuesto en este proyecto.

5.2.3. Datos

Este proyecto se basa en diferentes componentes bibliográficos y en una base de datos obtenidas experimentalmente, a continuación se mencionan las fuentes:

5.2.3.1. Fuentes primarias

Base de datos propia obtenida a través de la ejecución de pruebas basadas en el formato mostrado en el Anexo B.

5.2.3.2. Fuentes secundarias

- Artículos científicos relacionados con la influencia de la música en las emociones a través del uso de señales EEG.
- Libros de inteligencia artificial, *machine learning*, entre otros temas de interés.
- Trabajos de grados de otras universidades a nivel nacional e internacional relacionadas con el tema a tratar.
- Recursos ofrecidos por plataformas como *Github* o librerías externas ofrecidas por la comunidad científica.
- Asesorías brindadas por personas especializadas en el tema.

5.3. Descripción de los experimentos

5.3.1. Participantes

En los experimentos ha participado voluntariamente un joven de 25 años de edad del programa de Ingeniería Electrónica de la Universidad de Pamplona, a quien se le tomó una prueba cada día por alrededor de 20 días.

Todos los experimentos se han llevado a cabo en los laboratorios del programa de Ingeniería Mecatrónica situados en el edificio Simón Bolívar de la Universidad de Pamplona.

5.3.2. Lista de canciones

Fueron seleccionadas 13 canciones de diferente género cada una con una duración aproximada de 2 minutos, la parte reproducida se trata principalmente

del coro de la canción. Se trató de escoger canciones representativas dentro de cada género. A continuación se presentan las canciones seleccionadas junto al género al que pertenecen:

1. *Braulio el templao* de Mr. Black — **Champeta**.
2. *Can't take my eyes off you* de Frankie Valli and The Four Season — **Jazz**.
3. *Cum on feel the noize* de Quiet Riot — **Hard Rock**.
4. *Entre dos aguas* de Paco de Lucía — **Flamenco**.
5. *I remember* de Damien Rice — **Indie**.
6. *I will survive* de Gloria Gaynor — **Disco**.
7. *Johnny B. Goode* de Chuck Berry — **Rock'n Roll**.
8. *Levels* de Avicii — **Electrónica**.
9. *Negro y azul* de Los Cuates de Sinaloa — **Corrido**.
10. *Nocturne in E-Flat Major (Op. 9 No. 2)* de Frédéric Chopin — **Clásica**.
11. *Roots, rock, reggae* de Bob Marley — **Reggae**.
12. *Sonido bestial* de Ricardo Ray y Bobby Cruz — **Salsa**.
13. *Y si la ves* de Ñejo — **Reggaetón**.

5.3.3. Bases de datos

En primera instancia, en la Figura 5.3 se observa la manera de preparar la diadema para su uso en los experimentos realizados para la obtención de las bases de datos.

En etapas preliminares se consideró un tiempo de adaptación por parte del sujeto del experimento que buscaba reducir el estrés y el estado de alerta frente a las mediciones, sin embargo la presión ejercida de los electrodos de gel semiseco sobre su cráneo generaba un nivel creciente de incomodidad en el tiempo y afectaba la posterior adquisición de datos, por tanto para las pruebas realizadas en el presente proyecto se eliminó esta etapa del experimento.

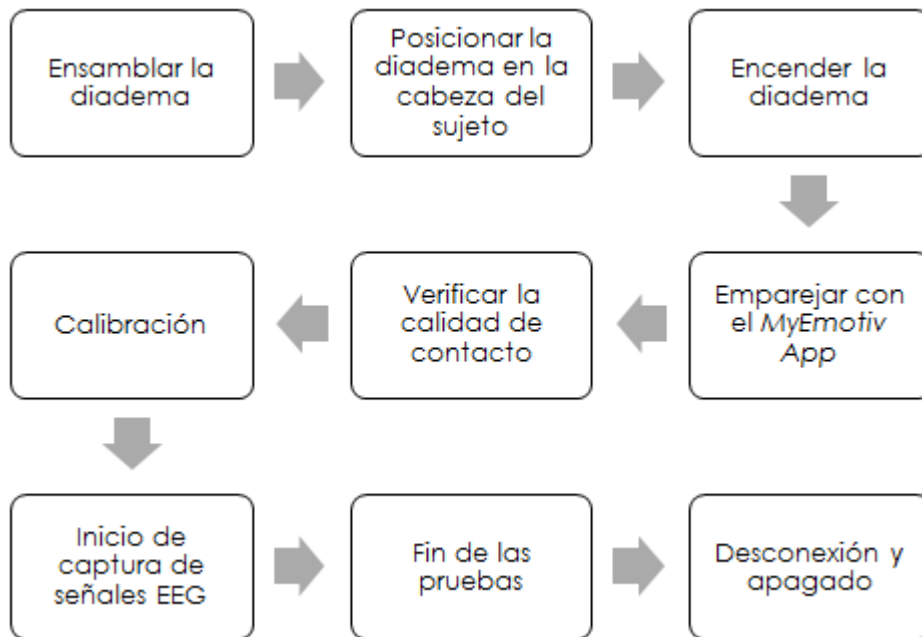


Figura 5.3: Preparación del dispositivo Emotiv Insight. *Fuente: Elaboración propia.*

La parte de ensamblaje se debe realizar tal y como lo indica la guía rápida de Emotiv Insight que viene adjunta al adquirir el dispositivo.

El emparejamiento de la diadema con la aplicación se realiza por vía *bluetooth* por lo cual éste debe estar encendido en el móvil utilizado.

La verificación de la calidad del contacto entre los electrodos y el cuero cabelludo se realiza mediante la aplicación *MyEmotiv*, allí se muestra en la pantalla las posiciones de los cinco electrodos, el color indica la calidad de la señal recibida por el dispositivo EEG (Figura 5.4). Una buena señal se indica con el color verde, una señal regular con amarillo, una mala señal con el color rojo y si no existe contacto, se muestra el electrodo correspondiente sin color.

La calibración de la diadema se realiza con el sujeto primeramente con los ojos abiertos observando una pared blanca alrededor de 15 segundos, y luego, con los ojos cerrados la misma cantidad de tiempo.

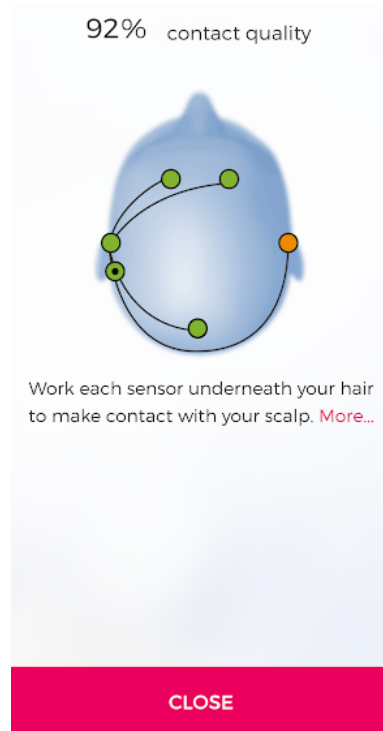


Figura 5.4: Verificación de la calidad de contacto (electrodos - cuero cabelludo).
Fuente: Elaboración propia en base a MyEmotiv App.

La **estructura general de los experimentos** para la obtención de la base de datos se puede observar en la Figura 5.5. En la imagen se muestra que la reproducción de cada una de las canciones se realiza con el mismo móvil que posee instalada la aplicación *MyEmotiv*. La música se lleva al oyente a través de unos audífonos. El sujeto con la diadema posicionada correctamente se dispone a escuchar cada canción, las señales EEG son enviadas vía *bluetooth* a la aplicación, esta última se encarga de realizar el procesamiento respectivo de las señales y genera los promedios ponderados de cada una de las seis métricas del estado de ánimo que mide el Emotiv. Estos promedios son almacenados, luego, en una hoja de cálculo del software Excel.

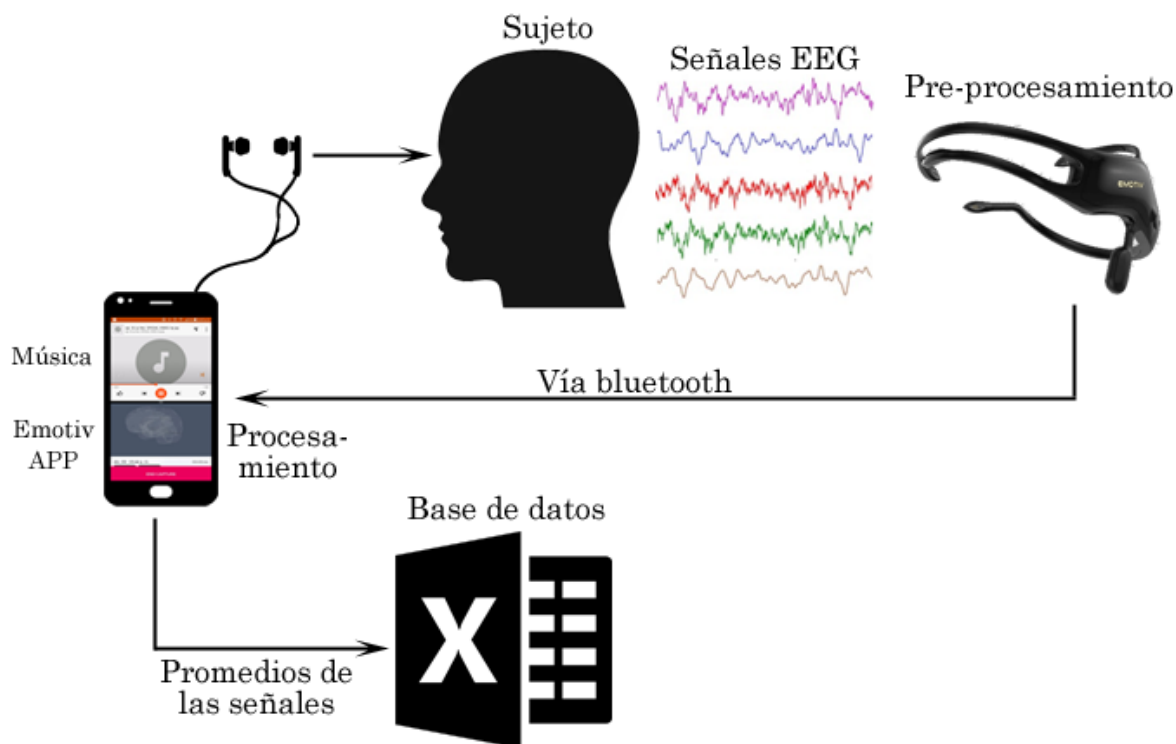


Figura 5.5: Esquema general de los experimentos para la obtención de la base de datos. *Fuente: Elaboración propia.*

5.3.3.1. Base de datos No. 1

Para esta base de datos se realizaron 10 pruebas (una por día) con la siguiente lista de canciones (siempre en el mismo orden):

1. *Braulio el templao* de Mr. Black — **Champeta**.
2. *Nocturne in E-Flat Major (Op. 9 No. 2)* de Frédéric Chopin — **Clásica**.
3. *Negro y azul* de Los Cuates de Sinaloa — **Corrido**.
4. *I will survive* de Gloria Gaynor — **Disco**.
5. *Levels* de Avicii — **Electrónica**.
6. *Entre dos aguas* de Paco de Lucía — **Flamenco**.
7. *Cum on feel the noize* de Quiet Riot — **Hard Rock**.
8. *I remember* de Damien Rice — **Indie**.
9. *Can't take my eyes off you* de Frankie Valli and The Four Season — **Jazz**.

10. *Roots, rock, reggae* de Bob Marley — **Reggae**.
11. *Y si la ves* de Ñejo — **Reggaetón**.
12. *Johnny B. Goode* de Chuck Berry — **Rock'n Roll**.
13. *Sonido bestial* de Ricardo Ray y Bobby Cruz — **Salsa**.

Para este caso, la prueba inicia con la preparación de la diadema (lo explicado al inicio de la sección) y con las respuestas a las preguntas del formato que se encuentra en el Anexo B. Luego de haber realizado estos procedimientos, se dispone a realizar la captura de las señales EEG del estado inicial en el que se encuentra el sujeto (duración de 5 minutos), la cual consiste en poner al sujeto a observar una pared blanca mientras se acostumbra a la diadema y de la misma forma obtener la data correspondiente a cómo se encuentra el sujeto previamente para obtener un patrón con el que comparar terminada la prueba. Posteriormente, se dispone a reproducir la primera canción de la lista (duración de 2 minutos), tras terminada la primera canción se da un descanso a la persona de alrededor de medio minuto. Este proceso se repite durante las 13 canciones. Después de terminada la última canción, se conduce al almacenamiento de los datos de los promedios ponderados de cada canción para ese día (arrojados por la aplicación) en una hoja de cálculo de Excel con el formato descrito en el Anexo B.

5.3.3.2. Base de datos No. 2

Para esta base de datos se realizaron 10 pruebas (una por día) con la lista de canciones en aleatorio, esto con el fin de observar los diferentes comportamientos de los estados de música frente a la canción anterior.

Para este caso se procede de la misma forma que para la Base de datos No. 1, con la excepción de que el orden de las canciones aquí reproducidas se hace con el modo aleatorio del reproductor. Después de terminada la última canción, se conduce al almacenamiento de los datos de los promedios ponderados de cada canción para ese día en una hoja de cálculo de Excel con el formato descrito en el Anexo B, con la salvedad de que el orden será diferente para cada experimento.

5.4. Determinación del estado de ánimo

En primer lugar, con los datos recolectados en las bases de datos en Excel, luego se crearon diferentes tablas que agrupaban los datos por estado de ánimo de los experimentos realizados cada día, para cada estado de ánimo se crearon dos tablas, la primera usando la Base de datos No. 1 y la segunda utilizando la Base de datos No. 2 (ver en Anexos C y D). Cada tabla contiene los valores promedio, el valor máximo, el valor mínimo, el rango y la varianza de cada género musical.

La fórmula utilizada para hallar el rango es:

$$\text{Rango} = \text{Valormáximo} - \text{Valormínimo} \quad (5.1)$$

La fórmula de la varianza que se empleó se muestra a continuación:

$$\sigma^2 = \frac{\sum(x_i - \bar{x})^2}{n - 1} \quad (5.2)$$

Donde:

σ^2 : Varianza

x_j : Términos del conjunto de datos

\bar{x} : Media de la muestra

n : Tamaño de la muestra

Los datos de cada tabla fueron normalizados haciendo uso de la siguiente fórmula:

$$N = \frac{\text{Valoractual} - \text{Valormínimo}}{\text{Valormáximo} - \text{Valormínimo}} \quad (5.3)$$

Para la selección del estado de ánimo que se trata en este proyecto, se encontró la sumatoria de la variación en valor absoluto de la varianza para cada género musical en orden específico con la varianza en orden aleatorio, la expresión resultante es la siguiente:

$$\Delta\sigma_{Total}^2 = \sum |\sigma_{ord.especifico}^2 - \sigma_{aleatorio}^2| \quad (5.4)$$

Los resultados son mostrados en la Tabla 5.2, evidenciando que el estado de ánimo que obtuvo menor variación fue el **compromiso** con **0.39**, esto quiere decir que para las distintas pruebas ejecutadas previamente, esta métrica se comportó de manera estable para cada canción, obteniendo valores constantes para cada género y conservando poca variabilidad entre pruebas, comparado con las otras métricas también evaluadas en donde su comportamiento era errático.

Dada la característica mencionada anteriormente, se puede cerciorar de que cada género conservará un nivel de respuesta a experimentos futuros y podrán ser utilizados para el diseño del algoritmo selector.

Tabla 5.2: Variaciones totales de la varianza para cada estado de ánimo.

%	Compromiso	Entusiasmo	Interés	Relajación	Estrés	Concentración
Champeta	0,00	0,02	0,02	0,07	0,01	0,07
Clásica	0,04	0,05	0,08	0,03	0,09	0,15
Corrido	0,05	0,08	0,04	0,01	0,02	0,05
Disco	0,00	0,03	0,06	0,03	0,00	0,02
Electrónica	0,00	0,07	0,01	0,04	0,00	0,03
Flamenco	0,01	0,03	0,02	0,07	0,01	0,02
Hard Rock	0,06	0,02	0,03	0,01	0,02	0,03
Indie	0,11	0,08	0,01	0,04	0,06	0,11
Jazz	0,01	0,10	0,04	0,01	0,02	0,03
Reggae	0,00	0,02	0,04	0,04	0,04	0,04
Reggaetón	0,08	0,04	0,02	0,01	0,02	0,04
Rock'n Roll	0,01	0,05	0,03	0,03	0,07	0,02
Salsa	0,02	0,07	0,03	0,05	0,04	0,04
TOTAL	0,39	0,66	0,43	0,44	0,41	0,65

5.5. Algoritmo selector de música

En el presente proyecto se consideraron dos metodologías para la realización del algoritmo selector de música. La primera basada en una ecuación de construcción heurística que elabora una lista de reproducción que busca situar las canciones con mejor rendimiento en el incremento de la métrica compromiso sin que se repitan una y otra vez la misma canción, penalizando cada reproducción previa. La segunda metodología basada en una Máquina de Soporte Vectorial (SVM), la cual busca predecir la canción que mejore, según su estado actual, la métrica compromiso. Cabe aclarar que este último método no fue configurado para penalizar la repetición de la canciones.

5.5.1. Algoritmo selector de música basado en el método heurístico (Algoritmo básico)

Para el algoritmo basado en el método heurístico (algoritmo básico) se elaboró la siguiente ecuación:

$$P_{Actual} = P_{Máx} * (1 - \frac{n}{T}) - A \quad (5.5)$$

Donde:

P_{Actual} : Nuevo promedio de la canción seleccionada.

$P_{Máx}$: Promedio más alto de todos los géneros.

n : Número de veces que se ha repetido la canción.

T : Total de canciones seleccionadas.

$A = [0,5 \ 0,4 \ 0,3 \ 0,2 \ 0,1 \ 0]$: Vector de castigo para que no se repita la misma canción.

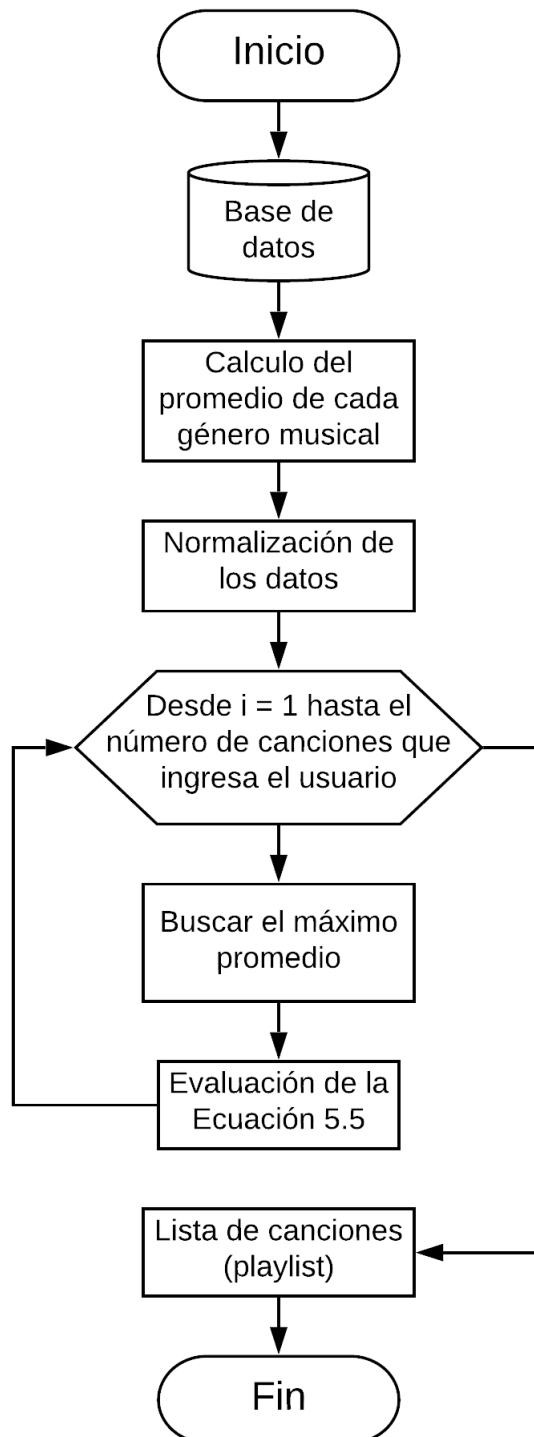


Figura 5.6: Diagrama de flujo del algoritmo selector de música basado en el método heurístico (Algoritmo básico). *Fuente: Elaboración propia.*

En la Figura 5.6 se muestra el diagrama de flujo del algoritmo selector de música básico, este consiste principalmente en:

1. Cargar la base de datos.
2. Calcular el promedio de cada género musical en las diferentes pruebas realizadas.
3. Normalizar los datos obtenidos en el paso anterior.
4. Seleccionar la canción con el promedio más alto de entre todos los datos normalizados de los experimentos.
5. Evaluar la Ecuación 5.5, la cual se basa en multiplicar el valor encontrado por un factor que es igual a la resta de uno menos el número de veces que se ha repetido la canción sobre el total de canciones seleccionadas, esto se hace con el objetivo de que se baje el promedio y no se repita en la siguiente ocasión, además se castiga aún más la canción escogida con la resta del vector A , esta penalización pretende disminuir la aparición de la canción en la *playlist* en mínimo un ciclo de seis canciones.
6. Por último, se cuenta con un vector M , en donde se almacenan las canciones que el algoritmo va seleccionando y de esta manera crea una *playlist* que permite el aumento o la estabilidad de un nivel aceptable de compromiso.

El algoritmo creado se implementó en Matlab y se muestra en el apartado Anexo E junto con el algoritmo de la interfaz gráfica creada.

5.5.2. Algoritmo basado en Máquinas de Soporte Vectorial, SVM

La máquina de soporte vectorial es una técnica de aprendizaje automático (*machine learning*) que busca el mejor hiperplano posible entre dos clases para establecerlo como límite de decisión. Esta técnica se define como un clasificador de dos clases que optimiza la distancia entre elementos cercanos al maximizar las distancias entre estos. Este clasificador se basa en la proyección de un vector de características sobre vectores auxiliares llamados vectores de soporte [35].

Para el caso de dos clases, se pueden tener hiperplanos lineales o no lineales que satisfagan los requerimientos, siendo este el punto fuerte de SVM. Además, es posible utilizar funciones para modificar los elementos de determinadas clases, y con estas transformaciones, ampliar las distancias entre las clases, a fin de que se puedan separar mediante hiperplanos. Estas funciones se conocen como *kernel*. De acuerdo al *kernel*, así será la transformación y las dimensiones del nuevo problema de clasificación [35].

Para trabajar con múltiples clases se conocen dos métodos [35]:

- Combinando múltiples SVM de dos clases, convirtiendo el clasificador en un multiclase (*one against the rest*): En esta se propone construir K-SVM con K^{th} modelos $y_k(x)$ entrenados con datos de la clase C_k como verdaderos y los datos de las $K - 1$ clases restantes como falsos, entendiéndose K como el número de clases totales, y C_k como una clase particular.

En la Figura 5.7 se presenta cómo múltiples clasificadores funcionan para clasificar entre dos clases (recuadro B, C, D) y si se realiza una combinación de estos clasificadores se pueden clasificar las tres clases propuestas (recuadro A). El principal problema de esta técnica es que una misma entrada puede ser asignada a diferentes clases simultáneamente, lo cual conllevaría a errores al momento de realizar predicciones de nuevas entradas.

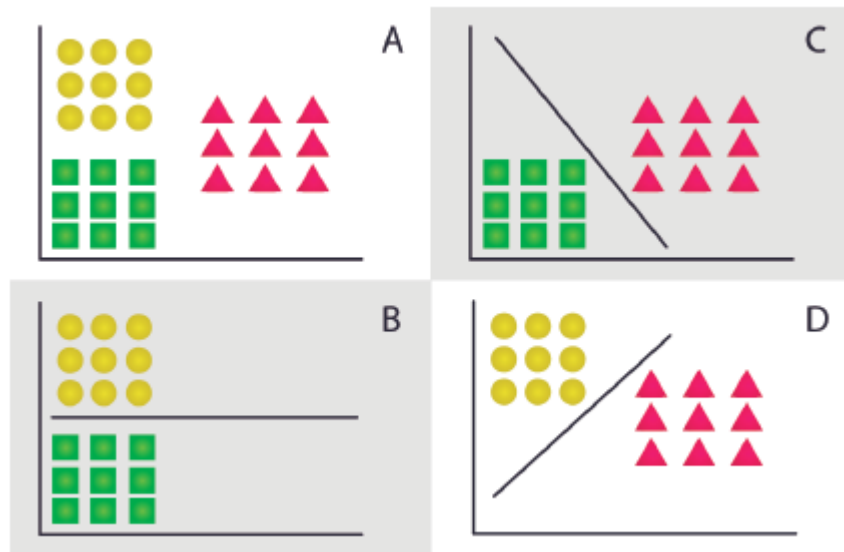


Figura 5.7: SVM Multiclase (*one against the rest*). Fuente: Cristian Olivares, “Diseño y construcción de una interfaz cerebro computadora para el control de una silla de ruedas como ayuda a personas con discapacidad motriz” (2017).

- Construir $K(K - 1)/2$ clasificadores de dos clases (*one against one*): El principal problema del método mencionado anteriormente es que bajo ciertas condiciones puede haber un objeto perteneciendo a dos o más clases, reduciendo la precisión del sistema a la hora de clasificar datos nuevos. A fin de cubrir todos los pares posibles de clases, se han estudiado métodos que confronta cada clases contra todas las posibles clases. A este método se le conoce como *one against one*.

Este método se basa en contar cuántos clasificadores de los creados determina que un elemento pertenece a una misma clase. La clase que obtenga el mayor número de “votos” será seleccionada como la clase a la que pertenece el elemento. A diferencia del método anterior, al tener que enfrentar cada clase con las demás por separado, el tiempo de entrenamiento y el tiempo de cómputo será mayor al momento de evaluar entradas nuevas.

Para este tipo de aprendizaje automático se debe tener claro que la *clasificación* es el proceso de predecir la clase de datos dados. El enfoque general para la clasificación consta de dos etapas. La primera, una etapa de aprendizaje donde se forma un modelo de clasificación a partir del análisis o entrenamiento de un conjunto de datos de entrenamiento (*training datasets*), este conjunto de datos de entrenamiento se encuentra constituido por un conjunto de datos (vector de características) y sus clases asociadas (vector de etiquetas). La segunda, una etapa de clasificación que es usada para predecir clases o etiquetas para los datos dados [46].

En el presente trabajo de investigación se implementó el método *one against one* para una SVM multiclase, puesto que se tienen 13 clases que corresponden a cada género musical, y un tipo de kernel de función de base radial (RBF) que se basa en la Ecuación 5.6. Se usó la librería LIBSVM (*A Library for Support Vector Machines*) para Matlab creada por Chang, Chih-Chung y Lin, Chih-Jen [47].

$$k_{RBF} = e^{(-gamma*|u-v|^2)} \quad (5.6)$$

Donde:

k_{RBF} : Kernel de función de base radial (RBF).

gamma: Define qué tan lejos llega la influencia de un solo ejemplo de entrenamiento. Con una gamma bajo los puntos alejados de la línea de separación plausible se consideran en el cálculo de esta, y un gamma alto significa que los puntos cercanos a la línea plausible se consideran en el cálculo (Figura 5.8).

u : Vector de entrada.

v : Vectores de soporte.

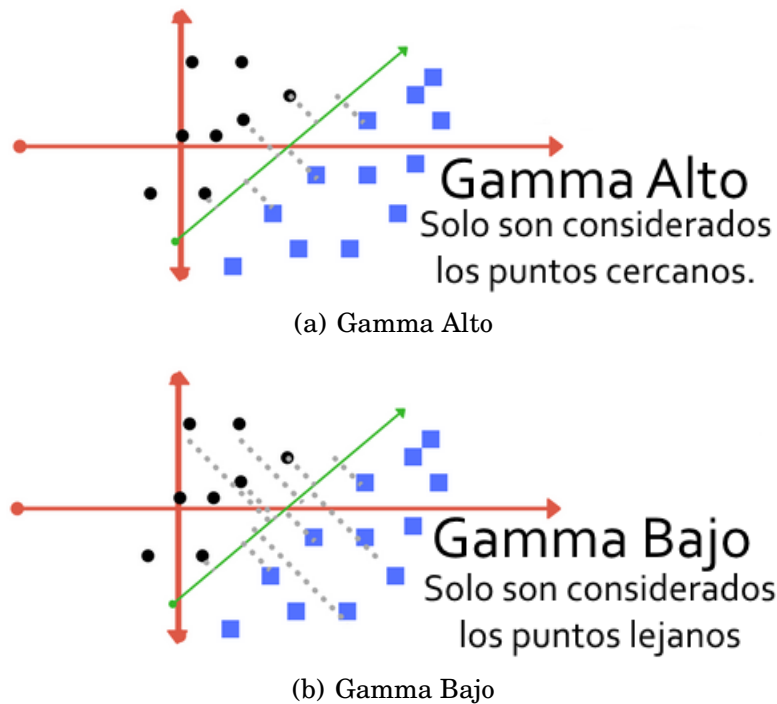


Figura 5.8: Comportamiento de gamma. *Fuente: Elaboración propia.*

La metodología de entrenamiento y ensayo fue mediante *Hold-Out*, este método consistió en dividir el conjunto de datos en un conjunto para entrenamiento y otro para prueba, escogiendo un porcentaje de 80% y 20% respectivamente (ver Anexo G). Para diseñar un SVM que al clasificar predijera la canción con mejor respuesta para la métrica de compromiso, los parámetros seleccionados para el entrenamiento correspondieron a los valores previos y actuales del estado del ánimo y las pistas que generaron estos estados, junto a la canción que incrementó la métrica de compromiso como clase. De esta forma el algoritmo genera 78 clasificadores (determinado por la forma $K(K-1)/2$ donde K es el número de clases) que agrupan a las 260 muestras según su comportamiento incremental frente al compromiso.

El algoritmo creado se implementó en Matlab y se muestra a continuación, el algoritmo de la interfaz gráfica creada se muestra en el Anexo E.

```

1      %Autor: Melissa Carolina Paternina Jimenez
2      %Fecha: 30-10-2019
3
4      clear; clc; close all;
5
6      load Data.mat
7      %Estructura que contiene el vector de características (Features)
8      %y de clases asociadas (Labels).
9
10     fs = sparse(Features);
11     %Creacion de una matriz dispersa para optimizar el uso de memoria
12
13     libsvmwrite('svm',Labels,fs);
14     %Convierte la matriz de formato Matlab a un archivo de formato
15     %LIBSVM llamado 'svm'.
16
17     [y,x] = libsvmread('svm');
18     %Lee el archivo 'svm' de formato LIBSVM y arroja dos salidas que
19     %son usadas como los datos de entrenamiento y datos de prueba.
20
21     %Datos de entrenamiento
22     trainlabel = y(1:208,:); %Datos de entrenamiento para las clases.
23     traindata = x(1:208,:); %Datos de entren. para las features.
24
25     %Datos de prueba
26     testlabel = y(209:260,:); %Datos de prueba para las clases.
27     testdata = x(209:260,:); %Datos de prueba para las features.
28
29     %Modelo de entrenamiento
30     model = svmtrain(trainlabel, traindata, '-s_0_-t_2_-g_0.01');
31     %Con svmtrain se construye el modelo de la maquina de soporte
32     %vectorial con los datos de entrenamiento y los parametros de:
33     %tipo de SVM '-s', en este caso se usa la opcion 0 que corres-
34     %ponde a la clasificacion multi-clase (C-SVC); tipo de funcion
35     %de kernel '-t', en este caso se usa la opcion 2 que corres-
36     %ponde al tipo RBF; y el valor de Gamma '-g', el cual se uso
37     %de 0.01.
38
39

```

```
40      %Prediccion
41      [predicted_label] = svmpredict(testlabel , testdata , model , '-q');
42      %Con svmpredict se elabora la clasificacion de los datos de
43      %prueba con el modelo previamente construido para evaluar la
44      %validez de este.
45
46      %Comparacion del resultado de las clases predichas con las
47      %clases reales
48      Diferencia = (predicted_label - testlabel)'
```

En el siguiente apartado se mostrarán los resultados de la implementación de ambos algoritmos junto a su discusión.

Resultados

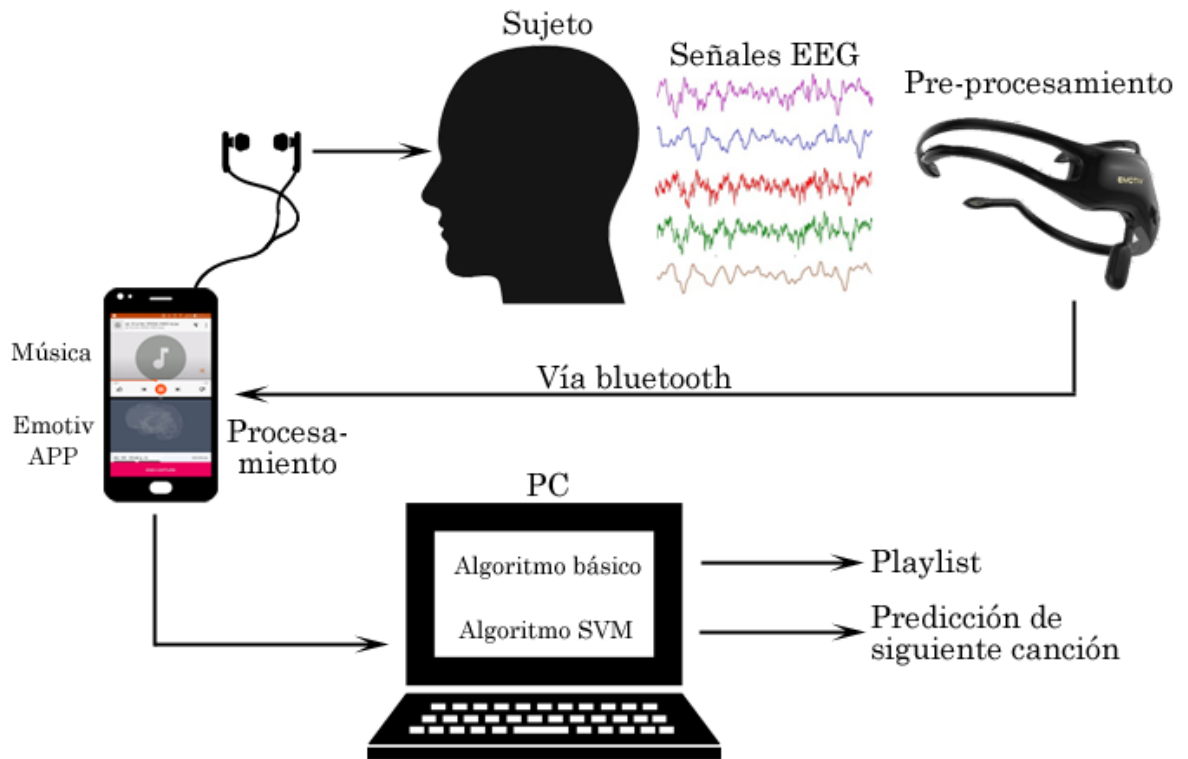


Figura 6.1: Esquema general del sistema implementado. Fuente: *Elaboración propia*.

En la Figura 6.1 se muestra el esquema general del sistema implementado en el proyecto. La música se reproduce en el mismo celular que contiene la aplicación *MyEmotiv*, las canciones son escuchadas por el sujeto a través de audífonos, las señales EEG son captadas por la diadema EMOTIV Insight la cual se encarga de realizar el pre-procesamiento de estas, luego las señales pre-procesadas son enviadas vía *bluetooth* a la aplicación la cual arroja al final de la captura de datos las señales procesadas en una gráfica y las medidas de los

promedios ponderados de cada métrica del estado de ánimo. Por último, los datos son enviados al algoritmo básico (basado en un método heurístico) o al algoritmo basado en SVM. Para la primera opción, se obtiene una *playlist* con el número de canciones que elija el usuario, mientras que para la segunda opción el usuario ingresará sus medidas de estado actual y estado anterior tomadas por la diadema y el algoritmo predecirá la próxima canción (más detalles en la sección 5.5.2).

6.1. Implementación del algoritmo basado en el modelo matemático (Algoritmo básico)

En la Figura 6.2 se evidencia el listado de géneros musicales arrojados por el algoritmo limitando la cantidad a 13 canciones.

```
LISTA DE CANCIONES:  
Corrido  
Salsa  
Hard Rock  
Electrónica  
Reggae  
Disco  
Corrido  
Salsa  
Indie  
Hard Rock  
Rock and Roll  
Electrónica  
Jazz
```

Figura 6.2: Lista de música (*playlist*) arrojada por el Algoritmo básico. *Fuente: Elaboración propia.*

Al obtener la lista de canciones, se procedió a realizar la prueba de validación, ejecutándose de manera similar a lo expuesto anteriormente en el apartado 5.3 con los cambios respectivos en la secuencia de ejecución de las canciones previamente obtenidas con el algoritmo. A continuación se observa en la Figura 6.3 el comportamiento de tres pruebas de validación de la métrica compromiso realizadas cada una en días diferentes.

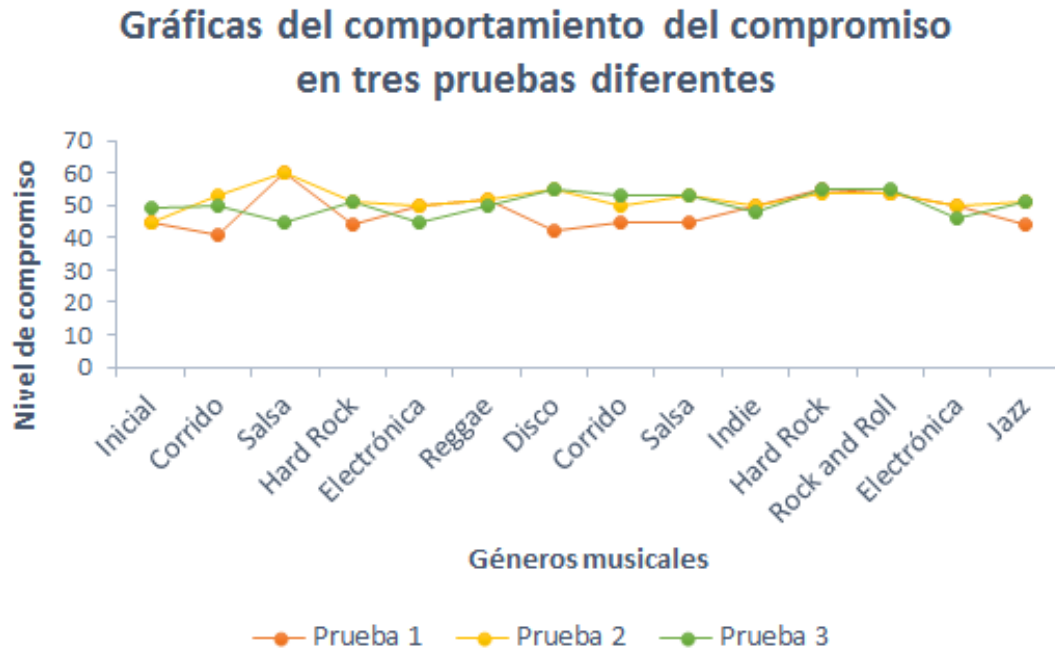


Figura 6.3: Gráficas del comportamiento del compromiso en tres pruebas diferentes. *Fuente: Elaboración propia.*

La Figura 6.3 se construyó con los datos de la tabla ubicada en el Anexo F.0.1. En la gráfica se puede evidenciar un comportamiento constante entre pruebas debido a su similitud y a la superposición entre algunos puntos de las gráficas, adicionalmente al analizar la desviación estándar de cada género por prueba se observa que algunos géneros tiene un comportamiento constante entre pruebas (Reggae, Indie, Hard Rock y Rock'n Roll).

Para determinar el incremento porcentual de los promedios de la métrica de compromiso para cada una de las tres pruebas se utilizó la ecuación del error relativo:

$$E_{rel.} = \frac{(P_G - E_i)}{E_i} \tag{6.1}$$

Donde:

$E_{rel.}$: Error relativo.

E_i : Estado inicial de la prueba.

P_G : Promedio general de la prueba sin E_i .

De igual manera, al analizar los niveles obtenidos en cada prueba se puede inferir un comportamiento positivo para cada canción en la métrica evaluada, reflejado en la conducta estable (con una desviación estándar en promedio de 4) y la obtención de un incremento del 9,3% del promedio de la prueba omitiendo el estado inicial sobre el valor con el que el usuario empezó cada experimento (ver Tabla 6.1). Para este grupo de pruebas el género con mejor resultado fue Salsa, lo que puede significar una predisposición positiva por parte del sujeto hacia este género.

Tabla 6.1: Parámetros de dispersión de la Tabla de Anexo F.0.1.

	Prueba 1	Prueba 2	Prueba 3	Promedio
Estado inicial	45	45	49	—
Promedio general de las pruebas	49	52.54	50.54	51
Desviación	5.340	3.273	3.417	4.009
% de incremento	8.034	16.752	3.140	9.309

Para ofrecer una herramienta que facilite la implementación del algoritmo se desarrolló una interfaz gráfica (Figura 6.4), la cual cuenta con una casilla para ingresar la cantidad de canciones para la *playlist*, una tabla en la que se cargan los conjuntos de datos, y un botón para generar la *playlist* que aparecerá en el lado derecho de la ventana debajo de “Lista de canciones (playlist)”. En la Figura 6.5 se muestra el resultado cuando se eligen 20 canciones.

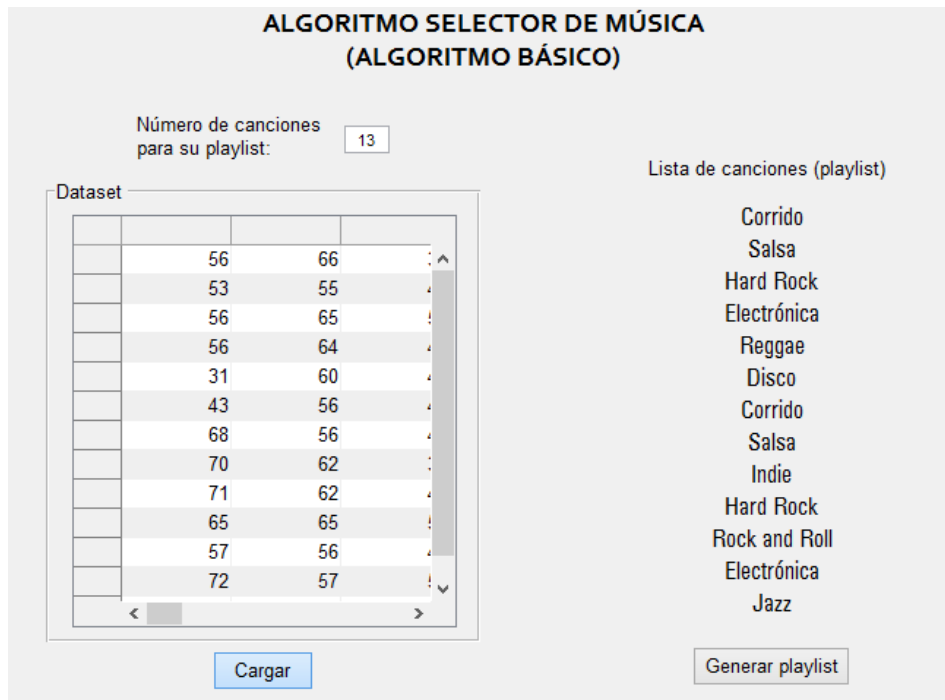


Figura 6.4: Interfaz gráfica del algoritmo básico. *Fuente: Elaboración propia.*

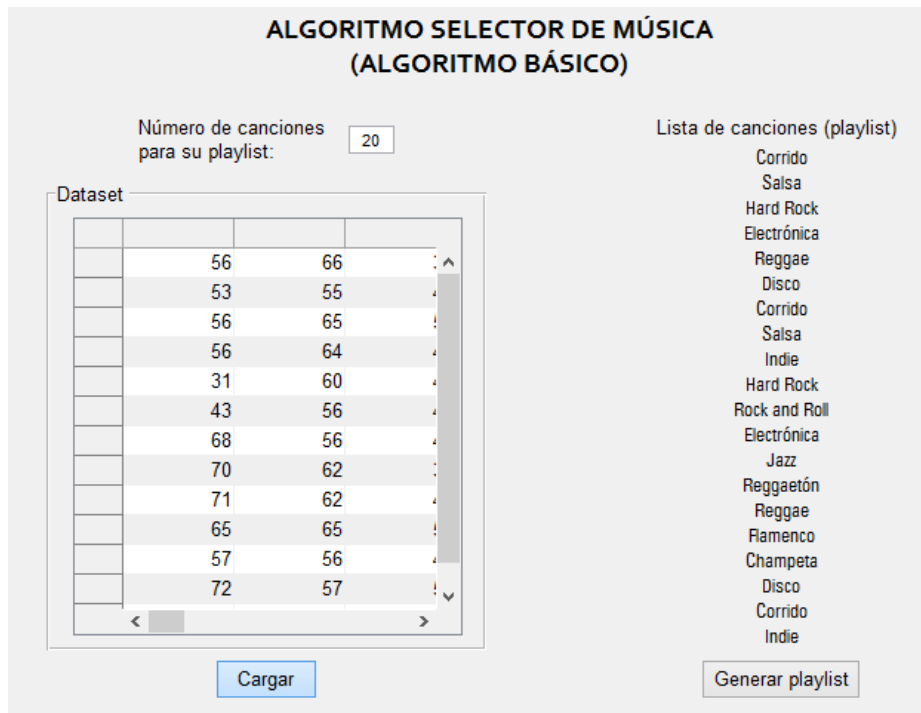


Figura 6.5: Interfaz gráfica del algoritmo básico para 20 canciones. *Fuente: Elaboración propia.*

6.2. Implementación del algoritmo basado en Máquinas de Soporte Vectorial (Algoritmo SVM)

```

predicted_label =
Columns 1 through 20
    5    10    5    5    6    6    15    5    9    5    5    5    10    5    9    10    5    6    3    10
Columns 21 through 40
    5    9    5    10    5    10    13    12    11    10    5    9    5    12    12    10    12    8    5    5
Columns 41 through 52
    9    10    12    5    12    9    15    9    12    5    12    10
  
```

(a) Etiqueta de las canciones predichas.

```

Diferencia =
Columns 1 through 21
    2    0    0    2    2    2    0    0    0    0    0    0    0    0    0    0    -2    -1    0    3    0
Columns 22 through 42
    0   -3    2   -4    1    0    0    1    0    0   -1    0    1    1    0    0   -4    0    0    0   -3
Columns 43 through 52
    0    0    0    0    5    0    0    0    0    0
  
```

(b) Diferencia entre las etiquetas de las canciones predichas y las etiquetas reales.

Figura 6.6: Resultados del algoritmo SVM. *Fuente: Elaboración propia.*

Los resultados de la ejecución del algoritmo se muestran en la Figura 6.6. Como se puede observar el algoritmo predijo acertadamente 35 de 52 canciones, teniendo un *accuracy* de 67,3%, la cual se halló con la siguiente ecuación:

$$Accuracy = \frac{No. \text{ datos predichos correctamente}}{No. \text{ total de los datos de prueba}} \times 100\% \quad (6.2)$$

En la Figura 6.6 se visualiza la respuesta del algoritmo selector basado en SVM para los 52 datos de prueba, cada número representa una de las trece canciones previamente mencionadas, en la parte (b) se muestra la resta de estas etiquetas numéricas precedidas con las reales, dando como resultado un vector

donde cada 0 que se muestra representa una buena precisión y el resto como un desacierto.

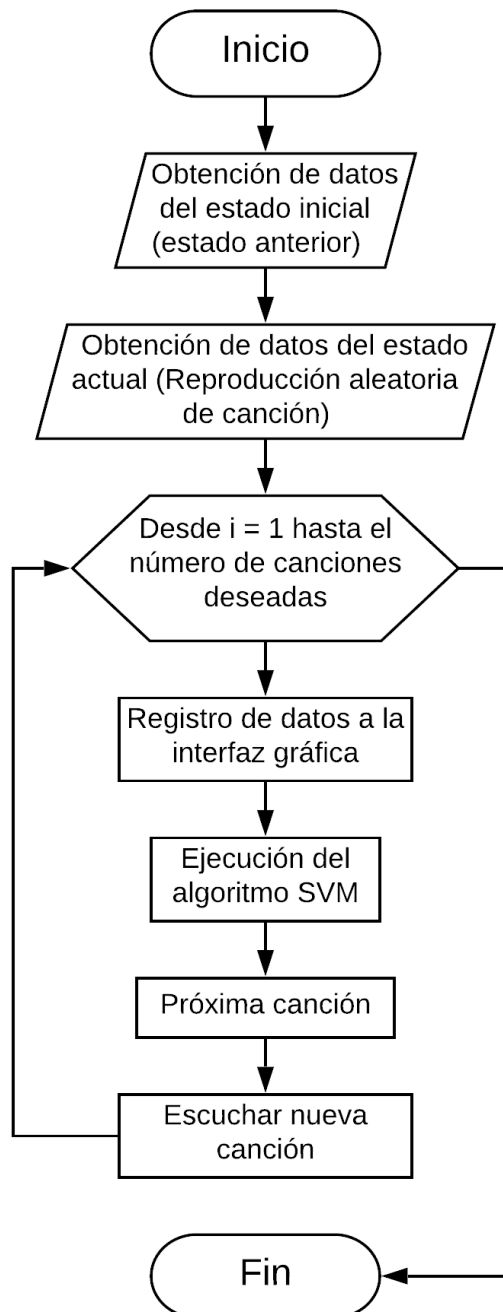


Figura 6.7: Diagrama de flujo del experimento para el algoritmo selector de música basado en SVM (Algoritmo SVM). Fuente: *Elaboración propia*.

Para la realización de las pruebas concernientes a la validación del algoritmo se capturó de manera preliminar el estado inicial del sujeto con la diadema EMOTIV Insight, luego de esto se reprodujo una canción aleatoria para inducir un cambio en el estado inicial y ser capaz de captar nuevamente la métrica compromiso. Posteriormente, los datos recolectados (Tipo de música actual, Estado actual, Estado anterior y Tipo de música anterior) se introdujeron a la interfaz gráfica para realizar la ejecución del algoritmo SVM y, de esta manera generar una predicción que indica la siguiente canción a reproducir, por último se escucha la nueva canción seleccionada con la diadema puesta y se procede a repetir este proceso hasta completar las 13 canciones de la prueba. En la Figura 6.7 se muestra el diagrama de flujo del procedimiento que debe realizar el usuario que usará el algoritmo.

En la tabla que se encuentra en el Anexo F.0.2 se presentan los datos arrojados por la diadema Emotiv Insight y la lista de canciones predichas por el algoritmo.

En la Figura 6.8 se puede observar el comportamiento del compromiso en las pruebas realizadas con el presente algoritmo. En general, presentó un comportamiento incremental con la excepción de dos canciones que al repetirse en un periodo corto de tiempo generaron una disminución significativa en los niveles de la métrica compromiso, sin embargo en términos generales al comparar el estado inicial con el promedio de todas las canciones ponderadas se evidencia un incremento del 12,27%, este último se calculó con la Ecuación 6.1 (ver Tabla 6.2).

Tabla 6.2: Parámetros de análisis de la Tabla del Anexo F.0.2.

Parámetros de dispersión	
Promedio de los géneros musicales	47.15
% de incremento	12.27

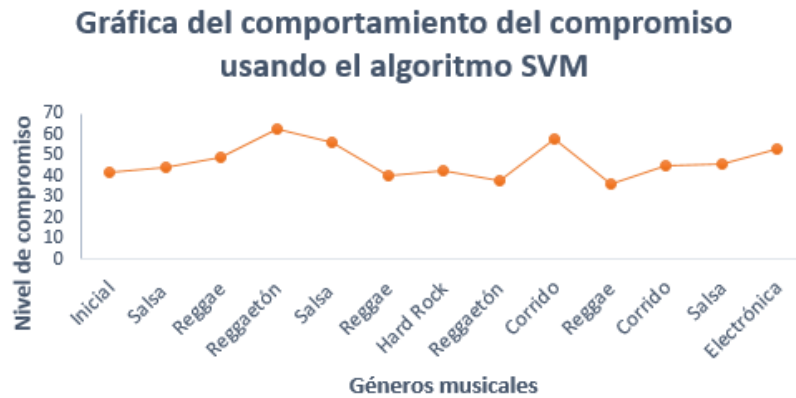


Figura 6.8: Gráfica del comportamiento del compromiso en las pruebas realizadas con el Algoritmo SVM. *Fuente: Elaboración propia.*

Para ofrecer una herramienta que facilite la implementación del algoritmo se desarrolló una interfaz gráfica (Figura 6.9), la cual cuenta con cuatro casillas para ingresar los datos requeridos, una lista de la etiqueta correspondiente para cada género musical, y un botón llamado “Próxima canción” para ejecutar el algoritmo SVM, por último la canción predicha aparecerá en el lado derecho de la ventana debajo.

ALGORITMO SELECTOR DE MÚSICA (ALGORITMO SVM)

Datos

Género musica actual	Estado actual	Estado anterior	Género musical anterior
13	63	49	12

Etiquetas para canciones

- Inicial - 2
- Champeta - 3
- Clásica - 4
- Corrido - 5
- Disco - 6
- Electrónica - 7
- Flamenco - 8
- Hard Rock - 9
- Indie - 10
- Jazz - 11
- Reggae - 12
- Reggaetón - 13
- Rock'n Roll - 14
- Salsa - 15

Próxima canción

Canción predicha

Salsa

Figura 6.9: Interfaz gráfica del algoritmo SVM. *Fuente: Elaboración propia.*

Conclusiones

En este trabajo de investigación se propusieron dos algoritmos selectores de música para cambiar o mantener un estado de ánimo aceptable, en este caso el compromiso. Se diseñaron experimentos que permitieron la creación de una base de datos clave para el uso de los algoritmos.

De manera general, se pudo observar una diferencia significativa entre las dos gráficas que describían el comportamiento del compromiso versus el género musical para cada método empleado (Algoritmo básico o SVM). Con esta diferencia se logró inferir a simple vista que el resultado del Algoritmo básico basado en el modelo matemático fue un poco superior frente al construido por la Máquina de Soporte Vectorial. Sin embargo, al evaluar los ciclos repetitivos dentro del algoritmo de Máquinas de Soporte Vectorial se encontró un patrón el cual dejaba en evidencia una respuesta creciente del parámetro deseado (compromiso), pero que decaía al momento de repetirse una canción que previamente había incrementado el nivel de este estado de ánimo.

Es de esta manera como, al interpretar la selección del género como factor que incrementa este atributo se encontró que el error en el que caen ambos algoritmos (en especial el Algoritmo con SVM) es la poca variabilidad dentro del género musical, puesto que solo se encuentra una canción por cada género incurriendo de esta forma en repeticiones que reducen el impacto de cada canción a medida que se repiten constantemente.

En virtud de lo anteriormente dicho, se hace necesaria la inclusión de más canciones por género musical para obtener mayor variabilidad y robustez en los algoritmos.

Bibliografía

- [1] Valles del Pozo, María José: *Música y educación*. Revista Electrónica de Desarrollo de Competencias (REDEC), 2(4):29–54, 2009. <http://dta.utralca.cl/ojs2/index.php/fcompetencias/article/view/53>.
- [2] Goleman, Daniel: *Inteligencia social: La nueva ciencia de las relaciones humanas*. Kairós, Editorial S.A, Barcelona, España, primera edición, 2006, ISBN 9788472456303.
- [3] Cook, Nicholas: *Perception: A Perspective from Music Theory*. En Aiello, Rita y John A. Sloboda (editores): *Musical Perceptions*, capítulo 3, páginas 64–95. Oxford University Press, New York, USA, primera edición, 1994.
- [4] Shahnaz, Celia, Shoaib Bin Masud y S. M.Shafiul Hasan: *Emotion recognition based on wavelet analysis of Empirical Mode Decomposed EEG signals responsive to music videos*. En *IEEE Region 10 Annual International Conference, Proceedings/TENCON*, páginas 424–427, Jeju, Corea del Sur, 2017. IEEE, ISBN 9781509025961.
- [5] Wu, Shiyi, Xiangmin Xu, Lin Shu y Bin Hu: *Estimation of valence of emotion using two frontal EEG channels*. En *2017 IEEE International Conference on Bioinformatics and Biomedicine, BIBM*, páginas 1127–1130, Kansas, USA, 2017. IEEE, ISBN 9781509030491.
- [6] García Moran, María de Carmen y Marta Gil Lacruz: *El estrés en el ámbito de los profesionales de la salud*. Persona, (19):11–30, 2016. <http://www.redalyc.org/pdf/1471/147149810001.pdf>.
- [7] Forbes Staff: *Mexicanos, los más estresados del mundo por su trabajo*, dec 2017. <https://www.forbes.com.mx/>

mexicanos-los-mas-estresados-del-mundo-por-su-trabajo/,
visitado el 2019-05-24.

- [8] Ministerio de la Protección Social: *Primera Encuesta Nacional de Condiciones de Salud y de Trabajo en el Sistema General de Riesgos Profesionales*, 2007. <https://www.minsalud.gov.co/DocumentosyPublicaciones/ENCUESTASALUDRP.pdf>, visitado el 2019-05-24.
- [9] Arévalo, Lyda: *La música en el manejo del estrés*, 2014. <https://www.aarp.org/espanol/recursos-para-el-cuidado/expertos/Lyda-Arevalo-Flechas/info-2014/musica-manejo-estres-relajarse.html>, visitado el 2019-05-24.
- [10] Mosquera Cabrera, Ileana: *Influencia de la música en las emociones: una breve revisión*. *Realitas: Revista de Ciencias Sociales, Humanas y Artes*, 1(2):34–38, 2013.
- [11] Bradt, Joke, Cheryl Dileo y Noah Potvin: *Music for stress and anxiety reduction in coronary heart disease patients*. *Cochrane Database of Systematic Reviews*, (12):1–104, 2013. <http://topomelody.com/wp-content/uploads/2016/08/Study2.pdf>.
- [12] Juslin, Patrik N.: *Music and Emotion: Seven Questions, Seven Answers*. En Deliège, Irene y Jane Davidson (editores): *Music and the mind: Essays in honour of John Sloboda*, capítulo 7, páginas 113–135. Oxford University Press, New York, 1ª edición, 2011, ISBN 978-0199581566. <https://www.psyk.uu.se/digitalAssets/510/c{ }510552-1{ }1-k{ }music-and-emotion{ }86978{ }3chapter.pdf>.
- [13] Jauset Berrocal, Jordi A.: *Música y Neurociencia: la musicoterapia sus fundamentos, efectos y aplicaciones terapéuticas*. UOC (Universitat Oberta De Catalunya), Barcelona, 1ª edición, 2008, ISBN 9788497887625.
- [14] Qi, Zhang y Yoshimine Norikazu: *A study on human brain activity during music listening using EEG measurement*. Tama University School

- of Global Studies Bulletin, 7:148–157, 2015. https://tama.repo.nii.ac.jp/?action=pages_view_main&active_action=repository_view_main_item_detail&item_id=268&item_no=1&page_id=13&block_id=52.
- [15] Mulla, F., Eya Eya, E. Ibrahim, A. Alhaddad, R. Qahwaji y R. Abd-Alhameed: *Neurological Assessment of Music Therapy on the Brain using Emotiv Epoc*. En *Internet Technologies and Applications (ITA)*, páginas 259–263, Wrexham, United Kingdom, 2017. IEEE. <https://ieeexplore.ieee.org/document/8101950>.
- [16] Folgieri, Raffaella y Matteo Zichella: *A BCI-based application in music: conscious playing of single notes by brainwaves*. ACM Computers in Entertainment, 10(3):10, 2012. https://www.researchgate.net/publication/235633541_A_BCI-based_application_in_music_Conscious
- [17] Qi, Zhang y Yoshimine Norikazu: *An EEG study on music listening with ICA approach*. Tama University School of Global Studies Bulletin, 9:117–128, 2017. https://tama.repo.nii.ac.jp/?action=pages_view_main&active_action=repository_view_main_item_detail&item_id=919&item_no=1&page_id=13&block_id=52.
- [18] Hossan, Alamgir y A. M. Mahmud Chowdhury: *Real time EEG based automatic brainwave regulation by music*. En *5th International Conference on Informatics, Electronics and Vision (ICIEV)*, páginas 780–784, Dhaka, 2016. IEEE. <https://ieeexplore.ieee.org/document/7760107>.
- [19] Yanguas Leyes, Javier: *Influencia de la música en el rendimiento deportivo*. Apunts. Medicina de l’Esport, 41(152):131–171, 2006. <https://www.apunts.org/es-influencia-musica-el-rendimiento-deportivo-articulo-X021337170>
- [20] Hassan, Hasmindia, Zunairah Haji Murat, Valerie Ross y Norli-da Buniyamin: *A preliminary study on the effects of music on hu-*

- man brainwaves.* En *International Conference on Control, Automation and Information Sciences, ICCAIS*, páginas 176–180, Vietnam, 2012. IEEE. https://www.researchgate.net/publication/261206700_A_preliminary_study_on_the_effects_of_mu
- [21] Gómez Gallego, M. y J. Gómez García: *Musicoterapia en la enfermedad de Alzheimer: efectos cognitivos, psicológicos y conductuales.* *Neurología*, 32(5):300–308, 2016. <https://www.elsevier.es/es-revista-neurologia-295-avance-resumen-musicoterapia-enfermedad>
- [22] Fernández, Isabel: *Disminución del gasto energético en prematuros a través de la música de Mozart.* *Enfermería Clínica*, 24(3):205–206, 2014.
- [23] López, Natividad, Andrés Ruiz de Casas, Macarena Morales, David Moreno y Francisco Camacho: *Aspectos socioculturales de la influencia de la música sobre el personal sanitario que trabaja en el quirófano.* *PIEL: Formación continuada en dermatología*, 31(4):236–241, 2015. <https://www.sciencedirect.com/science/article/pii/S0213925116000083>.
- [24] Brennan, Juan Arturo: *Cómo acercarse a la música.* Plaza y Valdés Editores, Ciudad de México, primera edición, 1988, ISBN 968-856-137-1. https://kupdf.net/download/como-acercarse-a-la-musica-de-juan-arturo-brennan-pdf_59f496a9e
- [25] Guerrero, Juliana: *El género musical en la música popular: algunos problemas para su caracterización.* *Trans - Revista Transcultural de Música*, 16(16):3, 2012, ISSN 1697-0101. https://www.sibetrans.com/trans/public/docs/trans_16_09.pdf.
- [26] Gallardo Vergara, René: *Naturaleza del Estado de Ánimo.* *Revista Chilena de Neuropsicología*, 1(1):29–40, 2006. <http://www.redalyc.org/pdf/1793/179317886004.pdf>.
- [27] Oneca Carreras, Noelia: *Musicoterapia fundamentos, aspectos prácticos y aplicación a niños hospitalizados.* Monografía, Universidad de Navarra, 2015. <https://dadun.unav.edu/bitstream/10171/39653/1/NoeliaOneca.pdf>.

- [28] Perani, Daniela, Mari Tervaniemi y Petri Toivainen: *Tuning the brain for music*. *Cortex*, 47(9):1023–1025, 2011, ISSN 00109452. <http://dx.doi.org/10.1016/j.cortex.2011.05.021>.
- [29] Ramos-Argüelles, F., G. Morales, S. Egozcue, R.M. Pabón y M.T. Alonso: *Técnicas básicas de electroencefalografía: principios y aplicaciones clínicas*. *Anales del Sistema Sanitario de Navarra*, 32(3):69–82, 2009, ISSN 1137-6627. http://scielo.isciii.es/scielo.php?script=sci_arttext&pid=S1137-66272009000600006&lng=en&nrm=iso&tlng=en.
- [30] Reyes Rueda, Angélica: *Interfaz cerebro computador mediante la clasificación de señales electroencefalográficas*. Monografía, Pontificia Universidad Javeriana, 2013. <https://repository.javeriana.edu.co/bitstream/handle/10554/13623/ReyesRuedaAngelica2013.pdf?sequence=1>.
- [31] Trans Cranial Technologies Ltd: *10/20 System Positioning*. Trans Cranial Technologies Ltd, Wanchai, Hong Kong, primera edición, 2012. http://chgd.umich.edu/wp-content/uploads/2014/06/10-20_system_positioning.pdf.
- [32] McFarland, Dennis J. y Jonathan R. Wolpaw: *Brain-computer interfaces for communication and control*. *Communications of the ACM*, 54(5):60, may 2011, ISSN 00010782. <http://portal.acm.org/citation.cfm?doid=1941487.1941506>.
- [33] Shih, Jerry J., Dean J. Krusienski y Jonathan R. Wolpaw: *Brain-computer interfaces in medicine*. *Mayo Clinic Proceedings*, 87(3):268–279, 2012, ISSN 00256196. <http://dx.doi.org/10.1016/j.mayocp.2011.12.008>.
- [34] Schalk, Gerwin, Dennis J. McFarland, Thilo Hinterberger, Niels Birbaumer y Jonathan R Wolpaw: *BCI2000: A general-purpose brain-computer interface (BCI) system*. *IEEE Transactions on Biomedical Engineering*, 51(6):1034–1043, 2004, ISSN 00189294.

- [35] Olivares Carrillo, Cristian Yarisse: *Diseño y construcción de una interfaz cerebro computadora para el control de una silla de ruedas como ayuda a personas con discapacidad motriz*. Monografía, Universidad del Norte, 2017. <http://manglar.uninorte.edu.co/handle/10584/7622>.
- [36] Talamillo García, Teresa: *Manual básico para enfermeros en electroencefalografía*. *Enfermería Docente*, (94):29–33, 2011. <http://www.index-f.com/edocente/94/94-029.php>.
- [37] EMOTIV Company: *About us*, 2012. <https://www.emotiv.com/about-emotiv/>, visitado el 2018-08-19.
- [38] Ros, Jay: *Vice BudLab*, 2016. <https://bit.ly/2GBC2qd>, visitado el 2019-04-27.
- [39] Ogata, Katsuhiko: *Ingeniería de control moderna*. Pearson Educación S.A., Madrid, quinta edición, 2010, ISBN 978-84-8322-660-5. https://www.u-cursos.cl/usuario/78303fe04da8e4eb340eae09f1840b2/mi{}_blog/r/Ingenieria{}_de{}_Control{}_Moderna{}_Ogata{}_5a{}_ed.pdf.
- [40] Joyanes Aguilar, Luis: *Fundamentos de programación: Algoritmos, estructura de datos y objetos*. McGraw-Hill, Madrid, 4^a edición, 2008, ISBN 978-84-481-6111-8. <http://combomix.net/wp-content/uploads/2017/03/Fundamentos-de-programaci{%}25C3{%}25B3n-4ta-Edici{%}25C3{%}25B3n-pdf>.
- [41] Garcia Serrano, Alberto: *Inteligencia Artificial. Fundamentos, prácticas y aplicaciones*. RC Libros, Madrid, España, primera edición, 2012, ISBN 978-84-944650-4-8.
- [42] Gago Utrera, Rosario: *Uso de algoritmos automático aplicado a bases de datos genéticos*. Monografía, Universitat Oberta de Catalunya, 2017. <http://openaccess.uoc.edu/webapps/o2/bitstream/10609/65426/6/rgagoTFM0617memoria.pdf>.

- [43] Dankhe, Gordon: *Investigación y comunicación*. En Fernández-Collado, C. y G. L. Dankhe (editores): *La comunicación humana ciencia social*, capítulo 2, página 468. McGraw-Hill, Ciudad de México, México, primera edición, 1986.
- [44] ASUSTeK Computer Inc: *Características ZenFone 3 (ZE552KL) | Teléfonos | ASUS Colombia*. <https://www.asus.com/co/Phone/ZenFone-3-ZE552KL/Features/>, visitado el 2019-12-12.
- [45] EMOTIV Company: *MY EMOTIV*, 2012. <https://www.emotiv.com/myemotiv/>, visitado el 2019-12-04.
- [46] Karaca, Y y C Cattani: *Computational Methods for Data Analysis*. De Gruyter Textbook. De Gruyter, 2018, ISBN 9783110493603. <https://books.google.com.co/books?id=LE2FDwAAQBAJ>.
- [47] Chang, Chih Chung y Chih Jen Lin: *LIBSVM: A Library for Support Vector Machines*. ACM Transactions on Intelligent Systems and Technology, 2(3):1–27, 2011.

Formato de consentimiento

FORMATO DE CONSENTIMIENTO INFORMADO

Título del estudio: Algoritmo selector de música basado en el estado de ánimo del usuario utilizando una interfaz cerebro-computador.

Yo, _____ una vez informado sobre los propósitos, objetivos, procedimientos de intervención y evaluación que se llevarán a cabo en esta investigación autorizo a la persona encargada para la realización de las pruebas con la diadema EMOTIV Insight escuchando un conjunto de canciones para la obtención de las señales EEG de las seis métricas del estado de ánimo que maneja la diadema.

Adicionalmente se me informó que:

- El estudio no implica ningún riesgo para la salud ni para su estado de ánimo. No implica tampoco la toma de ningún medicamento.
- Su participación en este estudio es completamente libre y voluntaria por lo que en cualquier momento puede retirarse del mismo.
- Todos los datos recogidos sobre su participación en este estudio serán considerados como confidenciales.
- En el informe final del estudio o en caso de comunicar los resultados a la comunidad científica, se mantendrá a su persona en completo anonimato, los resultados personales no pueden estar disponibles a terceras personas como empleadores, organizaciones gubernamentales, compañías de seguros u otras instituciones educativas.

Hago constar que el presente documento ha sido leído y entendido por mí en su integridad de manera libre y espontánea.

Firma
Documento de identidad _____ de _____

Formato de las pruebas

Objetivo: Recoger información necesaria y relevante para medir la influencia de aspectos externos en las pruebas realizadas al usuario.

Fecha: __/__/__

Hora: __: __ __

1. ¿Cómo te sientes hoy?

- Extremadamente estresado/a
- Moderadamente estresado/a
- Algo estresado/a
- Un poco estresado/a
- Para nada estresado/a

- Extremadamente relajado/a
- Moderadamente relajado/a
- Algo relajado/a
- Un poco relajado/a
- Para nada relajado/a

- Extremadamente molesto/a
- Moderadamente molesto/a
- Algo molesto/a
- Un poco molesto/a
- Para nada molesto/a

- Extremadamente entusiasmado/a
- Moderadamente entusiasmado/a
- Algo entusiasmado/a
- Un poco entusiasmado/a
- Para nada entusiasmado/a

- Extremadamente cansado/a
- Moderadamente cansado/a
- Algo cansado/a
- Un poco cansado/a
- Para nada cansado/a

2. ¿Hay ruido en el exterior?

__ Sí __ No

Fecha	Prueba N° __ : ordenada __ o random __					
Hora						
%	Compromiso	Entusiasmo	Interés	Relajación	Estrés	Concentración
Estado inicial (5 min)						
Champeta						
Clásica						
Corrido						
Disco						
Electrónica						
Flamenco						
Hard Rock						
Indie						
Jazz						
Reggae						
Reggaetón						
Rock'n Roll						
Salsa						
Min						
Max						

Base de datos No. 1

31-ago-18	Prueba 1					
%	Compromiso	Entusiasmo	Interés	Relajación	Estrés	Concentración
Estado inicial (5 min)	73	31	52	33	53	42
Champeta	56	45	57	46	53	54
Clásica	53	17	53	30	32	31
Corrido	56	43	43	27	52	59
Disco	56	53	46	28	90	74
Electrónica	31	36	58	26	31	51
Flamenco	43	38	62	29	48	50
Hard Rock	68	26	60	37	54	37
Indie	70	20	50	40	24	27
Jazz	71	26	60	44	62	41
Reggae	65	19	51	42	23	19
Reggaetón	57	19	53	43	34	24
Rock'n Roll	72	17	53	46	32	21
Salsa	55	21	61	35	57	40
Min	31	17	43	26	23	19
Max	73	53	62	46	90	74

20-oct-18	Prueba 2					
%	Compromiso	Entusiasmo	Interés	Relajación	Estrés	Concentración
Estado inicial (10 min)	64	43	64	33	46	50
Champeta	66	35	62	34	44	49
Clásica	55	55	63	36	48	53
Corrido	65	40	60	45	48	48
Disco	64	31	56	46	47	39
Electrónica	60	57	64	30	90	78
Flamenco	56	52	61	27	72	67
Hard Rock	56	53	60	26	39	64
Indie	62	35	54	27	71	62
Jazz	62	24	56	44	57	41
Reggae	65	23	56	54	55	27
Reggaetón	56	30	64	27	69	53
Rock'n Roll	57	34	62	26	65	59
Salsa	69	20	60	30	44	35
Min	55	20	54	26	39	27
Max	69	57	64	54	90	78

29-abr-19	Prueba 3					
%	Compromiso	Entusiasmo	Interés	Relajación	Estrés	Concentración
Estado inicial (5 min)	41	23	50	28	32	37
Champeta	33	17	48	23	26	17
Clásica	42	23	49	28	29	26
Corrido	55	23	50	30	30	31
Disco	44	36	54	34	36	33
Electrónica	43	31	52	36	36	31
Flamenco	44	31	54	39	37	32
Hard Rock	45	27	52	38	36	30
Indie	35	24	50	27	29	25
Jazz	40	41	55	39	35	25
Reggae	59	34	52	32	35	39
Reggaetón	44	36	51	33	32	28
Rock'n Roll	56	29	59	28	38	41
Salsa	59	32	50	40	41	59
Min	33	17	48	23	26	17
Max	59	41	59	40	41	59

23-abr-19	Prueba 4					
%	Compromiso	Entusiasmo	Interés	Relajación	Estrés	Concentración
Estado inicial (5 min)	43	23	50	25	30	36
Champeta	55	28	51	31	35	43
Clásica	53	27	51	27	31	43
Corrido	61	22	52	31	35	51
Disco	49	41	53	35	38	39
Electrónica	48	30	52	26	33	42
Flamenco	53	29	52	36	38	42
Hard Rock	52	25	52	37	36	38
Indie	55	30	53	35	34	36
Jazz	45	32	53	33	35	41
Reggae	54	42	55	41	37	39
Reggaetón	60	30	53	37	34	46
Rock'n Roll	47	42	53	34	33	35
Salsa	60	35	52	35	35	39
Min	43	22	50	25	30	35
Max	61	42	55	41	38	51

11-abr-19	Prueba 5					
%	Compromiso	Entusiasmo	Interés	Relajación	Estrés	Concentración
Estado inicial (5 min)	51	34	54	40	36	34
Champeta	47	28	53	48	39	32
Clásica	47	34	56	32	34	33
Corrido	41	25	52	27	31	28
Disco	54	37	56	49	43	42
Electrónica	55	42	57	46	41	38
Flamenco	31	21	48	29	28	20
Hard Rock	33	24	52	49	36	21
Indie	37	19	48	34	29	20
Jazz	44	40	52	32	34	26
Reggae	59	36	53	40	36	43
Reggaetón	53	31	54	48	39	41
Rock'n Roll	43	20	49	34	30	26
Salsa	49	22	49	34	32	29
Min	31	19	48	27	28	20
Max	59	42	57	49	43	43

28-mar-19	Prueba 6					
%	Compromiso	Entusiasmo	Interés	Relajación	Estrés	Concentración
Estado inicial (5 min)	46	26	49	25	34	42
Champeta	46	35	53	38	36	33
Clásica	45	35	53	39	37	33
Corrido	52	21	50	35	36	38
Disco	49	29	53	36	36	34
Electrónica	48	28	53	35	35	31
Flamenco	47	41	54	45	39	34
Hard Rock	46	36	55	45	40	33
Indie	54	17	47	34	36	41
Jazz	50	18	48	32	35	36
Reggae	45	26	50	30	34	31
Reggaetón	44	30	51	36	38	36
Rock'n Roll	32	29	52	27	34	28
Salsa	38	31	52	28	33	34
Min	32	17	47	25	33	28
Max	54	41	55	45	40	42

03-abr-19	Prueba 7					
%	Compromiso	Entusiasmo	Interés	Relajación	Estrés	Concentración
Estado inicial (5 min)	46	21	50	29	34	36
Champeta	53	27	51	33	37	39
Clásica	52	20	51	29	31	42
Corrido	61	25	52	34	35	47
Disco	46	32	54	37	36	32
Electrónica	53	27	52	35	32	30
Flamenco	59	36	55	56	46	42
Hard Rock	69	39	55	53	43	49
Indie	49	44	55	48	41	29
Jazz	50	27	50	47	39	35
Reggae	47	29	52	49	38	31
Reggaetón	37	33	54	26	33	27
Rock'n Roll	61	25	50	37	35	32
Salsa	74	29	55	57	45	63
Min	37	20	50	26	31	27
Max	74	44	55	57	46	63

08-abr-19	Prueba 8					
%	Compromiso	Entusiasmo	Interés	Relajación	Estrés	Concentración
Estado inicial (5 min)	38	26	50	31	34	30
Champeta	44	23	50	24	31	34
Clásica	38	22	50	30	32	30
Corrido	60	31	52	39	40	49
Disco	53	24	52	38	38	41
Electrónica	47	31	53	33	37	36
Flamenco	37	20	52	33	33	25
Hard Rock	49	47	53	42	39	35
Indie	36	25	52	33	31	25
Jazz	39	19	51	23	28	30
Reggae	44	22	52	23	29	31
Reggaetón	37	23	52	40	37	26
Rock'n Roll	44	36	53	33	38	33
Salsa	47	27	53	44	40	35
Min	36	19	50	23	28	25
Max	60	47	53	44	40	49

09-abr-19	Prueba 9					
%	Compromiso	Entusiasmo	Interés	Relajación	Estrés	Concentración
Estado inicial (5 min)	45	34	53	37	39	36
Champeta	34	24	51	30	34	21
Clásica	46	28	51	35	35	31
Corrido	46	24	52	35	37	33
Disco	56	39	52	35	39	39
Electrónica	69	19	52	41	39	50
Flamenco	64	32	53	39	40	48
Hard Rock	65	34	56	55	45	49
Indie	69	25	55	60	47	50
Jazz	45	38	55	37	39	31
Reggae	48	20	52	30	34	35
Reggaetón	54	20	52	30	34	38
Rock'n Roll	56	25	53	34	36	42
Salsa	61	28	53	58	45	45
Min	34	19	51	30	34	21
Max	69	39	56	60	47	50

10-abr-19	Prueba 10					
%	Compromiso	Entusiasmo	Interés	Relajación	Estrés	Concentración
Estado inicial (5 min)	51	37	53	39	38	36
Champeta	36	26	52	37	32	24
Clásica	41	37	55	43	37	26
Corrido	51	22	52	52	41	39
Disco	61	31	53	50	43	44
Electrónica	51	43	56	51	43	36
Flamenco	52	37	54	38	38	33
Hard Rock	55	45	57	50	43	38
Indie	45	37	54	20	31	29
Jazz	54	39	54	40	37	35
Reggae	45	28	52	40	34	25
Reggaetón	48	33	52	45	41	34
Rock'n Roll	47	30	53	47	38	29
Salsa	58	28	53	49	40	42
Min	36	22	52	20	31	24
Max	61	45	57	52	43	44

Base de datos No. 2

07-may	Prueba 1					
%	Compromiso	Entusiasmo	Interés	Relajación	Estrés	Concentración
Estado inicial (5 min)	51	27	53	39	37	35
Reggaetón	45	30	52	27	32	37
Hard Rock	41	34	53	31	33	24
Flamenco	53	27	54	37	34	29
Salsa	47	30	53	35	32	31
Rock'n Roll	40	31	53	34	33	27
Disco	49	36	54	36	37	35
Clásica	53	26	53	35	35	42
Reggae	47	36	54	39	37	35
Corrido	51	42	53	33	34	40
Jazz	44	34	53	31	33	40
Electrónica	61	31	54	46	41	42
Indie	50	35	54	42	34	33
Champeta	43	32	53	40	33	26
Min	40	26	52	27	32	24
Max	61	42	54	46	41	42

13-may	Prueba 2					
%	Compromiso	Entusiasmo	Interés	Relajación	Estrés	Concentración
Estado inicial (5 min)	35	22	51	26	31	24
Champeta	53	33	52	40	37	42
Reggae	63	30	53	35	37	46
Indie	55	45	58	43	41	29
Electrónica	54	26	53	35	36	30
Corrido	62	29	54	46	43	40
Hard Rock	60	19	54	36	35	28
Salsa	59	30	54	41	38	33
Jazz	53	22	55	41	37	25
Rock'n Roll	50	28	53	39	40	32
Clásica	43	34	53	44	45	42
Reggaetón	63	22	53	36	37	38
Disco	50	32	52	37	37	33
Flamenco	48	26	52	35	36	23
Min	35	19	51	26	31	23
Max	63	45	58	46	45	46

20-may	Prueba 3					
%	Compromiso	Entusiasmo	Interés	Relajación	Estrés	Concentración
Estado inicial (5 min)	52	29	49	33	36	42
Rock'n Roll	41	27	50	34	38	35
Champeta	41	31	50	38	41	36
Indie	43	19	50	29	32	36
Disco	55	32	52	39	39	32
Hard Rock	46	22	51	37	36	34
Electrónica	45	30	52	41	40	37
Clásica	35	20	50	27	27	20
Corrido	41	35	51	23	28	30
Flamenco	35	35	51	20	26	26
Salsa	51	47	53	40	39	38
Reggaetón	52	42	56	42	38	36
Jazz	39	22	52	36	35	30
Reggae	54	36	55	43	38	36

21-may	Prueba 4					
%	Compromiso	Entusiasmo	Interés	Relajación	Estrés	Concentración
Estado inicial (5 min)	46	25	50	30	35	32
Reggae	49	29	55	36	33	32
Corrido	52	23	52	43	41	36
Disco	44	42	53	32	37	41
Clásica	43	29	52	32	35	31
Flamenco	46	36	54	37	38	30
Electrónica	47	37	54	41	41	32
Rock'n Roll	51	27	53	30	33	30
Jazz	54	31	54	33	35	29
Hard Rock	56	38	59	45	41	36
Salsa	44	56	67	41	36	31
Champeta	35	41	56	39	36	25
Reggaetón	31	31	58	28	33	17
Indie	42	48	57	49	39	28
Min	31	23	50	28	33	17
Max	56	56	67	49	41	41

27-may	Prueba 5					
%	Compromiso	Entusiasmo	Interés	Relajación	Estrés	Concentración
Estado inicial (5 min)	45	31	51	31	33	36
Salsa	51	21	52	31	33	39
Electrónica	46	27	53	38	41	41
Indie	51	25	53	33	35	42
Champeta	49	31	53	38	37	29
Disco	49	34	54	35	36	30
Flamenco	44	26	53	27	30	31
Rock'n Roll	47	39	57	45	48	30
Reggaetón	50	41	55	42	42	32
Hard Rock	49	38	57	46	45	32
Clásica	46	31	53	32	34	30
Corrido	66	56	57	45	42	61
Jazz	55	44	54	42	36	38
Reggae	57	27	53	29	31	44
Min	44	21	51	27	30	29
Max	66	56	57	46	48	61

28-may	Prueba 6					
%	Compromiso	Entusiasmo	Interés	Relajación	Estrés	Concentración
Estado inicial (5 min)	51	26	51	32	32	36
Flamenco	40	24	52	36	36	24
Reggaetón	38	28	52	29	34	31
Corrido	39	36	53	31	37	37
Jazz	36	23	52	29	31	30
Reggae	45	37	54	35	36	41
Salsa	39	28	53	34	36	30
Rock'n Roll	41	34	53	35	36	32
Clásica	51	33	53	32	36	44
Indie	51	26	53	30	34	42
Disco	44	39	54	40	41	38
Champeta	42	32	53	41	36	26
Electrónica	50	36	54	38	36	33
Hard Rock	54	40	53	45	41	46
Min	36	23	51	29	31	24
Max	54	40	54	45	41	46

10-jun	Prueba 7					
%	Compromiso	Entusiasmo	Interés	Relajación	Estrés	Concentración
Estado inicial (5 min)	41	35	50	34	35	35
Jazz	38	35	51	37	38	34
Reggaetón	32	27	51	32	37	25
Champeta	36	35	52	40	36	25
Hard Rock	43	31	51	32	35	37
Clásica	46	40	52	36	39	43
Corrido	35	35	52	32	36	27
Flamenco	35	34	52	31	36	26
Indie	42	64	55	26	36	32
Salsa	38	31	52	36	36	25
Reggae	41	62	55	37	39	31
Rock'n Roll	54	44	38	30	34	28
Disco	46	45	53	34	36	30
Electrónica	56	32	53	33	33	36
Min	32	27	38	26	33	25
Max	56	64	55	40	39	43

11-jun	Prueba 8					
%	Compromiso	Entusiasmo	Interés	Relajación	Estrés	Concentración
Estado inicial (5 min)	43	33	51	33	36	39
Salsa	37	27	51	25	29	29
Jazz	43	25	52	31	33	31
Clásica	44	14	52	24	28	33
Reggae	46	23	52	31	36	35
Flamenco	44	39	53	41	42	34
Electrónica	51	27	53	32	38	45
Hard Rock	54	31	54	44	45	39
Indie	52	44	54	45	39	31
Reggaetón	55	37	54	43	37	32
Champeta	53	42	54	32	31	33
Disco	50	31	53	30	30	32
Rock'n Roll	39	19	53	26	29	27
Corrido	46	27	54	31	33	34
Min	37	14	51	24	28	27
Max	55	44	54	45	45	45

12-jun	Prueba 9					
%	Compromiso	Entusiasmo	Interés	Relajación	Estrés	Concentración
Estado inicial (5 min)	43	36	52	31	35	36
Electrónica	42	39	52	34	36	36
Reggaetón	53	18	52	33	33	45
Clásica	27	30	52	27	31	19
Rock'n Roll	36	24	53	27	31	30
Jazz	42	39	53	31	35	32
Salsa	47	46	54	43	44	37
Hard Rock	47	52	56	46	47	40
Corrido	54	34	54	42	39	45
Flamenco	57	40	54	39	36	39
Champeta	56	34	59	28	41	51
Indie	44	33	53	31	32	29
Disco	39	29	50	24	29	36
Reggae	37	28	52	24	29	29
Min	27	18	50	24	29	19
Max	57	52	59	46	47	51

13-jun	Prueba 10					
%	Compromiso	Entusiasmo	Interés	Relajación	Estrés	Concentración
Estado inicial (5 min)	61	57	72	33	39	60
Corrido	67	22	58	32	32	32
Salsa	67	39	59	37	64	55
Jazz	66	31	51	36	48	40
Electrónica	72	38	67	26	37	49
Disco	68	22	55	40	34	34
Clásica	65	50	60	28	45	63
Reggaetón	56	53	63	25	65	71
Champeta	64	37	59	32	44	51
Reggae	57	69	62	32	56	70
Flamenco	58	33	63	33	71	59
Indie	63	24	53	40	44	39
Hard Rock	53	58	66	55	50	58
Rock'n Roll	58	48	60	32	35	53
Min	53	22	51	25	32	32
Max	72	69	72	55	71	71

Algoritmo selector de música basado en método heurístico (Algoritmo básico)

```
1      %Autor: Melissa Carolina Paternina Jimenez
2      %Fecha: 09-10-2019
3
4      clear; clc;
5
6      global ch cl co di el fl hr in ja rg rt rr sa
7      ch=0;cl=0;co=0;di=0;el=0;fl=0;hr=0;in=0;ja=0;rg=0;rt=0;rr=0;sa=0;
8      A = [0.5 0.4 0.3 0.2 0.1 0];
9      M = [];
10     PROM_N = [];
11
12     load compromiso.mat
13
14     %-----PROMEDIOS-----%
15     CH = mean(compromiso(1, :)); %Champeta
16     CL = mean(compromiso(2, :)); %Clasica
17     CO = mean(compromiso(3, :)); %Corrido
18     DI = mean(compromiso(4, :)); %Disco
19     EL = mean(compromiso(5, :)); %Electronica
20     FL = mean(compromiso(6, :)); %Flamenco
21     HR = mean(compromiso(7, :)); %Hard Rock
22     IN = mean(compromiso(8, :)); %Andie
23     JA = mean(compromiso(9, :)); %Jazz
24     RG = mean(compromiso(10, :)); %Reggae
25     RT = mean(compromiso(11, :)); %Reggaeton
```

```

26 RR = mean(compromiso(12 ,:)); %Rock'n Roll
27 SA = mean(compromiso(13 ,:)); %Salsa
28
29 %          1  2  3  4  5  6  7  8  9 10 11 12 13
30 PromSN = [CH CL CO DI EL FL HR IN JA RG RT RR SA];
31
32 %-----NORMALIZACION-----%
33 MAX = PromSN(PromSN==max(PromSN));
34 MIN = PromSN(PromSN==min(PromSN));
35
36 for i = 1:13
37     Normz = (PromSN(i)-MIN)/(MAX-MIN);
38     PROM_N = [PROM_N, Normz];
39 end
40
41 PROMO = PROM_N;
42
43 for i = 1:13
44     pos = find(PROM_N==max(PROM_N));
45     M = [pos, M];
46     sel = PROM_N(pos);
47     n = contador(pos);
48     T = sum(n);
49     P = (sel*(1-(n(pos)/T)))-A(1);
50     PROM_N(pos) = P;
51     if i == 2
52         loc = M(end);
53         sel1 = PROMO(loc);
54         P = (sel1*(1-(n(loc)/T)))-A(2); %Ecuacion 5.5
55         PROM_N(loc) = P;
56     end
57     if i == 3
58         loc = M(end);
59         sel1 = PROMO(loc);
60         P = (sel1*(1-(n(loc)/T)))-A(3);
61         PROM_N(loc) = P;
62         loc1 = M(2);
63         sel2 = PROMO(loc1);
64         P = (sel2*(1-(n(loc1)/T)))-A(2);

```

```

65         PROM_N(loc1) = P;
66         end
67     if i == 4
68         loc = M(end);
69         sel1 = PROMO(loc);
70         P = (sel1*(1-(n(loc)/T)))-A(4);
71         PROM_N(loc) = P;
72         loc1 = M(2);
73         sel2 = PROMO(loc1);
74         P = (sel2*(1-(n(loc1)/T)))-A(2);
75         PROM_N(loc1) = P;
76         loc2 = M(3);
77         sel3 = PROMO(loc2);
78         P = (sel3*(1-(n(loc2)/T)))-A(3);
79         PROM_N(loc2) = P;
80     end
81     if i == 5
82         loc = M(end);
83         sel1 = PROMO(loc);
84         P = (sel1*(1-(n(loc)/T)))-A(5);
85         PROM_N(loc) = P;
86         loc1 = M(2);
87         sel2 = PROMO(loc1);
88         P = (sel2*(1-(n(loc1)/T)))-A(2);
89         PROM_N(loc1) = P;
90         loc2 = M(3);
91         sel3 = PROMO(loc2);
92         P = (sel3*(1-(n(loc2)/T)))-A(3);
93         PROM_N(loc2) = P;
94         loc3 = M(4);
95         sel4 = PROMO(loc3);
96         P = (sel4*(1-(n(loc3)/T)))-A(4);
97         PROM_N(loc3) = P;
98     end
99     if i == 6
100        loc = M(end);
101        sel1 = PROMO(loc);
102        P = (sel1*(1-(n(loc)/T)))-A(6);
103        PROM_N(loc) = P;

```

```

104         loc1 = M(2);
105         sel2 = PROMO(loc1);
106         P = (sel2*(1-(n(loc1)/T)))-A(2);
107         PROM_N(loc1) = P;
108         loc2 = M(3);
109         sel3 = PROMO(loc2);
110         P = (sel3*(1-(n(loc2)/T)))-A(3);
111         PROM_N(loc2) = P;
112         loc3 = M(4);
113         sel4 = PROMO(loc3);
114         P = (sel4*(1-(n(loc3)/T)))-A(4);
115         PROM_N(loc3) = P;
116         loc3 = M(5);
117         sel4 = PROMO(loc3);
118         P = (sel4*(1-(n(loc3)/T)))-A(5);
119         PROM_N(loc3) = P;
120     end
121 end
122
123 M = fliplr(M);
124
125 %-----ListName-----%
126 disp('LISTA_DE_CANCIONES:');
127 for i=1:13
128     switch M(i)
129         case 1
130             disp('Champeta');
131         case 2
132             disp('Clasica');
133         case 3
134             disp('Corrido');
135         case 4
136             disp('Disco');
137         case 5
138             disp('Electronica');
139         case 6
140             disp('Flamenco');
141         case 7
142             disp('Hard_Rock');

```

```
143         case 8
144             disp( 'Indie' );
145         case 9
146             disp( 'Jazz' );
147         case 10
148             disp( 'Reggae' );
149         case 11
150             disp( 'Reggaeton' );
151         case 12
152             disp( 'Rock_and_Roll' );
153         case 13
154             disp( 'Salsa' );
155     end
156 end
```

Tablas de pruebas de validación

F.0.1. Algoritmo básico

Género	Prueba 1	Prueba 2	Prueba 3
Inicial	45	45	49
Corrido	41	53	50
Salsa	60	60	45
Hard Rock	44	51	51
Electrónica	50	50	45
Reggae	52	52	50
Disco	42	55	55
Corrido	45	50	53
Salsa	45	53	53
Indie	50	50	48
Hard Rock	55	54	55
Rock and Roll	54	54	55
Electrónica	50	50	46
Jazz	44	51	51

F.0.2. Algoritmo SVM

Género con su número	
Inicial	2
Champeta	3
Clásica	4
Corrido	5
Disco	6
Electrónica	7
Flamenco	8
Hard Rock	9
Indie	10
Jazz	11
Reggae	12
Reggaetón	13
Rock'n Roll	14
Salsa	15

No. de pruebas	Tipo de música	Estado actual	Estado anterior	Tipo de música anterior	Predicción
Prueba 1	10	42	47	2	15 (Salsa)
Prueba 2	15	44	42	10	12 (Reggae)
Prueba 3	12	49	44	15	13 (Reggaetón)
Prueba 4	13	63	49	12	15 (Salsa)
Prueba 5	15	56	63	13	12 (Reggae)
Prueba 6	12	40	56	15	9 (Hard Rock)
Prueba 7	9	43	40	12	13 (Reggaetón)
Prueba 8	13	38	43	9	5 (Corrido)
Prueba 9	5	58	38	13	12 (Reggae)
Prueba 10	12	36	58	5	5 (Corrido)
Prueba 11	5	45	36	12	15 (Salsa)
Prueba 12	15	46	45	5	7 (Electrónica)
Prueba 13	7	53	46	15	14 (Rock'n Roll)

Datos para el algoritmo SVM

Tipo de música actual	Estado actual	Estado anterior	Tipo de música anterior	Est.	Clases
3	56	73	2	-1	15
3	66	64	2	1	3
3	33	41	2	-1	9
3	55	43	2	1	3
3	47	51	2	-1	15
3	43	50	10	-1	10
3	53	35	2	1	3
3	41	41	14	0	14
3	35	44	15	-1	15
3	49	51	10	-1	10
3	46	46	2	0	14
3	53	46	2	1	3
3	44	38	2	1	3
3	34	45	2	-1	9
3	36	51	2	-1	5
3	42	44	6	-1	6
4	53	56	3	-1	3
4	55	66	3	-1	3
4	42	33	3	1	4
4	53	55	3	-1	3
4	47	47	3	0	12
4	53	49	6	1	4
4	43	50	14	-1	14

Sigue en la página siguiente.

Tipo de música actual	Estado actual	Estado anterior	Tipo de música anterior	Est.	Clases
4	35	45	7	-1	7
4	43	44	6	-1	6
4	46	49	9	-1	9
4	45	46	3	-1	3
4	52	53	3	-1	3
4	38	44	3	-1	3
4	46	34	3	1	4
4	41	36	3	1	4
4	51	41	14	1	4
5	56	53	4	1	5
5	65	55	4	1	5
5	55	42	4	1	5
5	61	53	4	1	5
5	41	47	4	-1	4
5	51	47	12	1	5
5	62	54	7	1	5
5	41	35	4	1	5
5	52	49	12	1	5
5	66	46	4	1	5
5	52	45	4	1	5
5	61	52	4	1	5
5	60	38	4	1	5
5	46	46	4	0	5
5	51	41	4	1	5
5	39	38	13	1	5
6	56	56	5	0	5
6	64	65	5	1	6
6	44	55	5	-1	5
6	49	61	5	-1	5
6	54	41	5	1	6

Sigue en la página siguiente.

Tipo de música actual	Estado actual	Estado anterior	Tipo de música anterior	Est.	Clases
6	49	40	14	1	6
6	50	63	13	-1	13
6	55	43	10	1	6
6	44	52	5	-1	5
6	49	49	3	0	7
6	49	52	5	-1	5
6	46	61	5	-1	5
6	53	60	5	-1	5
6	46	46	5	0	7
6	61	51	5	1	6
6	44	51	10	-1	10
7	31	56	6	-1	6
7	60	64	6	-1	6
7	43	44	6	-1	6
7	48	49	6	-1	6
7	55	54	6	1	7
7	61	44	11	1	7
7	54	55	10	-1	10
7	45	46	9	-1	9
7	47	46	8	1	8
7	46	51	15	-1	15
7	48	49	6	-1	6
7	53	46	6	1	7
7	47	53	6	-1	6
7	69	56	6	1	7
7	51	61	6	-1	6
7	50	42	3	1	7
8	43	31	7	1	8
8	56	60	7	-1	7
8	44	43	7	1	8

Sigue en la página siguiente.

Tipo de música actual	Estado actual	Estado anterior	Tipo de música anterior	Est.	Clases
8	53	48	7	1	8
8	31	55	7	-1	7
8	53	41	9	1	8
8	48	50	6	-1	6
8	35	41	5	-1	5
8	46	43	4	1	8
8	44	49	6	-1	6
8	47	48	7	-1	7
8	59	53	7	1	8
8	37	47	7	-1	7
8	64	69	7	-1	7
8	52	51	7	1	8
8	40	51	2	-1	15
9	68	43	8	1	9
9	56	56	8	0	9
9	45	44	8	1	9
9	52	53	8	-1	8
9	33	31	8	1	9
9	41	45	13	-1	13
9	60	62	5	-1	5
9	46	55	6	-1	6
9	56	54	11	1	9
9	49	50	13	-1	13
9	46	47	8	-1	8
9	69	59	8	1	9
9	49	37	8	1	9
9	65	64	8	1	9
9	55	52	8	1	9
9	54	50	7	1	9
10	70	68	9	1	10

Sigue en la página siguiente.

Tipo de música actual	Estado actual	Estado anterior	Tipo de música anterior	Est.	Clases
10	62	56	9	1	10
10	35	45	9	-1	9
10	55	52	9	1	10
10	37	33	9	1	10
10	50	61	7	-1	7
10	55	63	12	-1	12
10	43	41	3	1	10
10	42	31	13	1	10
10	51	46	7	1	10
10	54	46	9	1	10
10	49	69	9	-1	9
10	36	49	9	-1	9
10	69	65	9	1	10
10	45	55	9	-1	9
10	51	51	4	0	10
11	71	70	10	1	11
11	62	62	10	0	10
11	40	35	10	1	11
11	45	55	10	-1	10
11	44	37	10	1	11
11	44	51	5	-1	5
11	53	59	15	-1	15
11	39	52	13	-1	13
11	54	51	14	1	11
11	55	66	5	-1	5
11	50	54	10	-1	10
11	50	49	10	1	11
11	39	36	10	1	11
11	45	69	10	-1	10
11	54	45	10	1	11

Sigue en la página siguiente.

Tipo de música actual	Estado actual	Estado anterior	Tipo de música anterior	Est.	Clases
11	36	39	5	-1	5
12	65	71	11	-1	11
12	65	62	11	1	12
12	59	40	11	1	12
12	54	45	11	1	12
12	59	44	11	1	12
12	47	53	4	-1	4
12	63	53	3	1	12
12	54	39	11	1	12
12	49	46	2	1	12
12	57	55	11	1	12
12	45	50	11	-1	11
12	47	50	11	-1	11
12	44	39	11	1	12
12	48	45	11	1	12
12	45	54	11	-1	11
12	45	36	11	1	12
13	57	65	12	-1	12
13	56	65	12	-1	12
13	44	59	12	-1	12
13	60	54	12	1	13
13	53	59	12	-1	12
13	45	51	2	-1	15
13	63	43	4	1	13
13	52	51	15	1	13
13	31	35	3	-1	3
13	50	47	14	1	13
13	44	45	12	-1	12
13	37	47	12	-1	12
13	37	44	12	-1	12

Sigue en la página siguiente.

Tipo de música actual	Estado actual	Estado anterior	Tipo de música anterior	Est.	Clases
13	54	48	12	1	13
13	48	45	12	1	13
13	38	40	8	-1	8
14	72	57	13	1	14
14	57	56	13	1	14
14	56	44	13	1	14
14	47	60	13	-1	13
14	43	53	13	-1	13
14	40	47	15	-1	15
14	50	53	11	-1	11
14	41	52	2	-1	2
14	51	47	7	1	14
14	47	44	8	1	14
14	32	44	13	-1	13
14	61	37	13	1	14
14	44	37	13	1	14
14	56	54	13	1	14
14	47	48	13	-1	13
14	41	39	15	1	14
15	55	72	14	-1	14
15	69	57	14	1	15
15	59	56	14	1	15
15	60	47	14	1	15
15	49	43	14	1	15
15	47	53	8	-1	8
15	59	60	9	-1	9
15	51	35	8	1	15
15	44	56	9	-1	9
15	51	45	2	1	15
15	38	32	14	1	15

Sigue en la página siguiente.

Tipo de música actual	Estado actual	Estado anterior	Tipo de música anterior	Est.	Clases
15	74	61	14	1	15
15	47	44	14	1	15
15	61	56	14	1	15
15	58	47	14	1	15
15	39	45	12	-1	12
3	36	32	13	1	3
3	53	55	13	-1	10
3	56	57	8	-1	5
3	64	56	13	1	3
4	46	43	9	1	4
4	44	43	11	1	4
4	27	53	13	-1	15
4	65	68	6	-1	5
5	35	46	4	-1	9
5	46	39	14	1	5
5	54	47	9	1	5
5	67	61	2	1	5
6	46	54	14	-1	10
6	50	53	3	-1	5
6	39	44	10	-1	9
6	68	72	7	-1	10
7	56	46	6	1	7
7	51	44	8	1	7
7	42	43	2	-1	3
7	72	66	11	1	7
8	35	35	5	0	5
8	44	46	12	-1	9
8	57	54	5	1	8
8	58	57	12	1	8
9	43	36	3	1	9

Sigue en la página siguiente.

Tipo de música actual	Estado actual	Estado anterior	Tipo de música anterior	Est.	Clases
9	54	51	7	1	9
9	47	47	15	0	13
9	53	63	10	-1	12
10	42	35	8	1	10
10	52	54	9	-1	10
10	44	56	3	-1	5
10	63	58	8	1	10
11	38	41	2	-1	5
11	43	37	15	1	11
11	42	36	14	1	11
11	66	67	15	-1	10
12	41	38	15	1	12
12	46	44	4	1	12
12	37	39	6	-1	5
12	57	64	3	-1	5
13	32	38	11	-1	9
13	55	52	10	1	13
13	53	42	7	1	12
13	56	65	4	-1	5
14	54	41	12	1	12
14	39	50	6	-1	9
14	36	27	4	1	10
14	58	53	9	1	9
15	38	42	10	-1	12
15	37	43	2	-1	5
15	47	42	11	1	12
15	67	67	5	0	10