

---

Predicción de la calificación de música basada en el  
análisis de estados afectivos derivados de señales  
EEG



Tesis de Pregrado en Ingeniería Electrónica y Telecomunicaciones

**Jesús Eduardo Muñoz García**

Director: PhD. Juan Carlos Corrales Muñoz

Asesor: MSc. Luis Antonio Rojas Potosí

*Universidad del Cauca*

Facultad de Ingeniería Electrónica y Telecomunicaciones

Popayán, Abril 2016



# Índice general

<b>I</b>	<b>Introducción</b>	<b>1</b>
<b>1.</b>	<b>Introducción</b>	<b>2</b>
1.1.	Contexto de investigación . . . . .	3
1.2.	Motivación . . . . .	5
1.3.	Premisas e Hipótesis . . . . .	6
1.3.1.	Premisas . . . . .	6
1.3.2.	Hipótesis . . . . .	7
1.4.	Objetivos . . . . .	7
1.4.1.	Objetivo General . . . . .	7
1.4.2.	Objetivos Específicos . . . . .	7
1.5.	Alcance . . . . .	8
1.6.	Contribuciones y Principales Resultados . . . . .	8
1.6.1.	Contribuciones Directas . . . . .	8
1.6.2.	Contribuciones Indirectas . . . . .	9
1.7.	Contenido de la Monografía . . . . .	9
1.7.1.	Parte 1. Introducción . . . . .	9
1.7.2.	Parte 2. Propuesta . . . . .	10
1.7.3.	Parte 3. Experimentación y resultados . . . . .	10
<b>2.</b>	<b>Estado Actual del Conocimiento</b>	<b>11</b>
2.1.	Reconocimiento de Emociones . . . . .	11
2.1.1.	Definición de Emoción . . . . .	11
2.1.2.	Detección de emociones mediante la captura de señales biológicas	13
2.1.3.	Uso de señales EEG para la detección de emociones . . . . .	14
2.1.3.1.	Emotiv Insight . . . . .	15
2.2.	Sistemas de Recomendación de Música . . . . .	18
2.2.1.	Técnicas de agregación de información . . . . .	20
2.2.1.1.	Técnicas demográficas . . . . .	20
2.2.1.2.	Técnicas basadas en contenido acústico . . . . .	20
2.2.1.3.	Técnicas basadas en minería de la Web y contexto textual . . . . .	21
2.2.1.4.	Técnicas de Filtrado Colaborativo . . . . .	22
2.2.2.	Comparación de técnicas de agregación . . . . .	22
2.2.3.	Filtrado Colaborativo . . . . .	25
2.2.3.1.	Captura/inferencia de calificaciones . . . . .	25

## ÍNDICE GENERAL

---

2.2.3.2.	Definición de la vecindad de usuarios . . . . .	25
2.2.3.3.	Predicción de calificaciones . . . . .	26
2.2.3.4.	Presentación de la recomendación . . . . .	26
2.3.	Trabajos Relacionados . . . . .	26
2.3.1.	Trabajos relacionados con la recomendación de música basada en emociones . . . . .	27
2.3.2.	Reconocimiento de emociones a partir de señales EEG y su aplicación en el campo de la recomendación de música . . . . .	28
2.3.3.	Brechas existentes . . . . .	30
<b>II</b>	<b>Propuesta</b>	<b>33</b>
<b>3.</b>	<b>Captura y análisis de respuestas emocionales basadas en EEG</b>	<b>34</b>
3.1.	Proceso de análisis . . . . .	35
3.2.	Detección de emociones . . . . .	36
3.2.1.	Método de captura . . . . .	36
3.2.2.	Descripción de los datos . . . . .	37
3.2.3.	Exploración de datos . . . . .	39
3.3.	Etiquetado de canciones usando información emocional . . . . .	40
3.4.	Resumen . . . . .	42
<b>4.</b>	<b>Vecindad de usuarios y predicción</b>	<b>43</b>
4.1.	Vecindad . . . . .	43
4.1.1.	Vecindad tradicional . . . . .	43
4.1.2.	Vecindad emocional . . . . .	45
4.1.2.1.	Factor de similitud utilizando descripción de señal emocional. . . . .	45
4.1.2.2.	Factor de similitud usando $P_i$ . . . . .	47
4.2.	Predicción . . . . .	49
4.2.1.	Predicción basada en calificaciones ponderadas . . . . .	49
4.2.2.	Predicción mediante vecindades basadas en información emocional . . . . .	50
4.2.2.1.	Predicción por correlación promedio de señales emocionales $a_i$ . . . . .	50
4.2.2.2.	Predicción por correlación de señales emocionales $a_i$ agregadas. . . . .	51
4.2.2.3.	Predicción por puntaje emocional $P_i$ . . . . .	52
4.3.	Resumen . . . . .	53
<b>III</b>	<b>Experimentación y resultados</b>	<b>55</b>
<b>5.</b>	<b>Descripción de la solución</b>	<b>56</b>
5.1.	Metodologías utilizadas . . . . .	56

5.1.1.	Scrum . . . . .	56
5.1.1.1.	Flujo de trabajo . . . . .	57
5.1.1.2.	Adaptación . . . . .	58
5.1.2.	View and Beyond (V&B) . . . . .	59
5.2.	Vistas del sistema . . . . .	59
5.2.1.	Módulos . . . . .	59
5.2.1.1.	Catálogo de componentes . . . . .	60
5.2.1.2.	Guía de Variabilidad . . . . .	62
5.2.1.3.	Decisiones arquitecturales y de implementación . . .	62
5.2.2.	Estilo de Componentes y Conectores . . . . .	63
5.2.2.1.	Cliente - Servidor BraiM . . . . .	63
5.2.2.2.	Catálogo de componentes . . . . .	64
5.2.2.3.	Guía de variabilidad . . . . .	65
5.2.2.4.	Decisiones arquitecturales y de Implementación . . .	65
5.2.3.	Estilo de asignación . . . . .	66
5.2.3.1.	Vista de despliegue . . . . .	66
5.2.3.2.	Catálogo de elementos . . . . .	67
5.2.3.3.	Decisiones arquitecturales y de implementación . . .	68
5.2.3.4.	Relación entre vistas . . . . .	68
5.3.	Resumen . . . . .	68
<b>6.</b>	<b>Experimentación y evaluación</b>	<b>70</b>
6.1.	Metodología . . . . .	70
6.1.1.	Planeación del experimento . . . . .	70
6.1.1.1.	Definición del objetivo . . . . .	70
6.1.1.2.	Hipótesis . . . . .	70
6.1.1.3.	Selección de variables . . . . .	71
6.1.1.4.	Selección de los sujetos . . . . .	71
6.1.1.5.	Objetos Experimentales . . . . .	71
6.1.2.	Métricas de evaluación . . . . .	72
6.1.2.1.	MAE (Mean absolute Error) . . . . .	72
6.1.3.	Plan de ejecución de pruebas y resultados . . . . .	73
6.1.3.1.	Captura de datos . . . . .	73
6.1.3.2.	Plan de pruebas - MAE . . . . .	74
6.1.4.	Resultados . . . . .	74
6.1.5.	Resumen . . . . .	77
<b>7.</b>	<b>Conclusiones y trabajos futuros</b>	<b>78</b>
7.1.	Conclusiones . . . . .	78
7.2.	Restricciones . . . . .	79
7.3.	Trabajos futuros . . . . .	80

## ÍNDICE GENERAL

---

<b>A. Modelo de diseño de BraiM - Interfaz de usuario</b>	<b>87</b>
A.1. Registro y sesión de usuarios . . . . .	87
A.2. Configuración Emotiv Insight . . . . .	89
A.3. Búsqueda de canciones . . . . .	89
A.4. Reproducción y captura de emociones . . . . .	91
A.5. Sesión de pruebas y recolección de datos . . . . .	92
A.6. Recomendación de música . . . . .	93

# Índice de figuras

2.1. Diagrama Valence - Arousal <a href="#">Kim et al. (2010)</a> . . . . .	12
2.2. Estándar EEG 10-20 . . . . .	14
2.3. Emotiv Insight . . . . .	19
3.1. Estados afectivos detectados por Emotiv: Performance Metrics Suite	38
3.2. Factor de correlación de Pearson entre variables emocionales . . . . .	39
3.3. Señales capturadas por BraiM . . . . .	41
3.4. Calificación emocional mediante reducción a un valor . . . . .	42
5.1. Vista del Sprint . . . . .	58
5.2. Vista de descomposición del sistema . . . . .	60
5.3. Vista Call-Return (Arquitectura general del sistema) . . . . .	63
5.4. Vista de despliegue del sistema . . . . .	67
6.1. Sesiones de prueba . . . . .	73
6.2. Resultados MAE . . . . .	75
A.1. Interfaz gráfica - Inicio de sesión . . . . .	87
A.2. Interfaz gráfica - Registro Básico . . . . .	88
A.3. Interfaz gráfica - Recobrar contraseña . . . . .	88
A.4. Configuración Emotiv Insight . . . . .	89
A.5. Interfaz gráfica - Consulta de canciones y artistas . . . . .	90
A.6. Interfaz gráfica - Historial de usuario . . . . .	90
A.7. Interfaz gráfica - Reproducciones de otros usuarios . . . . .	91
A.8. Interfaz gráfica - Reproducción y calificación de música . . . . .	91
A.9. Interfaz gráfica - Registros detectados por Emotiv Insgiht para una canción . . . . .	92
A.10. Interfaz gráfica - Sesión de pruebas . . . . .	92
A.11. Interfaz gráfica - Sesión de pruebas - calificación . . . . .	93
A.12. Interfaz gráfica - Recomendación básica de canciones . . . . .	93

## ÍNDICE DE FIGURAS

---



Parte I  
Introducción

# Capítulo 1

## Introducción

La música juega un papel muy importante en la vida de las personas, siendo una de las expresiones artísticas más populares a lo largo de la historia. Debido a esto, la forma en que ha sido compartida, almacenada o distribuida cambia constantemente y va a la vanguardia de los continuos avances tecnológicos, especialmente desde que empezó a ser digitalizada en 1991 [Kaminskas and Ricci \(2012a\)](#). Hoy en día es muy común encontrar en la Web bibliotecas musicales que suponen decenas de terabytes de información, sin embargo, para el usuario resulta abrumador encontrar contenido acorde a sus gustos debido a la gran cantidad de opciones disponibles. Por esta razón los Sistemas de Recomendación de Música (SRM) son una herramienta tecnológica de gran utilidad, demandada por el potencial que representa la música online [Celma Herrada \(2009\)](#), [Song et al. \(2012a\)](#).

El objetivo de un SRM es mejorar la experiencia del usuario sugiriendo canciones que considera de alta relevancia para él, utilizando distintas técnicas. Sitios web como Pandora<sup>1</sup> o Last FM<sup>2</sup>, por ejemplo, se basan en el análisis de patrones de consumo (ratings/ like-dislike) y recomiendan canciones similares mediante recuperación de información musical (MIR)<sup>3</sup>. Sin embargo estos sistemas tradicionalmente ignoran los efectos emocionales que la música produce en el usuario [Typke et al. \(2005\)](#).

La música en sí misma es considerada como una expresión de emociones o estados afectivos<sup>4</sup> debido a la naturaleza que tiene este tipo de contenido; así que detectar emociones mientras el usuario escucha una canción es uno de los aspectos más interesantes y de mayor potencial para el desarrollo de nuevos y mejores servicios de recomendación de música [Kim et al. \(2010\)](#). Uno de los enfoques más recientes propone el uso de información emocional derivada de señales electroencefalográficas (EEG), puesto que, la aparición en el mercado de interfaces cerebro-computador de bajo costo completamente asequibles al público en general ha ampliado en forma radical el

---

<sup>1</sup><http://www.pandora.com>

<sup>2</sup><http://www.last.fm>

<sup>3</sup>Music Information Retrieval, por sus siglas en inglés

<sup>4</sup>Estados afectivos y emociones son definiciones intercambiables en este trabajo de investigación

campo de aplicación de esta tecnología, no solo en temas relacionados con la medicina [Bos \(2006\)](#), [Thompson et al. \(2008\)](#), [Koelstra et al. \(2012\)](#).

Este trabajo de grado está enfocado en el análisis de información sobre estados afectivos derivados de señales EEG aplicado a la predicción de calificaciones de música; proponiendo la captura de reacciones emocionales del usuario usando un dispositivo EEG de bajo costo, con el fin de encontrar usuarios similares y calcular su preferencia por una canción desconocida.

Este documento sintetiza el trabajo de grado "Predicción de la calificación de música basada en el análisis de estados afectivos derivados de señales EEG", presentando un nuevo mecanismo para la inclusión de información emocional sobre estados afectivos en sistemas de predicción de calificación de música (Capítulo 3). Este mecanismo se validó mediante la implementación de una herramienta denominada BraiM ("Brain Music") que utiliza el sistema de predicción propuesto para recomendar música. A diferencia de lo encontrado en el estado del arte (Capítulo 2), esta aproximación considera en el cálculo de la similitud de usuarios la inclusión de datos de variables continuas, en este caso asociadas con estados afectivos de los mismos (Capítulo 5). Los resultados del análisis sobre la similitud de usuarios y predicción de calificación de canciones, permiten entender más sobre nuevas maneras de relacionar contenido musical a través de la respuesta emocional que genera en el usuario, abriendo la puerta a la exploración de esta temática de investigación en la Universidad del Cauca. A continuación, este capítulo presenta de manera general el trabajo realizado, describiendo su contexto, enfoque y resultados.

### 1.1. Contexto de investigación

Dada la cantidad creciente de recursos en internet, los sistemas de recomendación (SR) se han convertido en herramientas indispensables, combinando técnicas y herramientas software que proveen sugerencias de ítems útiles para los usuarios [Maes \(1994\)](#), [Ricci et al. \(2011\)](#). La música, en particular, es uno de los campos en los que más se hace necesario los SR, puesto que existen librerías de canciones que crecen diariamente de manera exponencial, producto de continuos avances tecnológicos en redes, almacenamiento, portabilidad y servicios de Internet [Celma Herrada \(2009\)](#). Los primeros SRM aparecieron a principios de los años 90. Hoy en día, aún presentan grandes desafíos y su complejidad ha llevado al desarrollo de muchos estudios que buscan comprender cómo funciona la percepción humana al escucharla para generar mejores recomendaciones, teniendo en cuenta un sinnúmero de factores como la edad, el género, estado de ánimo, etc [Kaminskas and Ricci \(2012a\)](#).

Existe una estrecha relación entre la música y las emociones, por esta razón, encontrar mecanismos que permitan asociar emociones a una canción trae consigo grandes beneficios al momento de realizar una recomendación personalizada. Por ejemplo, el usuario puede recibir sugerencias de acuerdo a su contexto emocional, encontrar una

lista de reproducción pensada para mejorar el estado de animo en estados de frustración o por el contrario evitar estados de extrema relajación cuando necesita estar en alerta al manejar un automóvil o monitorear un tarea de gran importancia. El etiquetado por expertos ('human annotation') [Turnbull et al. \(2008\)](#), ha sido uno de los primeros intentos por recolectar información sobre contenido emocional en la música, no obstante es una actividad manual que requiere una inversión de tiempo y dinero considerable. Los tags sociales y los juegos de anotación son aproximaciones que buscan involucrar a los usuarios del sistema para etiquetar las canciones [Von Ahn \(2006\)](#), sin embargo, presentan una serie de problemas como el "arranque en frío", cuando existen muy pocos tags o cuando sólo los ítems más populares los reciben, y los "tags maliciosos" que pueden presentarse por parte de algunos usuarios. Otro de los enfoques más populares es el etiquetado automático, que nace debido a los problemas de escalabilidad del etiquetado por parte de expertos, y utiliza una serie mecanismos para clasificar la música identificando características acústicas en la señal de audio como el tempo<sup>5</sup>, armonía<sup>6</sup>, o timbre<sup>7</sup>, que según estudios pueden influenciar distintas emociones en el ser humano [Pohle et al. \(2005\)](#), [Mion and Poli \(2008\)](#), [Neumayer and Rauber \(2008\)](#). Si bien los esfuerzos mencionados anteriormente permiten hacer una aproximación generalizada a la detección de emociones en la música, esta continúa siendo una tarea bastante subjetiva dado a que cada persona percibe las emociones en una forma diferente. Autores como [Kim et al. \(2010\)](#), expresan la necesidad de sistemas realmente personalizados que involucren la colaboración de investigadores en campos como la psicología y la neurociencia para comprender cómo responde el ser humano emocionalmente ante la música y mas aún como funcionan las emociones en general.

Como podemos apreciar involucrar el estado de animo del usuario es uno de los enfoques más importantes en el desarrollo SRM en la actualidad, sin embargo es difícil reflejar los sutiles aspectos involucrados en las emociones humanas. El presente trabajo de grado está enfocado en el estudio de información emocional proporcionada por un dispositivo EEG de bajo costo, mientras el usuario se encuentra escuchando una pieza musical. Entre los dispositivos para la captura y análisis de señales EEG presentes en el mercado actual se destaca Emotiv Insight, producido por la empresa australiana Emotiv systems <sup>8</sup>, que ofrece información de alta resolución mediante la utilización de 5 canales EEG y un clasificador previamente entrenado que puede usarse para detectar estados afectivos como: compromiso, excitación a corto plazo, excitación a largo plazo, concentración, interés y relajación. Además, se define un factor de similitud entre usuarios utilizando la información emocional recolectada, y se analizan los efectos de la técnica de similitud propuesta sobre la predicción de la apreciación del usuario con respecto a una canción en particular, utilizando una aproximación "off line". [Herlocker et al. \(2000, 2004\)](#). Este tipo de técnica de

---

<sup>5</sup>Hace referencia a la velocidad de una pieza musical, o con la cual debe ser ejecutada.

<sup>6</sup>El uso de múltiples tonos, acordes o notas musicales.

<sup>7</sup>Propiedad de los sonidos asociada a su posición en una escala de frecuencia. En la música hace referencia a que tan "alta" o "baja" es una nota en particular [Sadie \(2001\)](#).

<sup>8</sup><https://emotiv.com/>

evaluación está basada en el estudio de un conjunto de datos reales previamente recolectados, brindando una visión general del desempeño del sistema sin la necesidad de la respuesta del usuario ante la recomendación. Lo anterior conduce a la siguiente pregunta de investigación.

**¿El estimar la similitud de usuarios mediante el análisis de sus respuestas emocionales tiene algún impacto sobre la calidad de predicción de un SRM?**

En este sentido, el presente trabajo profundiza sobre esta pregunta de investigación por medio de un estudio de la relación entre las emociones de los usuarios y sus preferencias musicales, el cual considera la definición de una medida de similitud basada en información emocional derivada de señales EEG.

## 1.2. Motivación

Los SRM juegan un papel importante en la industria musical de la actualidad, esto se debe a que los servicios de música digital atraen un número de usuarios que crece diariamente y acercan a los artistas a un público mucho más amplio, permitiéndoles crear contenido que luego pueden publicitar y distribuir fácilmente a través de la red. El reporte anual que realiza la Federación Internacional de la Industria Fonográfica (IFPI por sus siglas en inglés) <sup>9</sup>, indica que en el año 2014 las ventas de música en formato digital equivalían al 39% de los ingresos totales de la industria a nivel mundial. Por esta razón empresas líderes en el servicio de streaming de música, como Spotify, Deezer, Beats y Music Sony han invertido grandes esfuerzos brindar mejores y más inteligentes servicios de recomendación. Sin embargo, la mayoría de estas recomendaciones ignoran los efectos emocionales de la música en los usuarios y son ellos mismos quienes evalúan de forma manual el contenido incluyendo feedback adicional. Este trabajo se enfoca en el uso un dispositivo EEG para obtener información emocional de primera mano sobre los usuarios, con el objetivo de mejorar su experiencia al escuchar y descubrir nuevas canciones. El trabajo de [Guo et al. \(2012a\)](#) demuestra que este tipo de tecnología no debería limitarse únicamente al campo de la medicina, puesto que estos dispositivos ahora son fácilmente accesibles al público en general. Además, el desarrollo de aplicaciones utilizando estos dispositivos mediante una arquitectura Cliente-Servidor permite que se puedan utilizar en cualquier computador o dispositivo móvil y propician un entorno adecuado para su masificación.

El presente trabajo de investigación explora la comparación de usuarios basados en sus respuestas emocionales para construir sistemas de recomendación de música. En este sentido, se construyó la plataforma cliente-servidor denominada BraiM. Está pensada como una alternativa adecuada para la creación de estos servicios, permitiendo exponer a los usuarios a un estímulo en particular, que en este caso es música, para

---

<sup>9</sup><http://www.ifpi.org/>

después procesar esta información del lado del servidor. La información obtenida por la plataforma puede ser utilizada para construir soluciones en distintos campos, además, se obtienen grandes beneficios ante la dificultad identificada para llevar a cabo esta clase de estudios en entornos escalables.

Imaginemos por un momento el siguiente escenario propuesto en un futuro muy cercano: Alice es un usuario de un dispositivo EEG de bajo costo que compró a través de una tienda online. Este dispositivo es bastante cómodo y puede caminar por la calle con él; se comunica a Internet y tiene a su disposición gran cantidad de aplicaciones open source desarrolladas por la comunidad, además, sirve como sujetador de cabello. Entre las distintas aplicaciones descargadas, Alice utiliza un sistema de recomendación de música basada en el estudio de sus respuestas emocionales, el cual compara sus resultados con los de otros usuarios y está sincronizado con el reproductor de su dispositivo móvil. El sistema tiene la capacidad de encontrar “parejas-emocionales”, que se comportan de una forma muy parecida a Alice y que han escuchado canciones que ella desconoce. Este sistema puede recomendarle esas canciones, incluso recomendar conocer a un usuario en particular que parece ser su pareja ideal, Bob. Así Bob y Alice se conocen y comparten sus gusto por la música, que como sabemos está muy ligada a sus emociones, compartiendo grandes intereses.

### 1.3. Premisas e Hipótesis

Esta sección presenta la forma en que este trabajo i) apropia las aproximaciones de los principales trabajos de investigación en esta área y ii) propone un nuevo enfoque para aportar en este dominio.

#### 1.3.1. Premisas

A continuación se presentan las principales premisas que soportan este proyecto de investigación, fundamentada en los trabajos de investigación más importantes que están relacionados con la temática de esta monografía. Un análisis más detallado de estos trabajos, se encuentra en el capítulo dedicado al estado actual del conocimiento (Capítulo 2).

- **P1. La música tiene influencia directa sobre el estado emocional del usuario, el cual puede medirse mediante el seguimiento de su actividad cerebral, además posee características que permiten alterar y manipular las emociones humanas.** Estudios como el de Blood et al. [Blood and Zatorre \(2001\)](#) se basan en el seguimiento de la actividad cerebral del usuario mientras está expuesto a un estímulo musical, demostrando que se registran cambios en el flujo sanguíneo del cerebro en regiones involucradas con respuestas emocionales como relajación o excitación. Este tipo de actividad también se registra cuando la persona está expuesta a estímulos como las drogas, el sexo o la comida, permitiendo establecer una relación directa entre la música y este tipo de respuestas biológicas [Le \(2010a\)](#).

- **P2. Los sistemas de recomendación que utilizan enfoques colaborativos, se ven beneficiados mediante la inclusión de feedback implícito obtenido al estudiar el comportamiento del usuario.** Trabajos de investigación en múltiples dominios demuestran el efecto positivo que tiene el incluir información contextual sobre los usuarios para calcular vecindades con características similares y hacer mejores recomendaciones [Adomavicius and Tuzhilin \(2011\)](#) [Le \(2010a\)](#); [Kaminskas and Ricci \(2012a\)](#). Además, el uso de fuentes alternativas de información sobre usuarios e ítems permite mitigar los problemas asociados a este enfoque de predicción, relacionados con el “arranque en frío”, cuando muy pocos ítems en el sistema cuenta con feedback relevante para que puedan ser recomendados.

### 1.3.2. Hipótesis

Este trabajo de grado está enfocado en la exploración de la pregunta de investigación presentada en la sección 1.1, utilizando un aproximación que está determinada por la siguiente hipótesis:

- **H1.** El estimar la similitud de usuarios mediante el análisis de sus respuestas emocionales EEG tiene impacto positivo sobre la calidad de predicción de un SRM. Esta hipótesis se basa en los antecedentes entregados por la premisa P1, la cual demuestra la correspondencia entre la música y las emociones humanas. El aporte de esta hipótesis consiste en fundamentar la técnica de recomendación propuesta en este proyecto, proponiendo un escenario en el que si dos usuarios tienen respuestas emocionales similares por ende sus hábitos de escucha están relacionados de forma directa, para ello se utiliza un proceso de análisis y modelamiento de un fenómeno real utilizando una plataforma que permite a los usuarios escuchar música mientras utilizan un dispositivo EEG.

## 1.4. Objetivos

Una vez expuesto el enfoque de este proyecto, se presentan los objetivos de investigación que representan la exploración de las hipótesis planteadas previamente.

### 1.4.1. Objetivo General

Generar un sistema de predicción de preferencia de canciones basado en el análisis de las respuestas emocionales del usuario obtenidas gracias al monitoreo de su actividad cerebral utilizando un dispositivo EEG.

### 1.4.2. Objetivos Específicos

- Proponer una técnica de similitud entre usuarios basada en la comparación de sus respuestas emocionales al momento de escuchar música.

- Implementar un mecanismo de predicción que utilice la técnica de similitud de usuarios propuesta.
- Evaluar mediante un prototipo experimental la precisión del mecanismo de predicción.

### 1.5. Alcance

Esta tesis de pregrado está enmarcada en el área de SRM. Su alcance está limitado por las siguientes consideraciones.

- El proyecto se enfoca en la etapa de predicción de preferencia de canciones pero no considera el proceso de recomendación directa al usuario.
- La información necesaria para el proceso de experimentación fue recolectada en un entorno de pruebas compuesto por estudiantes de la Universidad del Cauca con edades entre los 18 y 30 años; utilizando la plataforma BraiM desarrollada para este proyecto de investigación y que permite la captura de emociones a partir de señales EEG cuando el usuario está expuesto al estímulo musical.
- El foco de esta investigación no es la clasificación de emociones, para ello se utiliza información emocional que podemos obtener gracias al dispositivo Emotiv Insight, el cual cuenta con un clasificador previamente entrenado que permite detectar 5 estados afectivos: compromiso, interés, excitación a corto plazo, excitación a largo plazo y relajación. [Radinsky et al. \(2011b\)](#) y [Guo et al. \(2012b\)](#) soportan la utilización de estos datos para experimentación en aplicaciones de entretenimiento.
- El sistema de predicción a ser generado corresponde a un prototipo experimental, enfocado en el análisis de la información obtenida utilizando la herramienta BraiM.

### 1.6. Contribuciones y Principales Resultados

Como resultado después de realizada exploración de las hipótesis formuladas anteriormente, este trabajo de grado realizó las siguientes contribuciones.

#### 1.6.1. Contribuciones Directas

- Un análisis de las respuestas emocionales de los usuarios y su relación con sus preferencias musicales (Capítulo 3). Además se define una técnica para calcular similitud entre usuarios basada en el análisis de sus respuestas emocionales derivadas de señales EEG.



- Un prototipo experimental para la predicción de la preferencia de canciones basado en el análisis del comportamiento emocional de los usuarios. (Capítulo 3)
- Una dataset de información emocional obtenido a partir de usuarios reales. Estos datos fueron recolectados mediante la utilización de la herramienta BraiM desarrollada para este proyecto de investigación mediante la preparación de un entorno experimental. La documentación completa de estas pruebas, así como la arquitectura utilizada para el desarrollo de la herramienta utilizada puede encontrarse en el Capítulo 5.
- Un estudio comparativo sobre la calidad del sistema implementado y otros enfoques comúnmente utilizados en la recomendación de música (Capítulo 6).

### 1.6.2. Contribuciones Indirectas

- Creación de una plataforma web para la recomendación de música denominada BraiM, que permite la recolección de información emocional a partir de señales EEG. Esta plataforma fue utilizada para obtener la información necesaria en los experimentos relacionados con la predicción de preferencia de canciones, sin embargo su utilización no está ligada a este campo en particular, puesto que la arquitectura cliente-servidor utilizada facilita su adaptación a múltiples escenarios de investigación.
- Los resultados obtenidos de este trabajo permitieron ampliar el conocimiento existente sobre recomendación de música utilizando información emocional, así como también sobre la aplicación de tecnologías EEG en dominios como el entretenimiento y aplicaciones multimedia. Lo anterior motiva la profundización en el desarrollo e investigación de sistemas de recomendación en el grupo de Ingeniería Telemática de la Universidad del Cauca.

## 1.7. Contenido de la Monografía

Esta Monografía se encuentra dividida en 3 partes, introducción, propuesta y experimentación.

### 1.7.1. Parte 1. Introducción

La primera parte de este trabajo de grado se enfoca en proporcionar una descripción del entorno de investigación, exponiendo los conceptos y los trabajos más significativos en el campo de la recomendación de música mediante el reconocimiento de emociones utilizando señales EEG. Los siguientes capítulos hacen parte de esta sección de la monografía.

## Capítulo 1. Introducción

---

**Capítulo 1. Introducción.** Capítulo dedicado a presentar al lector el entorno de investigación considerado en este proyecto de grado.

**Capítulo 2. Estado actual de conocimiento.** Proporciona una visión general sobre los trabajos de investigación más importantes que están relacionados con la predicción de preferencia de canciones mediante el reconocimiento de emociones.

### 1.7.2. Parte 2. Propuesta

La segunda parte de esta monografía expone la solución presentada por este trabajo de investigación.

**Capítulo 3. Captura y análisis de respuestas emocionales basadas en EEG:** este capítulo expone el método de captura utilizado para la recolección de señales EEG y su análisis desde la observación de las características estadísticas de las señales.

**Capítulo 4. Vecindad de usuarios y predicción:** en este capítulo se propone una técnica de similitud entre usuarios basada en la comparación de sus respuestas emocionales al momento de escuchar música. Posteriormente se expone una técnica alternativa de predicción que puede ser utilizada por cualquier SRM.

### 1.7.3. Parte 3. Experimentación y resultados

Aquí se exponen los elementos que fueron utilizados para la construcción de los modelos, técnicas y algoritmos propuestos en la segunda parte de la monografía.

**Capítulo 5 Descripción de la solución:** en cumplimiento del segundo objetivo específico del proyecto, se presenta una descripción arquitectural del sistema desarrollado como mecanismo de predicción que utiliza la técnica de similitud de usuarios propuesta.

**Capítulo 6 Experimentación y evaluación:** este capítulo describe cómo se alcanzó el tercer objetivo de este proyecto, mediante la definición de una metodología de evaluación y la descripción de las pruebas realizadas.

# Capítulo 2

## Estado Actual del Conocimiento

Este capítulo expone los conceptos relevantes para el análisis y desarrollo de este trabajo de grado, resaltando entre ellos el reconocimiento de emociones y sistemas de recomendación de música. Por último, se presentan los referentes teóricos e investigaciones más importantes que justifican este proyecto de grado.

### 2.1. Reconocimiento de Emociones

En esta sección se presenta una definición de término emoción y su relación con la música. Posteriormente se listan algunas de las técnicas más relevantes para el reconocimiento de emociones, haciendo énfasis en el uso de señales EEG, incluyendo un conjunto comparativo de dispositivos en el mercado actual que permiten realizar este tipo de tareas.

#### 2.1.1. Definición de Emoción

Mayers [Myers \(2004\)](#) define una emoción como una experiencia psico-fisiológica del estado mental de un individuo cuando interactúa con influencias biológicas (internas) o de su entorno (externas); sin embargo, no existe una definición unificada hasta el momento. Esto se debe a que una emoción es un concepto abstracto difícil de definir, teniendo en cuenta que cada persona puede percibir y evaluar una emoción de formas diferentes [Plutchik and Kellerman \(2013\)](#).

Existe una gran cantidad de términos que se asocian a la palabra emoción, como: estado afectivo, estado de ánimo y sentimiento [Le \(2010a\)](#). Comúnmente se usan para diferenciar si la emoción está dirigida hacia un objetivo particular. Por ejemplo, cuando una persona siente afecto hacia su pareja o su mascota se suele utilizar el término sentimiento; por otra parte, cuando el objetivo de esa emoción no existe y un individuo está en un estado de relajación o por el contrario de excitación se asocia a un estado de ánimo o estado afectivo. Aunque aparentemente estos términos son muy relevantes en realidad no lo son y en la mayoría de casos funcionalmente tienen el mismo significado, así que pueden ser intercambiados [Russell \(2003\)](#).




Figura 2.1: Diagrama Valence - Arousal [Kim et al. \(2010\)](#)

Por otra parte, existen dos enfoques teóricos para el estudio de las emociones: el modelo por categorías y el modelo dimensional. Estos enfoques permiten definir un conjunto de emociones a estudiar, sin embargo, no existe una taxonomía universalmente aceptada [Kaminskas and Ricci \(2012a\)](#). El modelo por categorías se basa en la utilización de un vocabulario discreto de palabras o etiquetas emocionales seleccionadas según la naturaleza del sistema y el campo de aplicación [Hevner \(1935\)](#), [Zentner et al. \(2008\)](#). Por otra parte el modelo dimensional considera que los seres humanos se encuentran bajo un estado afectivo continuo que puede representarse como un punto en un espacio dimensional compuesto por los ejes 'Valence' (valencia) y 'Arousal' (activación) como se muestra en la figura 2.1. Valencia hace referencia a qué tan positiva o negativa es una emoción. Activación por su parte es el grado de atención que la emoción provoca en el usuario [Eerola et al. \(2009\)](#), [Mion and Poli \(2008\)](#), [Harrison \(2013\)](#).

Comúnmente las personas seleccionan distintos tipos de música de acuerdo a su estado emocional actual; sin embargo, este comportamiento varía de persona a persona [Kaminskas and Ricci \(2012b\)](#). Por esta razón se hace necesario la creación de SRM capaces de comprender cómo reaccionan los usuarios cuando escuchan una canción y qué prefieren escuchar bajo ciertas condiciones emocionales [Le \(2010a\)](#). El uso de canciones previamente categorizadas con información emocional ha sido el enfoque de mayor popularidad en años recientes, permitiendo al usuario seleccionar su estado actual y recibir recomendaciones con base en sus acciones. No obstante, estos estudios omiten ciertos aspectos relevantes a tener en cuenta al recomendar una canción como: la percepción de las emociones en la música y su variación en el tiempo [Kim et al. \(2010\)](#). Esta investigación se enfoca en la utilización de mecanismos alternativos, mediante el uso de sensores que capturan señales biológicas para este tipo de mediciones,

haciendo énfasis en dispositivos que miden la actividad cerebral del usuario. A continuación se profundiza más acerca de este tipo señales y como pueden ser analizadas para inferir el estado emocional del usuario.

### 2.1.2. Detección de emociones mediante la captura de señales biológicas

El reconocimiento automático de emociones es un área de estudio que ha despertado gran interés en la comunidad científica desde hace muchos años; sin embargo, es una tarea compleja que requiere la colaboración de investigadores en campos como: la psicología, neurociencia, minería de datos y aprendizaje automático [Kim et al. \(2010\)](#). Este tipo de enfoque permite la creación de sistemas capaces de interactuar con el usuario con mayor eficiencia y tomar decisiones acertadas utilizando la información recolectada [Le \(2010a\)](#).

En la actualidad una de las técnicas con mayor fiabilidad consiste en el uso de sensores colocados en el usuario para medir señales biológicas, las cuales se ha comprobado pueden reflejar experiencias emocionales del usuario. Además, con el avance de la tecnología se busca que este tipo de dispositivos reduzcan su tamaño y puedan llegar a ser imperceptibles para el usuario final, aumentando en gran medida su utilización en campos como la medicina y el entretenimiento. Las señales biológicas son reacciones del cuerpo ante un suceso externo o interno. Por ejemplo, cuando estamos asustados el ritmo cardiaco tiende a aumentar, la respiración se acelera, los músculos se ponen tensos y aumenta la sudoración. Esto sucede porque el sistema nervioso autónomo encargado de regular el comportamiento interno del cuerpo en situaciones normales o de emergencia se ve afectado, produciendo situaciones como las mencionadas [Haag et al. \(2004\)](#). Las emociones afectan el balance del sistema nervioso autónomo, por ende pueden ser inferidas mediante el monitoreo de señales biológicas. [Le et. al, Le \(2010a\)](#) menciona la siguiente lista de señales biológicas representativas en el campo del reconocimiento automático de emociones:

**Temperatura de la piel:** producto de la contracción de músculos y venas. Puede indicar niveles de placer y dolor.

**Actividad electrodérmica:** hace referencia a la conductividad de la piel, que puede aumentar cuando incrementan los niveles de sudoración del cuerpo. Además, refleja algunas emociones como miedo o ira.

**Electrocardiograma (ECG):** un ECG refleja la actividad del corazón al contraerse. Pueden detectarse niveles de relajación o estrés mental al monitorear cambios en el ritmo cardiaco e intervalos entre latidos.

**Respiración:** monitorear la velocidad con que la persona respira puede indicar niveles de depresión, concentración, ira, miedo, felicidad o concentración.

## Capítulo 2. Estado Actual del Conocimiento

**Electroencefalograma (EEG):** un EEG registra niveles de voltaje sobre la superficie del cuero cabelludo, los cuales reflejan la actividad eléctrica cerebral. A Continuación se hace profundiza acerca de este tipo de señales biológicas para la detección de emociones.

### 2.1.3. Uso de señales EEG para la detección de emociones

Como se menciona en la sección anterior, el uso de sensores biológicos para la detección de las emociones humanas es una alternativa a los métodos convencionales, comúnmente basados en el autodiagnostico y el monitoreo del usuario mediante videocámaras. El presente proyecto se propone el uso de señales EEG para detectar y medir las emociones de lo usuarios, teniendo en cuenta que esta tecnología hoy en día es de facil acceso, permitiendo el uso de herramientas no invasivas, cada vez más pequeñas, económicas y sencillas de usar. En la tabla 2.1 se presenta una comparación entre los dispositivos representativos que permiten la captura y análisis de señales EEG en el mercado actual.




Figura 2.2: Estándar EEG 10-20

Un EEG es utilizado para registrar la actividad eléctrica cerebral que resulta por la interacción entre las neuronas del cerebro en un periodo de tiempo determinado; para ello se colocan múltiples electrodos sobre la superficie del cuero cabelludo [Niedermeyer and da Silva \(2005\)](#). Los electrodos están distribuidos según el estándar internacional “10-20 locations”, que establece una distancia entre electrodos adyacentes como muestra la figura 2.2. La actividad eléctrica cerebral se registra en bandas de frecuencia, entre las cuales se destacan las siguientes: banda delta, entre 1 y 3 hz, banda teta, entre 3 y 8 hz, banda alfa entre 8 y 12 hz y banda beta de 13 hz en adelante. Cada banda esta asociada a distintas clases de respuestas en el cerebro humano. La banda

Delta por ejemplo, se utiliza para seguir la actividad del usuario durante periodos de sueño y relajación, por su parte bajos niveles de amplitud en señales de la banda beta se pueden asociar a periodos de ansiedad y excitación. [Le \(2010a\)](#); [Niedermeyer and da Silva \(2005\)](#)

Tradicionalmente, esta tecnología ha sido utilizada en campos relacionados con la medicina, para la rehabilitación de pacientes que han perdido la movilidad de su cuerpo por algún tipo de trauma o desorden neuromuscular severo, detección de enfermedades graves como epilepsia o el control de cursores y teclados virtuales [Millán et al. \(2010\)](#). Sin embargo, la utilización de dispositivos EEG en aplicaciones multimedia abre un nuevo camino para obtener información valiosa directamente de los consumidores, que no necesariamente deben presentar alguna complicación médica, además, esta aproximación permite añadir una nueva dimensión en la forma como interactúa con un juego o aplicación [Nijholt et al. \(2009\)](#), [Mühl et al. \(2010\)](#). Por ejemplo, los personajes de un juego podrían comportarse de acuerdo a los estados de ánimo de los usuarios; de igual forma, la música puede cambiar para permitir una mayor inmersión, mejorando la experiencia en tiempo real [Krepki et al. \(2007\)](#). Esta investigación considera el uso de esta tecnología para mejorar la calidad con la que los SRM predicen las preferencias de los usuarios por la música. De esta manera se busca brindar al usuario una recomendación personalizada que tenga en cuenta sus respuestas emocionales derivadas de señales EEG, mejorando la experiencia del usuario final.

### 2.1.3.1. Emotiv Insight

Emotiv Insight (ver figura 2.3) es una interfaz cerebro-computador o BCI por sus siglas en ingles, fabricado por la empresa Emotiv Systems <sup>7</sup>, lanzado oficialmente al mercado a finales del año 2015. Según la compañía, este dispositivo permite la detección de expresiones, pensamientos y emociones mediante el análisis de la actividad cerebral del usuario<sup>8</sup>. Además, apunta a un mercado masivo, proporcionando acceso a múltiples aplicaciones que pueden ser descargadas desde su plataforma online, y cuenta con un kit de desarrollo orientado al desarrollo de videojuegos y control de herramientas software y hardware. Entre las opciones disponibles en el mercado actual, Emotiv Insight se destaca como una alternativa de fácil acceso por ser ligero, portable y de bajo precio. Cuenta con 5 canales basados en sensores de polímero de alta duración, que se colocan en puntos específicos sobre el cuero cabelludo siguiendo el estándar EEG 10-20(Figura 2.2), los cuales miden pequeños voltajes producto de la actividad cerebral. Además, este dispositivo funciona de manera inalámbrica con una duración de batería de 4 horas aproximadamente, con una frecuencia de muestreo que puede alcanzar los 128Hz. Un resumen de las características software y hardware más importantes recopiladas del manual de usuario y la documentación oficial se encuentran en el cuadro 2.2.

---

<sup>7</sup>[www.emotiv.com](http://www.emotiv.com)

<sup>8</sup><https://emotiv.com/insight.php>

## Capítulo 2. Estado Actual del Conocimiento

---

Dispositivo	Empresa	Electrodos	Descripción
Muse <sup>1</sup>	InteraXon	4	Cuenta con 7 sensores y una aplicación diseñada para reducir niveles de estrés y aumentar la concentración
Aurora Dream Headband <sup>2</sup>	iwinks	1	Detección de 3 estados mentales. Es un dispositivo especializado para monitoreo del sueño
MindWave <sup>3</sup>	NeuroSky	1	Detección de 2 estados mentales y pestañeo de ojos
Emotiv EPOC <sup>4</sup>	Emotiv systems	14	Detección de 4 estados mentales, expresiones faciales y movimiento de la cabeza.
Emotiv Insight <sup>5</sup>	Emotiv systems	5	Detección de 4 estados mentales y expresiones faciales
ANT <sup>6</sup>	AntNeuro	128	128 electrodos que cubren todas las principales áreas corticales cerebrales, cuenta con un amplificador de DC de banda completa

Cuadro 2.1: Dispositivos EEG presentes en el mercado actual



## 2.1 Reconocimiento de Emociones

Característica	Emotiv Insight
Total Sensores	5+2 referencias
Nombre Sensores	AF3, AF4, T7, T8, Pz
Referencias	Apófisis matoides izquierda
Frecuencia de muestreo	128 Muestras/Sg (Oscilador 2048Hz Interno)
Resolución	14 bits o 16 bits por canal
Rango dinámico	$\pm 4.17$ mV
Tecnología de sensores	Polímero semi-seco de alta duración
Conectividad	-Protocolo propietario 2.4GHz ISM Band - Bluetooth® Smart
Batería	Li-poly battery, 480 mAh, > 4 horas

Cuadro 2.2: Especificaciones técnicas Emotiv Insight

La información recolectada por Emotiv Insight es transmitida hacia el computador o dispositivo móvil en tiempo real, mediante tecnología Bluetooth Smart<sup>9</sup>. Sin embargo para aquellos dispositivos que no cuentan con esta funcionalidad permite la utilización de un dongle USB, cuya función de recibir la información de los sensores en la frecuencia de 2.4GHz usando protocolos propietarios de comunicación. Adicionalmente cuenta con un kit de desarrollo para la creación de aplicaciones de escritorio, web y móviles, mediante librerías en diferentes lenguajes como C++, C#, Java, ObjectiveC, Javascript y Python. Estas librerías permiten el procesamiento de las señales EEG para la detección de rasgos faciales (Facial Expression Suite), patrones de movimiento de objetos (Mental Commands Suite) y reconocimiento de emociones (Performance Metrics Suite), mas adelante se profundiza acerca de estas herramientas. A su vez, permite el acceso a la información en crudo (“raw format”)<sup>10</sup> de cada canal. Estas librerías pueden usarse en un cualquier aplicación mediante el uso de una licencia individual presente en Emotiv Insight. Sin embargo, para que una aplicación creada por terceros pueda ser distribuida, esta debe ser validada previamente por Emotiv y utilizar una licencia paga.

“Mental Commands Suite” permite el control y movimiento de objetos en un entorno virtual usando el pensamiento. Esta herramienta requiere entrenamiento previo del sistema para funcionar eficientemente, procesando las señales EEG para relacionar la información obtenida con un comando mental entrenado por el usuario de forma intensiva. “Expressive Suite”, por su parte permite la detección de expresiones faciales como guiños, pestaños, elevar las cejas y sonreír. A diferencia de las otras herramientas de detección presentes en el dispositivo, se basa en la actividad eléctrica provocada por el movimiento de los músculos faciales durante periodos de relajación y contracción. El sistema se encarga de clasificar estas señales identificando movimientos de grupos musculares que son similares para la mayoría de personas, dada la estructura

<sup>9</sup>Bluetooth de baja energía, también denominada como Bluetooth LE o Bluetooth ULP (Ultra Low Power)

<sup>10</sup>Información en formato binario obtenida por cada canal EEG

muscular del rostro humano [Lang \(2012\)](#)[Harrison \(2013\)](#). Estas herramientas de detección no son tenidas en cuenta para la presente investigación, sin embargo, proveen información de entrada al sistema que podría ser relevante para futuros proyectos.

El presente estudio se basa en la utilización de la herramienta de detección “Performance metrics suite” de Emotiv, que procesa las señales EEG y entrega valores entre 0 y 1 indicando la intensidad detectada para 5 emociones subjetivas que incluyen, excitación instantánea a corto y largo plazo, relajación, compromiso, interés y concentración. Según referencias industriales, este sistema se basa en “la detección de características que son universales en las señales EEG, las cuales no requieren de un entrenamiento específico por el usuario” <sup>11</sup>. El modelo emocional fue entrenado mediante pruebas con alrededor de 100 voluntarios, sometidos a distintos experimentos. Por ejemplo, para detectar niveles de frustración en los usuarios se utilizó el dispositivo en conjunto con sensores utilizados para medir el ritmo cardíaco, la temperatura de la piel y la tensión arterial mientras fueron sometidos a diferentes actividades con el acompañamiento de psicólogos [Radinsky et al. \(2011b\)](#). Entre estas actividades se menciona el uso de videojuegos, proporcionando controles que fallaban aleatoriamente para provocar en el usuario niveles de tensión y estrés [Harrison \(2013\)](#). Aunque hasta el momento Emotiv no ha publicado ninguno de los algoritmos de clasificación utilizados por sus dispositivos, existen trabajos de investigación que utilizan esta herramienta para evaluar el uso de información emocional en áreas como los Sistemas de Tutoría Inteligente o ITS (acrónimo del inglés Intelligent Tutoring System) o mejoramiento de experiencia de usuario en videojuegos y aplicaciones musicales [Inventado et al. \(2010\)](#), [Koutepova et al. \(2010\)](#), [Radinsky et al. \(2011b\)](#), [Lang \(2012\)](#).

Duvinge hace un estudio para dispositivos desarrollados por Emotiv Systems [Duvinge et al. \(2012\)](#), demostrando que a pesar de no contar con los mismos resultados frente a otros especializados en aplicaciones medicas, como ANT Neuro systems<sup>12</sup> en términos de desempeño y resistencia de señal a ruido, tienen resultados aceptables acordes a su bajo precio y cuentan con un gran potencial para el desarrollo de aplicaciones en el campo del entretenimiento.

## 2.2. Sistemas de Recomendación de Música

La música hace parte fundamental en la vida de las personas, siendo para muchos una actividad que se efectúa con mayor frecuencia que leer libros o ver televisión [Song et al. \(2012b\)](#). Esto se debe al poder de comunicación y expresión personal que tiene este tipo de contenido, por esta razón el mercado musical en la actualidad ha encontrado en los SRM una gran oportunidad para atraer usuarios y comprender sus preferencias al escucharla. Generalmente en un SRM se pueden identificar los siguientes componentes: modelado de usuarios, modelado de ítems y técnicas de

---

<sup>11</sup><https://emotiv.zendesk.com/hc/en-us/articles/201444095-Understanding-the-Performance-Metrics-Detection-Suite>

<sup>12</sup><https://www.ant-neuro.com/>



Figura 2.3: Emotiv Insight

agregación de información. A Continuación se se profundiza acerca de cada uno de estos elementos para tener una visión clara acerca de este tipo de sistemas.

**Modelado de Usuarios:** este componente de diseño se enfoca en la forma como se identifican los usuarios y el grado de personalización en la recomendación [Celma \(2009\)](#), [Rojas-Potosi et al. \(2012\)](#). La presente propuesta considera la utilización un dispositivo EEG de bajo costo para recolectar información emocional, de esta forma se hacen predicciones en base a respuestas individuales que permiten identificar otros usuarios con características similares.

**Modelado de ítems:** hace referencia al dominio de aplicación del SR propuesto, en este caso los ítems son canciones que también pueden modelarse con base en sus características, como género, tono y tipos de instrumentos utilizados en su composición. Sin embargo, gran cantidad de canciones en la web carecen de información relacionada, provocando que nunca lleguen a ser escuchadas por usuarios que desean descubrir material nuevo e interesante. Por ello la necesidad de nuevos mecanismos que permitan filtrar y clasificar el contenido musical que es publicado en la web diariamente. Algunos de estos métodos involucran la utilización de expertos y herramientas software, sobre los cuales se profundiza en la sección 2.2.1.2.

**Técnicas de agregación de información:** este componente esta relacionado con la selección del método adoptado por el SRM para aprovechar la información recolectada de usuarios y canciones. Esta fuertemente ligada a los datos de entrada del sistema y de esta forma se pueden hacer sugerencias de ítems relevantes adoptando técnicas que involucran múltiples áreas de investigación, como minería de datos, sistemas

de búsqueda y filtrado, redes sociales, interactividad, procesamiento de señales y visualización de contenidos [Celma \(2009\)](#). Uno de los enfoques de recomendación de mayor aceptación en el campo de la música, al igual que en otros dominios como la recomendación de libros y aplicaciones móviles es el filtrado colaborativo [Kaminskas and Ricci \(2012a\)](#), cuya técnica se basa en el “poder de la palabra”, recomendando ítems a un usuario si estos le gustan a usuarios similares. El presente proyecto de investigación busca adaptar técnicas de filtrado colaborativo en la recomendación de canciones, sin embargo para determinar la similitud entre los usuarios se tienen en cuenta sus reacciones emocionales o estados afectivos al escuchar música. En la siguiente sección se profundiza acerca de las técnicas de agregación de información más relevantes en este contexto y se presenta una tabla comparativa entre cada una de ellas.

### 2.2.1. Técnicas de agregación de información

A continuación se presenta una descripción teórica de las técnicas de agregación de información más utilizadas en el campo de la recomendación de música.

#### 2.2.1.1. Técnicas demográficas

Es la forma más simple de recomendar música, puesto que estos sistemas categorizan al usuario de acuerdo a sus atributos personales para hacer recomendaciones basadas en “Clases Demográficas” (estereotipos) que describen grupos de personas con características comunes [Rojas-Potosi et al. \(2012\)](#). Factores demográficos como edad, sexo, género y lugar de origen tienen influencia directa sobre el tipo de música que escuchan las personas, por esta razón generalmente se utilizan distintas técnicas de categorización y clasificación sobre el contenido musical en internet. En ese orden de ideas, este tipo de técnicas forman correlaciones entre usuarios similares utilizando la información básica recolectada y hacen recomendaciones de canciones sin tener en cuenta patrones de consumo previo. Estas técnicas pueden ser manuales o automáticas, sin embargo requieren una inversión considerable de tiempo y dinero para mantener la información de usuarios y canciones actualizada. Además, no todo el contenido musical en la Web cuenta con información editorial relacionada (autor, género, país, etc.), la cual comúnmente es proporcionada por casas disqueras o editores expertos y que permite asociar el contenido musical a un grupo de usuarios bajo una misma categoría demográfica [Song et al. \(2012b\)](#).

#### 2.2.1.2. Técnicas basadas en contenido acústico

En general las técnicas basadas en contenido determinan la semejanza entre los ítems del sistema permitiendo el filtrado de la información a recomendar, por esta razón este enfoque presenta una fuerte dependencia con el dominio de aplicación [Rojas-Potosi et al. \(2012\)](#). La música es un tipo de contenido bastante difícil de describir y clasificar, sin embargo los métodos más populares buscan extraer metadatos acústicos

directamente de la señal de audio, de esta forma se pueden comparar las canciones para hacer recomendaciones similares a las preferencias del usuario [Song et al. \(2012b\)](#). Este tipo de técnicas tienen fuertes bases en el área de investigación denominada recuperación de información musical (Music Information Retrieval, MIR), impulsando el diseño e implementación de algoritmos capaces de procesar contenido musical de forma automática para detectar patrones como el timbre y “tempo” de una canción. De esta forma cada pieza musical cuenta con un perfil de información que está representado mediante un vector de tantas dimensiones como características son extraídas en la señal de audio. Utilizando esta información un SRM puede modelar las preferencias del usuario usando el mismo espacio multidimensional para identificar canciones relevantes que pueden ser recomendadas [Li et al. \(2004\)](#), [Dillman Carpentier and Potter \(2007\)](#), [Adomavicius and Tuzhilin \(2011\)](#).

Uno de los principales limitantes presentes en estas técnicas es que la mayoría están enfocadas en la representación de canciones utilizando parámetros de bajo nivel asociados a la señal de audio, los cuales no son adecuados para capturar los aspectos más relevantes que permiten a un usuario decidir si dos canciones son similares [Kaminskas and Ricci \(2012a\)](#). Como solución a este problema algunas aproximaciones permiten considerar la detección automática de otro tipo de características musicalmente más significativas como el ritmo, acordes, género o incluso emociones. Musicoverly <sup>13</sup> por ejemplo, es una aplicación web que analiza contenido acústico de bajo nivel para asociar información emocional a las canciones, sin embargo, esta resulta ser una tarea bastante subjetiva [Kim et al. \(2010\)](#). Además, no existen estudios que comprueben que el comportamiento previo de los usuarios pueda llevarlos a querer escuchar el mismo tipo de música en el futuro [Kaminskas and Ricci \(2012a\)](#).

### 2.2.1.3. Técnicas basadas en minería de la Web y contexto textual

Este tipo de técnicas están enfocadas en la recomendación de música mediante la utilización de metadatos culturales para categorizar canciones y artistas, los cuales son extraídos usando minería de la Web (web mining) o sistemas de etiquetas colaborativas [Celma \(2009\)](#). En términos generales esta aproximación se basa en la utilización de la opinión pública presente en internet para caracterizar las canciones y descubrir música interesante [Su et al. \(2010\)](#). Hoy en día las redes sociales como Facebook, Youtube y Twitter proveen gran cantidad información valiosa acerca del contenido en internet gracias al uso de comentarios, reseñas, tags y redes de amigos. Por esta razón este tipo de técnicas consiguen mejores resultados que las basadas en contenido acústico, sin embargo, tienen una gran limitación denominada; sesgo de popularidad (‘popularity bias’), donde las canciones populares tienden a ser recomendadas frecuentemente debido a que poseen mayor cantidad de reseñas y opiniones que las poco conocidas [Song et al. \(2012b\)](#).

---

<sup>13</sup>[www.musicoverly.com](http://www.musicoverly.com)

### 2.2.1.4. Técnicas de Filtrado Colaborativo

El filtrado colaborativo (FC) es una de las técnicas más comunes, no solo en el campo de la recomendación de música, sino también en la mayoría de sistemas de recomendación y es en definitiva uno de los enfoques con mejores resultados. Asume que si dos usuarios califican  $n$  ítems de forma similar o tienen un comportamiento parecido, en el futuro compartirán opiniones similares para nuevos ítems [Song et al. \(2012b\)](#). Esta técnica utiliza el contenido generado por los usuarios de forma implícita (comportamiento) o explícita (ratings) para predecir la calificación de ítems con base en la similitud entre usuarios. Como resultado el FC no requiere información acerca del contenido de los ítems a recomendar, puesto que en la mayoría de casos es la comunidad quien tiene la tarea de evaluar cada elemento y se utilizan algoritmos de aprendizaje automático para establecer relaciones entre usuarios [Rojas-Potosi et al. \(2012\)](#). En el caso de los SRM este tipo de técnicas presentan un gran ventaja puesto que permiten evitar la tarea de analizar y clasificar contenido musical, dada la complejidad existente en el procesamiento de señales acústicas y metadatos de canciones [Kaminskas and Ricci \(2012a\)](#). Existen dos enfoques de filtrado colaborativo: filtrado colaborativo basado en memoria y filtrado colaborativo basado en modelos.

**Filtrado colaborativo basado en memoria:** trata de predecir el rating de un ítem basado en la colección entera de ratings previos. Esto se logra agrupando los usuarios con un comportamiento similar en “vecindades” de usuarios, para ponderar las preferencias de un ítem en función de la información recolectada [Ekman and Davidson \(1994\)](#).

**Filtrado colaborativo basado en modelos:** a diferencia del FC basado en memoria utiliza técnicas de aprendizaje automático como redes neuronales y redes bayesianas, para entrenar y modelar las preferencias de los usuarios [Rojas-Potosi et al. \(2012\)](#) [Jennings \(2007\)](#).

### 2.2.2. Comparación de técnicas de agregación

Después de describir las técnicas de recomendación de música más representativas en la literatura, se realizó una comparativa entre cada una de ellas, exponiendo en el cuadro 2.3 sus ventajas y en el cuadro 2.4 las desventajas encontradas. En cada cuadro la columna A hace referencia a las técnicas demográficas, B a las técnicas basadas en contenido, C a las técnicas basadas en minería de la Web y D a las técnicas de filtrado colaborativo.

## 2.2 Sistemas de Recomendación de Música

		A	B	C	D
<b>Ventajas</b>	Las recomendaciones pueden hacerse utilizando estudios de mercadeo previo sin tener en cuenta las preferencias musicales del usuario	x			
	Adaptativos: La calidad de la predicción mejora al pasar el tiempo.		x	x	x
	Soportan retroalimentación de forma implícita.		x	x	x
	Las recomendaciones pueden ser multi-dominio(e.g. música, películas, libros).				x
	Aprovechan el potencial de las redes sociales para recolectar información sobre los ítems a recomendar.			x	
	No se requiere un análisis del contenido a recomendar, evitando la clasificación e indexación previa de los ítems del sistema.				x

Cuadro 2.3: Comparativa de técnicas de recomendación: Ventajas

## Capítulo 2. Estado Actual del Conocimiento

		A	B	C	D
<b>Desventajas</b>	El usuario debe tener conocimiento previo sobre información de las canciones para recibir recomendaciones musicales acordes a sus preferencias.	x			
	Requiere una inversión considerable de tiempo y dinero el mantener información editorial de canciones actualizada.	x			
	Arranque en frío (Cold start), cuando nuevos ítems son ingresados al sistema y carecen de ratings o información con la que puedan ser asociados con otros usuarios/ítems		x		x
	Escasez de datos (Data Sparcity) cuando los ratings son pocos en comparación con la cantidad de ítems y usuarios presentes en el sistema. Esto se debe a que un usuario comúnmente solo brinda información explícita o implícita sobre una cantidad limitada de ítems y las vecindades de usuarios similares no son lo suficientemente fiables.			x	x
	Sesgo de popularidad (Popularity Bias o Long Tail) , provocando que los ítems populares tienden a ser recomendados más frecuentemente debido a que cuentan que una mayor cantidad de feedback de usuarios. Por el contrario los ítems poco conocidos nunca son recomendados al no aparecer en perfiles de usuarios vecinos.			x	x
	El contenido acústico no refleja por completo las preferencias de los usuarios, por lo que el modelo tiende a caer en un vacío semántico entre la percepción de la música que tiene una persona y la representación musical de una canción.		x		
	Los usuarios no son capaces de expresar sus necesidades musicales en términos de características acústicas de bajo nivel.		x		
	Las recomendaciones pueden llegar a ser obvias o muy similares, debido a que el modelo predictivo para algunos usuarios está “sobre-especializado” cuando aún no ha rankeado una gran cantidad de ítems.		x	x	

Cuadro 2.4: Comparativa de técnicas de recomendación: Desventajas



A partir de la comparación realizada, es posible concluir que el filtrado colaborativo pese a sus limitaciones, es la técnica de recomendación que cuenta con mayor número de ventajas frente a las demás. De igual forma puede ser aplicada a múltiples dominios y esta soportada por numerosos trabajos de investigación. Esta técnica fue seleccionada para su adaptación en el presente proyecto, como un punto de partida que permita proponer un mecanismo alternativo de predicción.

### 2.2.3. Filtrado Colaborativo

En esta sección se explica de una forma detallada los componentes teóricos del filtrado colaborativo, haciendo énfasis en el proceso utilizado para recomendar canciones mediante este tipo de técnicas. Como se menciona en la sección 2.2.1.4 el filtrado colaborativo predice las preferencias de un usuario para los ítems del sistema mediante el análisis de sus patrones de consumo previo. En este orden de ideas el usuario brinda una retroalimentación al sistema para hacer sugerencias basadas en la información recolectada. El proceso de recomendación utilizando este enfoque según [Rojas-Potosi et al. \(2012\)](#) se divide en cuatro etapas: Captura/inferencia de calificaciones, definición de la vecindad de usuarios, predicción de calificaciones y presentación de la recomendación.

#### 2.2.3.1. Captura/inferencia de calificaciones

El filtrado colaborativo ha sido ampliamente utilizado en el campo de la recomendación de música, sin embargo los mecanismos usados para capturar retroalimentación sobre contenido musical han evolucionando constantemente. Los primeros estudios consideraban únicamente puntuaciones hechas por usuarios sobre canciones y artistas. Sin embargo autores como [Anderson et al. \(2003\)](#) definieron una serie de dimensiones adicionales que se usan para medir la calificación del usuario como: originalidad, calidad de producción y letra. Aunque el uso de información explícita proporciona información valiosa para el sistema, permitiendo rastrear tanto calificaciones positivas como negativas de primera mano, son muy pocos los usuarios dispuestos a calificar el contenido de forma explícita [Rojas-Potosi et al. \(2012\)](#). En la actualidad muchos SRM registran el comportamiento del usuario cuando realiza acciones como reproducir, pausar o saltar una canción, de esta forma es posible inferir su calificación [Celma \(2009\)](#).

El proceso de captura de calificaciones consiste en la representación de la información recolectada mediante una matriz de  $M \times n$ , donde  $n$  corresponde al número de usuarios,  $m$  al número de ítems y  $R_{ij}$  es la calificación para el ítem  $j$ , concedida por el usuario  $i$  de forma directa o inferida a partir de su historial previo.

#### 2.2.3.2. Definición de la vecindad de usuarios

La segunda etapa del proceso consiste en identificar vecindades de usuarios similares comparando sus calificaciones explícitas o implícitas. La similitud de usuarios se

puede calcular a través de técnicas como similitud de cosenos, correlación de Pearson o similitud de Jaccard. De esta forma la vecindad para el usuario solicitante cuenta con una lista de integrantes que superan un valor umbral de similitud, definido por el diseñador del sistema [Sami and Harmala \(2009\)](#).

### 2.2.3.3. Predicción de calificaciones

En esta etapa la calificación para un ítem desconocido por el usuario solicitante se pondera en base a la calificación de sus usuarios vecinos, asignando un mayor peso al aporte realizado por aquellos con un grado de similitud mayor.

### 2.2.3.4. Presentación de la recomendación

Por ultimo se realiza la presentación de resultados al usuario final, sin embargo este proceso depende en gran medida de las características del dominio de recomendación. A continuación se listan las aplicaciones para SRM más utilizadas una vez completada la etapa de predicción.

- Listas de reproducción personalizadas: es una de las aplicaciones más importantes en la recomendación de música, puesto que permite a los usuarios escuchar contenido recomendado mientras proporcionan retroalimentación de forma instantánea y permiten al sistema actuar inmediatamente utilizando la información recolectada [Celma \(2009\)](#). La forma en la que se construyen estas listas de reproducción pueden variar de acuerdo a una gran cantidad de factores que tienen efectos en la experiencia del usuario final. Por ejemplo, una lista personalizada puede estar compuesta únicamente por canciones desconocidas con calificaciones altas, predichas previamente por el sistema; o por el contrario contar con canciones ya conocidas con el fin de proporcionar oportunidades de redescubrir contenido asociado a recuerdos y experiencias previas.
- Recomendación de artistas: gracias a la gran cantidad de contenido asociado con la música presente en internet, puede presentarse al usuario final información relacionada de gran utilidad, como nuevos lanzamientos de sus artistas favoritos, noticias, fechas de conciertos, reseñas de álbumes, blogs, etc [Kaminskas and Ricci \(2012a\)](#). Sistemas de recomendación como iTunes utilizan servicios de publicación que proveen esta clase de información personalizada para cada usuario, utilizando generadores de contenido RSS.
- Recomendación de Vecindades: permite al usuario final interactuar con personas con quienes comparte intereses musicales similares [Song et al. \(2012b\)](#).

## 2.3. Trabajos Relacionados

Esta sección presenta un análisis de los trabajos más sobresalientes en el área de acción de la presente propuesta.

### 2.3.1. Trabajos relacionados con la recomendación de música basada en emociones

Los primeros trabajos de recomendación de música propuestos en la academia aparecieron no mucho después del nacimiento de los Sistemas de Recomendación a principios de los años 90 [Kaminskas and Ricci \(2012a\)](#). Sin embargo tal se menciona en la introducción de esta monografía, hoy en día este tipo de herramientas están ligadas a mecanismos que permiten apropiarse información emocional de usuarios y canciones, debido a que este es uno de los criterios de búsqueda más importantes.

Tradicionalmente autores como [Kim et al. \(2010\)](#) han definido la detección de emociones en la música como un problema estadístico de clasificación o regresión, en el cual se busca anotar una pieza musical utilizando un conjunto de emociones (usando un modelo emocional). Donde una pieza musical puede ser una canción completa, una sección (intro, solo, coro) o un clip de duración definida (por lo general de 30 segundos). Las emociones por su parte se pueden representar como una serie temporal de vectores, registrando cambios emocionales a lo largo de la pieza musical.

Este vector de emociones puede determinarse utilizando varios tipos de información. El *análisis de audio para la detección automática de emociones* es uno de los enfoques más populares, en él se destaca el trabajo de Li y otros [Li and Ogihara \(2003\)](#), siendo uno de los primeros en utilizar características acústicas de una canción para entrenar algoritmos de aprendizaje automático y clasificar una librería de 499 canciones usando 13 estados de ánimo. En el año 2007 el evento anual MIREX<sup>14</sup> (Music Information Research Evaluation eXchange) para la evaluación de algoritmos y sistemas MIR<sup>15</sup>, añadió como una de sus áreas de investigación el reconocimiento automático de emociones; destacando los trabajos de [Peeters \(2008\)](#) y [Cao and Li \(2009\)](#) ganadores en este campo en los años 2008 y 2009 respectivamente. Recientemente Panda y otros [Panda et al. \(2015\)](#), propusieron una aproximación basada en la detección de características melódicas que, a diferencia de los patrones comúnmente extraídos en la señal de audio, brindan información relevante sobre la asociación de elementos musicales combinados como el ritmo y las notas musicales. Los resultados obtenidos por este trabajo de investigación demuestran que este tipo de características permiten obtener mejores resultados en la detección automática de emociones usando distintas técnicas de aprendizaje supervisado. Otro de los enfoques para la detección de emociones en la música es el uso de *etiquetas colaborativas*, que involucra a los usuarios del sistema, permitiéndoles asignar anotaciones al momento de escuchar una canción. Miller y otros [Miller et al. \(2008\)](#) presentaron en 2007 el sitio web Last.Fm<sup>16</sup>, que fue un referente en este dominio, sin embargo hoy en día ha perdido gran parte del mercado frente a gigantes del “streaming” de música como Spotify<sup>17</sup> y Pandora<sup>18</sup>.

---

<sup>14</sup><http://www.music-ir.org/mirex>

<sup>15</sup>Recuperación de información Musical - Music information retrieval

<sup>16</sup><http://www.last.fm>

<sup>17</sup><https://www.spotify.com>

<sup>18</sup><http://www.pandora.com/>

Los anteriores aportes han permitido la aparición de trabajos que emplean la información emocional presente en una pieza musical en diferentes contextos de recomendación. Baltrunas y otros [Baltrunas et al. \(2011\)](#) por ejemplo, utilizan filtrado colaborativo para sugerir piezas musicales, presentando un enfoque sensible al contexto actual del usuario cuando se encuentra manejando un automóvil. La contribución principal de este trabajo es una metodología que permite evaluar la influencia de variables contextuales como estado de ánimo del usuario y el tráfico al conducir, sobre la calificación de música, y permite la recolección de calificaciones explícitas, utilizando una aplicación móvil. La evaluación offline del modelo predictivo propuesto por Baltrunas demuestra resultados positivos en cuanto a reducción del Error medio Absoluto (MAE) frente al filtrado colaborativo convencional y otros algoritmos de predicción no personalizados. Braunhofer y otros [Braunhofer et al. \(2013\)](#) por su parte, presentaron un sistema de recomendación que permite establecer relaciones entre canciones y sitios de interés (POI points of interest), previamente categorizados por los usuarios usando etiquetas emocionales en una aplicación web. Mas adelante Ferwerda y otros [Ferwerda and Schedl \(2014\)](#), se basan en información provista por la red social Twitter, para detectar de forma implícita factores psicológicos asociados al usuario como su personalidad y estado de ánimo actual. Esta aproximación hace un análisis del léxico presente en los tweets publicados para detectar cambios emocionales en el usuario y posteriormente presenta una recomendación de canciones provista por Last.Fm. Un enfoque parecido es propuesto por Deng y otros [Deng et al. \(2015\)](#), comparando las emociones detectadas en twitter para los usuarios del sistema, sugiriendo canciones previamente etiquetadas.

Sin embargo, el uso de información emocional en SRM es una tarea que aún presenta diversos desafíos. Esto se debe a que no es claro como funciona la percepción humana al escuchar música teniendo en cuenta que distintos usuarios pueden experimentar diferentes emociones al escuchar una misma canción. Por este motivo, han surgido propuestas innovadoras que buscan incluir herramientas para monitorear directamente las reacciones del usuario mediante el uso de sensores. [Le \(2010b\)](#), propone un sistema que califica las canciones teniendo en cuenta dos factores: la relevancia de la canción en sus preferencias musicales y el grado de influencia positiva o negativa sobre su emoción actual. El autor plantea la medición automática de las emociones mediante el análisis de información proveniente de sensores biológicos que miden la temperatura de la piel y el ritmo cardiaco. En la siguiente sección se detallan los trabajos más destacados en el campo de la recomendación de música, que además tienen en cuenta el uso de dispositivos EEG para la detección de emociones.

### **2.3.2. Reconocimiento de emociones a partir de señales EEG y su aplicación en el campo de la recomendación de música**

Esta área de estudio permite involucrar nuevos elementos en la recomendación para asociar contenido emocional con las preferencias musicales de los usuarios. Aunque

este trabajo de investigación no está enfocado en la clasificación de señales EEG, este campo es de vital importancia ya que hace posible la apropiación de estas técnicas para modelar un algoritmo colaborativo de recomendación.

**Real-Time EEG-Based Emotion Recognition and Its Applications:** Liu [Liu et al. \(2010\)](#) plantea en este trabajo de investigación la detección de las emociones “internas” de los usuarios analizando señales EEG como una alternativa a otros mecanismos como el análisis de texto, habla y expresiones faciales; teniendo en cuenta que el ser humano puede disfrazar este tipo de reacciones “externas”. El aporte principal de este proyecto es la creación de un algoritmo para la clasificación de señales EEG denominado “Algoritmo de dimensión fractal”, que permite la detección de emociones básicas en un modelo dimensional. Este algoritmo fue entrenado con información recolectada a partir de experimentos de inducción de emociones mediante estímulos acústicos, obtenidos de la base de datos IADS (International Affective Digitalize Sounds por sus siglas en ingles). Además se plantea el uso del mecanismo propuesto en aplicaciones relacionadas al tratamiento de pacientes mediante musicoterapia para reducir niveles de estrés y recomendación no personalizada de música.

**Real-Time EEG-Based Emotion Recognition and Its Applications:** Guo y otros [Guo et al. \(2012b\)](#) enfocan su estudio en la captura de señales EEG para niveles de frecuencia que se encuentran en la banda Beta, entre los 14 y 30 Hz, los cuales están asociados a estados de ánimo como excitación y aburrimiento en el ser humano. Esta información es utilizada para categorizar las canciones y construir un perfil de usuario con el que implementa un servicio de segmentación de canciones, asignando calificaciones positivas o negativas a distintas partes de una pieza musical. De esta forma el sistema presenta al usuario una lista de clips cortos que considera de mayor relevancia.

**MyMusicShuffler: Mood-based music recommendation with the practical usage of brainwave signals:** Shin [Shin et al. \(2014\)](#) propone un servicio automático de música que interactúa con el estado emocional del usuario mediante un análisis de las señales EEG, de esta forma la aplicación puede seleccionar música que refleje las emociones del usuario en tiempo real. Este autor utiliza una aproximación que permite eliminar las interacciones manuales del usuario a fin de utilizarse en entornos multitarea.

**Human-centered favorite music estimation:** [Sawata et al. \(2015\)](#) presentan una herramienta para detectar características propias de la señal de audio que pueden reflejar la preferencia de los usuarios, y que se derivan a partir del análisis de señales EEG. La más importante de las características propuestas es la ‘proyección’ de una canción, que se calcula aplicando un análisis de correlación canónica (CCA) aplicado a las características tradicionales de una canción (tempo, ritmo, tono, etc.) y a las señales EEG recolectadas. Resultados experimentales de este trabajo muestran que

## Capítulo 2. Estado Actual del Conocimiento

---

este enfoque obtiene mejores resultados con respecto a las características tradicionales o acústicas de una canción para reflejar las preferencias musicales del usuario.

**A personalized music recommendation system based on electroencephalography feedback:** Chang y otros [Chang et al. \(2016\)](#) proponen un sistema personalizado para la recomendación de música con el fin de mitigar niveles peligrosos de estrés en los usuarios, y utilizando información proporcionada por un dispositivo EEG. De esta forma se evitan géneros musicales incorrectos que, en un usuario particular pueden causar el efecto contrario. Este sistema agrupa las canciones en clusters de acuerdo a sus características acústicas extraídas mediante la herramienta MIRToolBox, utilizando un algoritmo de clustering denominado K-Meansh. Como resultado de este experimento Chang registra resultados superiores en términos de precisión, respecto a otros algoritmos de clustering como K-Means y KMedoids.

**Brain-Computer Interfaces for Music Recommendation:** Radinsky [Radinsky et al. \(2011b\)](#), presenta un sistema de recomendación que tiene como objetivo realizar una selección adecuada de canciones que permitan llevar al usuario desde su estado de ánimo actual a un estado de ánimo objetivo. La actividad emocional del usuario se mide mediante un dispositivo Emotiv Epoc, el cual cuenta con un clasificador previamente entrenado para detectar 4 emociones básicas y produce probabilidades para cada una de ellas en tiempo real. El algoritmo de predicción utilizado tiene un enfoque de aprendizaje por refuerzo, el cual consiste en un agente software que toma decisiones y como consecuencia se generan cambios de estados que producen recompensas. Las acciones están representadas por la selección de canciones pertenecientes a un género en particular, de esta forma cada cambio de estado se produce una recompensa y el algoritmo es capaz de decidir cuál acción maximiza esta recompensa.

### 2.3.3. Brechas existentes

En esta sección se presenta una revisión bibliográfica sobre los trabajos de investigación que soportan la hipótesis presentada en la Sección 1.3, ya que no ha sido abordada por los trabajos relacionados, justificando el presente proyecto.

Trabajo	Aportes	Brechas
<a href="#">Le (2010a)</a>	<ul style="list-style-type: none"><li>- Realiza una clasificación de cambios en el estado de ánimo del usuario dependiendo de la emoción detectada antes y después de escuchar una canción. De esta forma se identifican cambios considerados como “positivos” y “negativos”, los cuales se traducen en un puntaje que aporta en la calificación final de la canción.</li><li>- Hace un estudio de múltiples señales biológicas para la detección de emociones en el usuario.</li></ul>	<ul style="list-style-type: none"><li>- No se tienen en cuenta señales EEG para captura de información emocional.</li><li>- Se detecta información emocional en base al ritmo cardíaco y la temperatura de la piel.</li></ul>

## 2.3 Trabajos Relacionados

<p>Radinsky et al. (2011a)</p>	<ul style="list-style-type: none"> <li>- Propone un modelo de aprendizaje por refuerzo para llevar al usuario a un estado de ánimo objetivo.</li> <li>- Utiliza el clasificador emocional proporcionado por el dispositivo Emotiv Epop.</li> </ul>	<ul style="list-style-type: none"> <li>- El sistema de recomendación propuesto no considera la predicción de la calificación de canciones desconocidas por el usuario final.</li> <li>- Esta aproximación se enfoca en seleccionar un genero musical adecuado dependiendo del estado de animo al que el usuario quiere llegar, sin tener en cuenta la calificación previa de los usuarios por las canciones escuchadas.</li> </ul>
<p>Guo et al. (2012b)</p>	<ul style="list-style-type: none"> <li>- Servicio de segmentación de canciones, asignando feedback emocional positivo o negativo a distintas partes de una pieza musical.</li> <li>- Presenta al usuario listas de reproducción compuesta por segmentos de canciones teniendo en cuenta su actividad cerebral a partir de un análisis de señales EEG en la banda Beta.</li> </ul>	<ul style="list-style-type: none"> <li>- Este enfoque utiliza las señales EEG en crudo para la creación de los perfiles de usuario, sin hacer énfasis en las respuestas emocionales de los usuarios.</li> <li>- No se usa un enfoque colaborativo para la predicción de canciones desconocidas por el usuario solicitante.</li> </ul>
<p>Shin et al. (2014)</p>	<ul style="list-style-type: none"> <li>- Genera listas de reproducción acordes al estado de ánimo del usuario en tiempo real.</li> <li>- Elimina las interacciones manuales del usuario con el sistema.</li> </ul>	<ul style="list-style-type: none"> <li>- No se tienen en cuenta las respuestas de usuarios vecinos para la recomendación de canciones.</li> </ul>
<p>Sawata et al. (2015)</p>	<ul style="list-style-type: none"> <li>- Mecanismo para detectar nuevos parámetros acústicos basados en el análisis de señales EEG, los cuales pueden reflejar de forma más eficiente respuestas emocionales de los usuarios, frente a los parámetros comunes como tempo o timbre.</li> </ul>	<ul style="list-style-type: none"> <li>- Aunque se registró mejoras en los experimentos realizados con el método propuesto frente a los mecanismos tradicionales para determinar la calificación del usuario, no se tiene en cuenta un enfoque colaborativo para el calculo de la predicción realizada. Por este motivo la recomendación generada tiende a ser siempre muy parecida o inexistente.</li> <li>- La técnica de agregación de información utilizada por el SRM propuesto, se centra en el análisis del contenido acústico, y la información obtenida mediante la captura de señales EEG se transforma para clasificar previamente las canciones sin tener en cuenta la calificación de usuarios similares.</li> </ul>
<p>Chang et al. (2016)</p>	<ul style="list-style-type: none"> <li>-La recomendación presentada al usuario final depende de sus respuestas emocionales derivadas de señales EEG, sugiriendo canciones que permiten mitigar niveles peligrosos de estrés.</li> </ul>	<ul style="list-style-type: none"> <li>- Las canciones sugeridas son seleccionadas con base en un análisis de características acústicas presentes en la canciones. Para ello se analizan previamente usando una herramienta de recuperación de información.</li> </ul>

### Cuadro 2.3.3 Brechas Existentes

En la tabla 2.3.3 se presenta un resumen de las brechas encontradas en los trabajos de investigación seleccionados, destacando el trabajo de Radinsky [Radinsky et al. \(2011b\)](#) como principal exponente en la recomendación de música mediante información emocional proporcionada por el motor de clasificación de Emotiv para señales EEG; sin embargo no considera la predicción de la calificación para hacer dichas recomendaciones. Este proyecto de investigación propone un enfoque colaborativo, dejando abierta la pregunta de investigación presente en la sección 1.1, planteando un mecanismo para comparar las respuestas sobre el estado de animo del usuario proveniente de un dispositivo EEG Emotiv Insight, y de esta forma hacer una recomendación personalizada de música mediante la creación de vecindades de usuarios con respuestas similares.



Parte II  
Propuesta

## Capítulo 3

# Captura y análisis de respuestas emocionales basadas en EEG

Como se presentó en la Parte I, los primeros sistemas de recomendación en entornos reales fueron implementados para contenido musical; desde entonces han sido foco importante de investigación y han evolucionado continuamente. Estas herramientas se basan en el uso de algoritmos de agregación de datos para predecir las preferencias de los usuarios mediante su historial de reproducción previo. Una de las preguntas de investigación con mayor interés en este campo consiste en evaluar el impacto de la incorporación de información emocional en la recomendación de canciones para mejorar en la predicción realizada, planteando nuevos modelos de interacción del usuario con el contenido y proporcionando mecanismos alternativos para obtener retroalimentación de forma más acertada.

Trabajos recientes han estudiado la posibilidad de utilizar sensores y herramientas capaces de medir respuestas biológicas de los usuarios para recomendar música, detectando por ejemplo, cambios en la temperatura de la piel y el ritmo cardiaco para inferir el estado de ánimo del usuario. De esta forma el sistema puede sugerir canciones apropiadas en situaciones de estrés o de alta concentración [Le \(2010a\)](#). Siguiendo una aproximación similar, otras investigaciones usan dispositivos para la captura de señales EEG, los cuales como en el caso de Emotiv Insight y Emotiv EPOC, cuentan con sistemas para la detección de respuestas afectivas básicas inferidas a partir de las señales obtenidas [Radinsky et al. \(2011b\)](#); [Guo et al. \(2012b\)](#). Sin embargo los estudios mencionados no profundizan sobre el efecto que tiene detectar usuarios con respuestas similares a partir de este tipo de información contextual, y cómo puede influenciar la calidad de la predicción en SRM con enfoques colaborativos. Este proyecto de grado explora este enfoque a partir de la Hipótesis H1 (Sección 1.3) y la pregunta de investigación general (Sección 1.1), que se deriva en las siguientes preguntas específicas:

- ¿Cómo puede utilizarse las respuestas emocionales de los usuarios a partir de señales EEG, en un SRM basado en filtrado colaborativo?

- ¿ Definir vecindades de usuarios con respuestas emocionales similares al escuchar música, influye sobre la calidad de predicción en un SRM?

Para responder a los interrogantes mencionados, en esta sección se expone un análisis estadístico sobre la información recolectada en aplicación web BraiM (Capítulo 5), desarrollada para este proyecto de investigación y que permite escuchar canciones desde Spotify, mientras en paralelo se sincroniza con el dispositivo periférico Emotiv Insight para recolectar respuestas emocionales de los usuarios. Así, en la sección 3.1 se presenta la metodología escogida para el proceso de análisis de datos, posteriormente en la sección 3.2.2 se expone un análisis estadístico sobre la información recolectada. Por último, en la sección 3.2.3, se discuten los resultados obtenidos. Este análisis además, describe alternativas para la utilización de este tipo de información contextual en la predicción de las preferencias de los usuarios al escuchar música.

## 3.1. Proceso de análisis

En esta sección se presenta el proceso de análisis realizado para describir la información recolectada, con el fin de tener un primer acercamiento sobre los datos, e implementar un mecanismo que permita hacer predicciones sobre la calificación de canciones desconocidas para el usuario solicitante. Este proceso esta basado en la metodología CRISP-DM para proyectos de implementación de minería de datos [Chapman et al. \(2002\)](#). CRISP-DM propone un modelo integral compuesto por 6 fases que pueden aplicarse de forma independiente tanto del sector de la industria como de la tecnología utilizada. Estas fases se describen a continuación:

1. Comprensión del negocio: fase inicial que busca identificar los objetivos y requerimientos del proyecto mediante un análisis a profundidad del contexto de investigación. Esta fase es trabajada en la Parte I de esta monografía.
2. Comprensión de datos: inicia con la definición del dataset utilizado para la presente investigación, que en este caso está compuesto por la información recolectada por la herramienta BraiM, descrita en el Capítulo 5. El acercamiento con los datos e identificación de problemas de calidad en la información, o subconjuntos de datos que pueden arrojar nuevas hipótesis e información oculta, se trabaja en el Capítulo 3 de esta monografía.
3. Preparación en los datos: en esta fase se realiza un proceso para la depuración de los datos recolectados por BraiM, construyendo el dataset final a partir de la información en crudo. Además, se selecciona la información con mayor relevancia para el presente estudio y se define el formato que tendrán los datos. Esta fase es abordada en las secciones finales del Capítulo 3.
4. Modelado: se expone en el Capítulo 4, mediante modelado del problema de forma matemática. Para esto se utiliza como insumo la información obtenida durante la fase de comprensión de datos.

5. Evaluación: esta fase se enfoca en discutir los resultados obtenidos durante en el análisis estadístico de los datos recolectados. Capítulo 6.
6. Despliegue: se describe el alcance potencial de los resultados obtenidos. En este orden de ideas se presenta una serie de alternativas que permiten incluir información emocional sobre los usuarios para recomendar canciones desconocidas. Si bien, esta fase no está en el alcance del proyecto; el Capítulo 7 presenta varias consideraciones a partir de los resultados de la evaluación realizada en el Capítulo 6; describiendo algunos lineamientos como preámbulo al desarrollo e implementación de un sistema de recomendación desplegado en un entorno real.

### 3.2. Detección de emociones

Esta sección está dedicada a la exposición del método de captura utilizado para la detección de estados afectivos al momento de escuchar una canción, posteriormente se hace una descripción del tipo información recolectada, presentando las bases teóricas que permiten asociar emociones con la recomendación de música. Finalmente se proponen distintas técnicas para comparar las respuestas de los usuarios y se presenta una tabla comparativa entre cada una de ellas.

#### 3.2.1. Método de captura

Emotiv es una compañía que ofrece herramientas tecnológicas para la captura y análisis de señales EEG, que por sus características (flexibilidad, poco peso y bajo costo) presentan grandes ventajas frente a otras alternativas usadas tradicionalmente en el campo de la medicina. Actualmente sus productos más representativos en el mercado son Emotiv EPOC y Emotiv Insight. Su principal diferencia radica en la cantidad de canales EEG (14 canales para EPOC y 5 para Insight). Emotiv Insight sin embargo, cuenta con un diseño moderno y mucho más estilizado. Adicionalmente utiliza un sistema de sensores de polímero patentado, que ofrecen una conductividad eléctrica mejorada, absorbiendo la humedad del entorno. Este tipo de sensores, según la compañía eliminan la necesidad de una preparación extensiva para colocar el dispositivo y la utilización de geles o solución salina para mejorar la calidad de la detección. <sup>1</sup>

Ambos dispositivos ofrecen un sistema que permite la clasificación automática de señales EEG para la detección de emociones, denominado Suite de Medidas de Rendimiento (“Performance Metrics Suite” o “Affective Suit” para dispositivos EPOC) <sup>2</sup>, sobre el cual se profundiza en la sección 2.1.3.1. Trabajos como el de Cernea y otros [Cernea et al. \(2011\)](#) utilizan esta herramienta para detectar estados de frustración, excitación y compromiso en el campo de los videojuegos. De esta forma el autor transforma la información obtenida por el clasificador emocional de Emotiv a una escala de

---

<sup>1</sup><https://emotiv.com/insight.php>

<sup>2</sup><https://emotiv.zendesk.com/hc/en-us/articles/200778439-What-happened-to-Affective-Cognitiv-Expressiv->

5 puntos, comparando los resultados con la opinión del usuario mediante cuestionarios en una escala de Likert. Este experimento demuestra que la información entregada por el dispositivo presenta un comportamiento acorde a las emociones expresadas por el usuario de forma explícita, sin embargo no se hace un estudio sobre la precisión con la que Emotiv hace estas mediciones. Lang [Lang \(2012\)](#), utiliza una aproximación similar, haciendo registros de 8 segundos para cada una de las emociones entregadas por el dispositivo. Los experimentos de Lang se basaron en actividades y juegos que podían fallar o terminar exitosamente para medir estados de frustración y excitación. Sin embargo, los ejemplos más representativos sobre la utilización de esta herramienta para la detección de estados afectivos derivados de señales EEG, se encontraron en el campo de los sistemas de tutoría inteligentes o ITS. Salvador, Legaspy y Suárez [Inventado et al. \(2010\)](#) usan las emociones clasificadas por EPOC, a fin de comprender cómo un grupo de estudiantes evalúan la retroalimentación proporcionada por sus docentes. Harrison y otros [Harrison \(2013\)](#) por su parte, estudian el uso de EPOC para fortalecer procesos de aprendizaje al detectar estados de baja concentración y aburrimiento.

Los estudios mencionados anteriormente junto con el de Radinsky [Radinsky et al. \(2011b\)](#), que fue presentado en el estado del arte (capítulo 2), permiten establecer un punto de referencia sobre cómo abordar las métricas afectivas entregadas por Emotiv y utilizar esta información en aplicaciones de recomendación de música. Cabe mencionar que Emotiv Insight a pesar de contar con una cantidad reducida de canales EEG, al igual que EPOC posee los mismos sistemas para la detección de emociones y expresiones faciales. El objetivo de la presente investigación no es calcular el grado de precisión con la que Emotiv Insight hace este tipo de mediciones, en cambio se propone una aproximación que utiliza la información emocional provista por el dispositivo al escuchar música, para relacionarla con las preferencias de los usuarios. Lo anterior a fin de predecir su gusto por una canción comparando sus respuestas con las de otros usuarios.

### 3.2.2. Descripción de los datos

Emotiv insight mediante el Suite de Medidas de Rendimiento, brinda información en tiempo real asociada a la variación de 5 estados afectivos básicos, cada uno puede representarse mediante la señal discreta según la ecuación 3.1. Donde,  $\tau$  es el periodo de muestreo,  $N$  es el número de muestras recolectadas durante el transcurso de la canción y  $e$  es un valor entre 0 y 1 en función del tiempo que representa la intensidad de la emoción, que varía en función de los estímulos del entorno [Radinsky et al. \(2011b\)](#); [Lang \(2012\)](#). Lo anterior se puede apreciar en la figura 3.1..

$$s = \sum_{n=1}^N e\delta(t - n) \quad (3.1)$$

## Capítulo 3. Captura y análisis de respuestas emocionales basadas en EEG

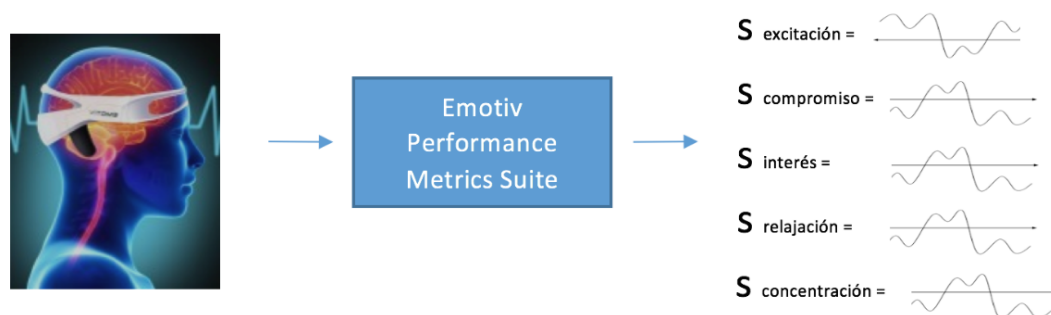


Figura 3.1: Estados afectivos detectados por Emotiv: Performance Metrics Suite

Periodo de muestreo ( $\tau$ )	1 segundo
Número máximo de muestras recolectadas por canción (N)	30
Duración máxima de la señal ( $T = N\tau$ )	30 segundos

Cuadro 3.1: parámetros escogidos para las señales recolectadas

Para el presente proyecto se tuvo en cuenta los parámetros seleccionados en el cuadro 3.1 para realizar la captura de datos, utilizando una frecuencia de muestreo de 1Hz. De esta forma la información sobre cada estado afectivo al escuchar una canción puede describirse según el vector  $A = \{a_i\}$ ,  $1 < i < 5 = \{excitación, compromiso, concentración, interés, relajación\}$ ; a su vez, cada  $a_i$  está conformado por un conjunto finito de valores  $e$ , entre 0 y 1. Excitación se define como la “experiencia de excitación fisiológica positiva”; compromiso es el “nivel de inmersión para una tarea en específico, reflejando el aburrimiento del usuario”; concentración “mide la profundidad y frecuencia de la atención hacia la actividad actual”; interés es “el nivel de atracción o rechazo por una actividad”; relajación “permite identificar que tan calmado está el usuario en el momento. Este valor está influenciado por la habilidad del usuario para relajarse y descansar después de un periodo de concentración intenso”<sup>3</sup>.

En el cuadro 3.1, el número máximo de muestras recolectadas se definió con base en la duración de los clips musicales que fueron seleccionados para la evaluación de la técnica propuesta. Cada clip musical tiene una duración de 30 segundos, de esta forma es posible recolectar una cantidad mayor de respuestas por parte de los usuarios durante las sesiones de prueba. Este tipo de aproximaciones se han utilizado previamente en el campo de la recomendación de música como en trabajos como Kim Kim et al. (2010) y Guo Guo et al. (2012b). Por su parte el periodo de muestreo de 1 segundo permite identificar cambios en el estado de ánimo del usuario durante el transcurso de la canción.

<sup>3</sup><https://emotiv.zendesk.com/hc/en-us/articles/201444095-Understanding-the-Performance-Metrics-Detection-Suite>

### 3.2.3. Exploración de datos

En esta sección se presenta un análisis de los datos recolectados durante las sesiones de experimentación. Al usar BraiM en un entorno de prueba se logró construir un dataset compuesto por los registros emocionales de 25 usuarios que escucharon en promedio 35 clips musicales de 30 segundos cada uno. Este dataset puede encontrarse en el siguiente enlace: [https://github.com/JesusEduardo2028/Braim\\_Rails/tree/master/database](https://github.com/JesusEduardo2028/Braim_Rails/tree/master/database).

	excitación	compromiso	concentración	interés	relajación
<b>Valor Promedio</b>	0.501436	0.720848	0.446188	0.493137	0.488115
<b>Desviación estándar</b>	0.257437	0.163738	0.122183	0.148797	0.123384
<b>Valor máximo</b>	0.985883	1.000000	0.769868	0.977674	0.666667

Cuadro 3.2: Parámetros estadísticos para cada variable emocional




Figura 3.2: Factor de correlación de Pearson entre variables emocionales

Utilizando información recolectada se realizó un análisis univariante para los registros obtenidos de cada estado afectivo, detallando características estadísticas descriptivas como: valor promedio, valor mínimo, valor máximo y desviación estándar. Estos parámetros resultan de gran utilidad para entender el comportamiento de los datos, informando sobre la tendencia general de cada variable. De esta forma se puede tener un primer acercamiento sobre la forma en la que se comporta la información que brinda Emotiv Insight. El propósito de este estudio es identificar, por ejemplo, aquellos estados afectivos que presentan desviaciones altas respecto a su media durante

## Capítulo 3. Captura y análisis de respuestas emocionales basadas en EEG

---

el transcurso de una canción, puesto que aportan información útil sobre los cambios emocionales del usuario. Los resultados de este análisis se exponen en la tabla 3.2. Por otra parte en la figura 3.2 se muestra una representación gráfica la correlación calculada para cada par de variables utilizando el coeficiente de correlación de Pearson.

Los resultados anteriores muestran que el estado afectivo excitación presenta una mayor desviación estándar promedio para las canciones escuchadas, por este motivo se espera que esta señal pueda brindar mejores resultados que las demás señales; dado que sus amplios cambios potencialmente describirían mejor la similitud en la variación de sus valores entre usuarios. Por su parte concentración presenta el valor promedio de desviación estándar más pequeño para todas las canciones escuchadas en comparación con las otras señales emocionales, lo que indica poca variación respecto a su media y no permite establecer diferencias significativas entre la percepción emocional de los usuarios al escuchar música. Además, mediante la comparación entre señales se identificó que los factores de correlación más altos se presentaron entre los estados afectivos relajación - compromiso y relajación- excitación. Lo anterior indica que a mayor grado de relajación en usuario, aumenta su grado de compromiso y excitación. A su vez la señal de interés presenta una correlación muy baja con las demás señales, hecho que genera gran expectativa para su utilización en la predicción de calificación de canciones. Harrison [Harrison \(2013\)](#) detectó un comportamiento similar para el dispositivo EPOC, exponiendo ciertas inquietudes asociadas a la forma como Emotiv clasifica estas emociones, debido a que comúnmente se asocia la excitación y compromiso como emociones opuestas a la relajación. Sin embargo, cabe mencionar que según el análisis realizado en este proyecto, ninguna de las emociones detectadas por Emotiv Insight presentaron correlaciones significativas que permitan establecer relaciones lineales entre ellas; por esta razón se realizará la experimentación con las 5 señales provistas por el dispositivo.

A partir del análisis estadístico presentado para cada estado afectivo, se plantea en la siguiente sección dos aproximaciones que permiten la utilización de la información recolectada para etiquetar las canciones escuchadas por los usuarios basados en sus respuestas al usar el dispositivo. Esta calificación “emocional”, permite comparar el comportamiento de los usuarios usando un enfoque distinto al filtrado colaborativo tradicional, en cumplimiento del objetivo general para la presente monografía.

### 3.3. Etiquetado de canciones usando información emocional

El reconocimiento de emociones en la música es visto como un problema de clasificación multi-clase o multi-etiqueta, donde se busca anotar una pieza musical utilizando un conjunto emociones [Kim et al. \(2010\)](#). Cada pieza musical, puede considerarse como una canción completa, una sección (coro, verso, etc.), un clip de duración fija (por



### 3.3 Etiquetado de canciones usando información emocional

lo general de 30 segundos), o un segmento de corta duración (1 segundo por ejemplo); el objetivo entonces, es representar la emoción en cada pieza como un vector multi-dimensional o una serie discreta de vectores. El valor de cada dimensión puede ser un valor binario para denotar la presencia o ausencia de una emoción; sin embargo generalmente se representa como un puntaje en una escala de Likert o mediante una estimación de probabilidad. La presente investigación propone 2 tipos de *etiquetas*, Señal discreta  $a_i$  y Puntaje  $P_i$  que permiten asociar de forma implícita las respuestas emocionales de los usuarios en canciones escuchadas mediante BraiM. Cabe mencionar que este tipo de calificación no expresa ningún tipo de preferencia o disgusto por una canción, sin embargo permitirá la definición de vecindades de usuarios con respuestas emocionales similares:

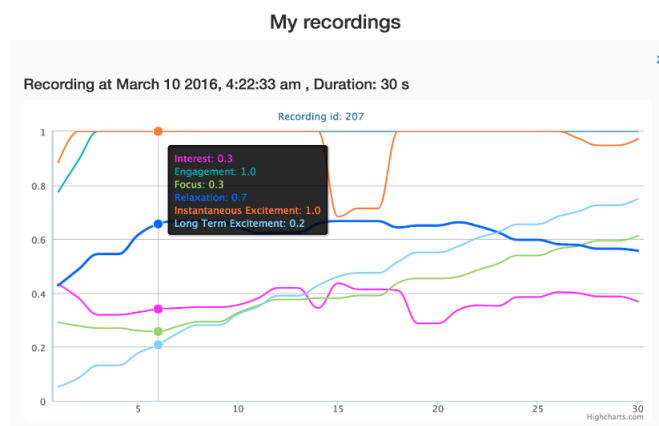


Figura 3.3: Señales capturadas por BraiM

**Señal discreta  $a_i$ :** consiste en el registro de cada estado afectivo durante el transcurso de la canción utilizando un periodo de muestreo de 1 segundo. Esta calificación formalmente se puede expresar mediante la señal discreta  $a_i$ , donde:  $a_i = e[n] = \{e_1 \dots e_n\}$ . En la figura 3.3 se aprecia la variación de los estados afectivos de un usuario para un clip musical de 30 segundos.

**Puntaje  $P_i$ :** este enfoque está basado en el trabajo de Cernea y otros [Cernea et al. \(2011\)](#), quienes proponen un mecanismo para utilizar la información entregada por el sistema de clasificación de emociones provisto por Emotiv. Consiste en asignar un puntaje  $P_i$  para cada señal  $a_i$ , mediante la detección de incrementos significativos en secciones de tiempo de duración fija. Cada señal se divide en fracciones de tiempo menores a T por lo general de entre 5 y 10 segundos, como se puede apreciar en la gráfica 3.4. Los puntos A y B son los valores máximos y mínimos respectivamente para un  $a_i$ , y los puntos C y D son valores inicial y final para una fracción de tiempo entre la duración total de la señal. Así, se asigna un puntaje entre 1 y 5 mediante la combinación de criterios que permiten identificar aquellos momentos en que la intensidad de la emoción aumenta, como se muestra a continuación:

## Capítulo 3. Captura y análisis de respuestas emocionales basadas en EEG

---

- Por defecto el puntaje  $P_i$  para toda  $a_i$  es 1, Se suma 1 punto si existe una fracción con un incremento mayor a 0.3.
- Se suma 1 punto si existe una fracción con un incremento mayor a 0.6.
- Se suma 1 punto si la diferencia entre el valor máximo y mínimo de  $a_i$  durante el periodo completo es mayor a 0.3
- Se suma 1 punto si la diferencia entre el valor máximo y mínimo de  $a_i$  durante el periodo completo es mayor a 0.6
- Los incrementos de cada fracción se miden encontrando la diferencia entre el valor inicial y final de  $a_i$  en esa ventana de tiempo.




Figura 3.4: Calificación emocional mediante reducción a un valor

Usando la descripción emocional discreta ( $a_i$ ), y la descripción emocional mediante reducción a un valor ( $P_i$ ) se plantea en el siguiente capítulo una técnica de filtrado colaborativo que permite comparar dichas calificaciones al escuchar música.

### 3.4. Resumen

En este capítulo se hace un análisis estadístico sobre la información que brinda Emotiv Insight, asociada con la respuesta emocional de los usuarios a partir de señales EEG. Para ello se hace énfasis en la metodología CRISP-DM, detallando cada uno de sus componentes. Este análisis permite hacer un primer acercamiento sobre los datos recolectados durante las sesiones de prueba, con el fin de proponer un mecanismo mediante el cual, es posible etiquetar una canción dependiendo de las respuestas emocionales de cada usuario. Las etiquetas propuestas son:  $a_i$ , compuesta por los registros para cada emoción detectados durante el transcurso de la canción; y  $P_i$ , que asigna un puntaje que depende de la variación de cada emoción. Estas etiquetas serán utilizadas posteriormente en el Capítulo 4, para proponer una técnica de predicción de calificación de música basada en vecindades de usuarios con respuestas similares.

# Capítulo 4

## Vecindad de usuarios y predicción

### 4.1. Vecindad

Detectar una vecindad de usuarios es el paso más importante en el proceso de diseño de SR mediante filtrado colaborativo (ver sección 2.2.3). Este proceso implica la definición de un factor de similitud entre usuarios y una técnica de selección de vecinos. A continuación se presenta un enfoque tradicional para el calculo de la vecindad de usuarios y seguidamente se exponen 2 alternativas basadas en la calificación emocional  $a_i$  y  $P_i$ , propuestas en el capitulo 3.

#### 4.1.1. Vecindad tradicional

Consiste en la selección de aquellas personas parecidas al usuario solicitante teniendo en cuenta su historial de calificaciones previas [Ekstrand et al. \(2011\)](#). Generalmente para determinar la similitud entre usuarios en un SRM se usa el factor de correlación de Pearson, determinando la dependencia estadística existente entre sus calificaciones para canciones comunes. Este procedimiento se expone en la ecuación 4.1.

$$s(u, v) = \frac{\sum_{j \in I_u \cap I_v} (r_{u,j} - \bar{r}_u)(r_{v,j} - \bar{r}_v)}{\sqrt{\sum_{j \in I_u \cap I_v} (r_{u,j} - \bar{r}_u)^2} \sqrt{\sum_{j \in I_u \cap I_v} (r_{v,j} - \bar{r}_v)^2}} \quad (4.1)$$

En la ecuación anterior,  $r_{u,j}$  y  $r_{v,j}$ , representan la calificación explícita (like/dislike, estrellas), o inferida (a partir de historial de reproducción previo) asignada para el ítem  $j$  por los usuarios  $u$  y  $v$  respectivamente. Por otra parte  $\bar{r}_u$  y  $\bar{r}_v$  representan las calificaciones promedio de cada uno. La identificación de la vecindad termina cuando se seleccionan aquellos usuarios cuyo valor de similitud  $s$  con usuario solicitante fue de mayor magnitud; además, se tiene en cuenta un valor umbral mínimo (threshold) y un número máximo de usuarios por vecindad (topN). En el algoritmo 1 se describe este proceso de forma completa.

---

**Algoritmo 1** Vecindad tradicional

---

```

1: INPUTS: Usuario solicitante  $u$ , set  $SR$  /*  $SR$  es el conjunto de calificaciones
   explícitas asignadas por los usuarios, o inferidas a partir de su consumo para cada
   canción: cada registro tiene la forma  $\{User : u, Song : j, Score : r_{u,j}\}$ */, double
   threshold, integer topN
2: OUTPUTS: set  $Netighborhood$ : /* lista de pares:  $\{user, similarity\}$  */
3: BEGIN
4: set  $U \leftarrow getUserTargetSet(SR)$  /* lista de usuarios objetivo */
5: set  $UserSimilarity \leftarrow similarityRanking(UserSimilarity)$  /* lista de tuplas:
    $\{requesterUser : u, targetUser : v, similarity : userSimilarity\}$  */
6: set  $songs_u \leftarrow getScoredSongs(u, SR)$  /* lista de canciones calificadas por el usua-
   rio solicitante  $u$  */
7: for each user  $v$  in  $U$  do
8:    $songs_v \leftarrow getScoredSongs(v, SR)$ 
9:    $commonSongs \leftarrow songs_u \cap songs_v$  /* lista de canciones calificadas por los
   usuarios  $u$  y  $v$  */
10:   $similarity \leftarrow s(u, v) = \frac{\sum_{j \in commonSongs} (r_{u,j} - \bar{r}_u)(r_{v,j} - \bar{r}_v)}{\sqrt{\sum_{j \in commonSongs} (r_{u,j} - \bar{r}_u)^2} \sqrt{\sum_{j \in commonSongs} (r_{v,j} - \bar{r}_v)^2}}$ 
11:   $UserSimilarity \leftarrow add(\{User : v, sim : similarity\})$ 
12: end for
13: for each  $similarity$  in  $UserSimilarity$  do
14:   if  $similarity > threshold$  then
15:      $Netighborhood \leftarrow add(similarity)$ 
16:   end if
17:   if  $iteration > topN$  then
18:     Break for
19:   end if
20: end for
21: Return  $Netighborhood$ 
22: END

```

---

### 4.1.2. Vecindad emocional

A diferencia del método tradicional, el factor de *similitud emocional* entre usuarios utiliza los métodos propuestos en la sección 3.3, para describir las canciones escuchadas. De esta forma el cálculo de la vecindad inicia mediante la detección de aquellos usuarios más similares al usuario solicitante dependiendo de su calificación  $a_i$ , compuesta por los cambios registrados cada segundo para un estado afectivo; o por  $P_i$  que reduce la señal  $a_i$  a un único valor dependiendo de la cantidad de incrementos significativos detectados durante el transcurso de la canción. A continuación se detalla el cálculo de ambos factores de similitud.

#### 4.1.2.1. Factor de similitud utilizando descripción de señal emocional.

En este caso el factor de similitud entre el usuario solicitante  $u$  y cualquier usuario del sistema  $v$ , se calcula mediante la comparación de los registros  $a_i$  para todas las canciones escuchadas por ambos usuarios. Este procedimiento puede analizarse desde dos puntos de vista, teniendo en cuenta el grado de procesamiento requerido para comparar las calificaciones emocionales recolectadas:

**Correlación promedio:** consiste en calcular la correlación entre las calificaciones  $a_i$  de forma independiente para toda canción escuchada por los usuarios  $u$  y  $v$ ; posteriormente se obtiene el valor promedio. De esta manera, la similitud encontrada corresponde a: .

$$sep_i(u, v) = \frac{\sum_{j \in J_u \cap J_v} PCOR(a_i(u, j), a_i(v, j))}{n} \quad (4.2)$$

En la ecuación especificada  $PCOR$  corresponde al coeficiente de correlación de Pearson entre las señales  $a_i(u, j)$  y  $a_i(v, j)$ . Cada una de estas señales registra los cambios en magnitud de un estado afectivo  $i$  durante el transcurso de la canción  $j$ , por el usuario  $u$  y  $v$  respectivamente.  $n$  es el número de canciones escuchadas por ambos usuarios. El proceso para la identificación de una vecindad basada en este factor de similitud se describe en el algoritmo 2; el cual, al igual que en la vecindad tradicional culmina mediante la selección de los usuarios más similares al usuario solicitante, utilizando un valor de umbral (threshold) y un límite de miembros (topN).

## Capítulo 4. Vecindad de usuarios y predicción

---



---

### Algoritmo 2 Vecindad usando correlación promedio de calificaciones

---

```

1: INPUTS : Usuario solicitante  $u$ , set  $ESR$  /*  $ESR$  es el conjunto
de calificaciones emocionales para cada canción. Cada registro tiene la
forma :  $\{User : u, Song : j, a_1 : \{e_1 \dots e_n\}, a_2 : \{e_1 \dots e_n\} \dots, a_5 : \{e_1 \dots e_5\}\}$  */ , double
 $threshold$ , integer  $topN$ , integer  $i$  /*  $i$  es el estado afectivo que se tendra en
cuenta para determinar de la similitud entre usuarios */
2: OUTPUTS : set  $Netighborhood$  : /* lista de pares :  $\{user, similarity\}$ 
3: BEGIN
4: set  $U \leftarrow getUserTargetSet(ESR)$  /* lista de usuarios objetivo */
5: set  $UserSimilarity \leftarrow similarityRanking(UserSimilarity)$  /* conjunto de tu-
plas :  $\{requesterUser : u, targetUser : v, similarity : userSimilarity\}$  */
6: set  $songs_u \leftarrow getRecords(u, ESR)$  /* lista de calificaciones emocinoales para las
canciones escuchadas por el usaurio solicitante */
7: for each user  $v$  in  $U$  do
8:    $songs_v \leftarrow getRecords(v, ESR)$ 
9:    $commonRecords \leftarrow songs_u \cap songs_v$  /* lista de calificaciones para las canciones
comunes entre el usaurio  $u$  y  $v$  */
10:    $similarity \leftarrow s_{ep}(u, v) = \frac{\sum_{j \in commonRecords} PCOR(a_i(u, j), a_i(v, j))}{n}$ 
11:    $UserSimilarity \leftarrow add(\{User : v, Sim : similarity\})$ 
12: end for
13: for each  $similarity$  in  $UserSimilarity$  do
14:   if  $similarity > threshold$  then
15:      $Netighborhood \leftarrow add(similarity)$ 
16:   end if
17:   if  $iteration > topN$  then
18:     Break for
19:   end if
20: end for
21: Return  $Netighborhood$ 
22: END

```

---

**Agregación de señales:** a diferencia del enfoque anterior este proceso se basa en el calculo de la similitud entre dos usuarios  $u$  y  $v$  mediante la agregación de los vectores  $a_i$  para las canciones escuchadas por ambos usuarios. Este proceso consiste en concatenar las señales  $a_i$  de cada usuario y calcular el factor de correlación de Pearson para los vectores resultantes. De esta forma se reduce la cantidad de procesamiento requerido al determinar similitud entre usuarios. Este factor de similitud corresponde a:

$$sea_i(u, v) = PCOR(\{a_i(u, j)\}_{j \in J_u \cap J_v}, \{a_i(v, j)\}_{j \in J_u \cap J_v}) \quad (4.3)$$

**Algoritmo 3** Vecindad usando correlación entre calificaciones agregadas

---

```

1: INPUTS : Usuario solicitante  $u$ , set  $ESR$  /*  $ESR$  es el conjunto
de calificaciones emocionales para cada canción. Cada registro tiene la
forma :  $\{User : u, Song : j, a_1 : \{e_1 \dots e_n\}, a_2 : \{e_1 \dots e_n\} \dots, a_5 : \{e_1 \dots e_5\}\}$  */ , double
 $threshold$ , integer  $topN$ , integer  $i$  /*  $i$  es el estado afectivo que se tendra en cuenta
para determinar de la similitud entre usuarios */
2: OUTPUTS : set  $Netighborhood$  : /* lista de pares :  $\{user, similarity\}$ 
3: BEGIN
4: set  $U \leftarrow getUserTargetSet(ESR)$  /* lista de usuarios objetivo */
5: set  $UserSimilarity \leftarrow similarityRanking(UserSimilarity)$  /* conjunto de tu-
plas :  $\{requesterUser : u, targetUser : v, similarity : userSimilarity\}$  */
6: set  $songs_u \leftarrow getRecords(u, ESR)$  /* lista de calificaciones emocinoales para las
canciones escuchadas por el usaurio solicitante */
7: for each user  $v$  in  $U$  do
8:    $songs_v \leftarrow getRecords(v, ESR)$ 
9:    $commonRecords \leftarrow songs_u \cap songs_v$  /* lista de calificaciones para las canciones
comunes entre el usaurio  $u$  y  $v$  */
10:    $similarity \leftarrow s_{ea}(u, v) = PCOR(\{a_i(u, j)\}_{j \in I_u \cap I_v}, \{a_i(v, j)\}_{j \in I_u \cap I_v})$ 
11:    $UserSimilarity \leftarrow add(\{User : v, Sim : similarity\})$ 
12: end for
13: for each  $similarity$  in  $UserSimilarity$  do
14:   if  $similarity > threshold$  then
15:      $Netighborhood \leftarrow add(similarity)$ 
16:   end if
17:   if  $iteration > topN$  then
18:     Break for
19:   end if
20: end for
21: Return  $Netighborhood$ 
22: END

```

---

Por su parte el proceso para la definición de la vecindad de usuarios utilizando este factor de similitud se describe en el algoritmo 3

#### 4.1.2.2. Factor de similitud usando $P_i$

En este caso al igual que en el enfoque tradicional se utilizará la correlación de Pearson para hacer la comparación entre usuarios, por sus beneficios en términos de precisión y eficiencia [Ekstrand et al. \(2011\)](#). Sin embargo, esta aproximación considera el uso de  $P_i$  como alternativa a la calificación explícita de los usuarios.  $P_i$  como se mencionó en la sección 3.3 es un valor que tiene en cuenta incrementos significativos mayores a 0.3 y 0.6 para una señal  $a_i$  durante el transcurso de la canción. De esta forma el

## Capítulo 4. Vecindad de usuarios y predicción

---

factor de similitud entre dos usuarios  $u$  y  $v$  se define a continuación :

$$sp_i(u, v) = \frac{\sum_{j \in J_u \cap J_v} (P_i(u, j) - P_i(\bar{u}))(P_i(v, j) - P_i(\bar{v}))}{\sqrt{\sum_{j \in J_u \cap J_v} (P_i(u, j) - P_i(\bar{u}))^2} \sqrt{\sum_{j \in J_u \cap J_v} (P_i(v, j) - P_i(\bar{v}))^2}} \quad (4.4)$$

---

**Algoritmo 4** Vecindad usando correlación entre calificaciones  $P_i$

---

- 1: **INPUTS** : Usuario solicitante  $u$ , set  $PSR$  /\*  $PSR$  es el conjunto de calificaciones  $P_i$  para cada canción. Cada registro tiene la forma :  $\{User : u, Song : j, P_1 : \{e_1 \dots e_n\}, P_2 : \{e_1 \dots e_n\} \dots, P_5 : \{e_1 \dots e_5\}\}$ \*/, double  $threshold$ , integer  $topN$ , integer  $i$  /\*  $i$  es el estado afectivo que se tendrá en cuenta para determinar de la similitud entre usuarios\*/
  - 2: **OUTPUTS** : set  $Netighborhood$  : /\* lista de pares :  $\{user, similarity\}$
  - 3: **BEGIN**
  - 4: set  $U \leftarrow getUserTargetSet(PSR)$  /\* lista de usuarios objetivo \*/
  - 5: set  $UserSimilarity \leftarrow similarityRanking(UserSimilarity)$  /\* conjunto de tuplas :  $\{requesterUser : u, targetUser : v, similarity : userSimilarity\}$ \*/
  - 6: set  $songs_u \leftarrow getRecords(u, PSR)$  /\* lista de calificaciones emocionales para las canciones escuchadas por el usuario solicitante \*/
  - 7: **for** each user  $v$  **in**  $U$  **do**
  - 8:      $songs_v \leftarrow getRecords(v, PSR)$
  - 9:      $commonRecords \leftarrow songs_u \cap songs_v$  /\* lista de calificaciones para las canciones comunes entre el usuario  $u$  y  $v$ \*/
  - 10:      $similarity \leftarrow sp_i(u, v) = \frac{\sum_{j \in J_u \cap J_v} (P_i(u, j) - P_i(\bar{u}))(P_i(v, j) - P_i(\bar{v}))}{\sqrt{\sum_{j \in J_u \cap J_v} (P_i(u, j) - P_i(\bar{u}))^2} \sqrt{\sum_{j \in J_u \cap J_v} (P_i(v, j) - P_i(\bar{v}))^2}}$
  - 11:      $UserSimilarity \leftarrow add(\{User : v, Sim : similarity\})$
  - 12: **end for**
  - 13: **for** each  $similarity$  **in**  $UserSimilarity$  **do**
  - 14:     **if**  $similarity > threshold$  **then**
  - 15:          $Netighborhood \leftarrow add(similarity)$
  - 16:     **end if**
  - 17:     **if**  $iteration > topN$  **then**
  - 18:         **Break for**
  - 19:     **end if**
  - 20: **end for**
  - 21: **Return**  $Netighborhood$
  - 22: **END**
- 

En la ecuación anterior,  $P_i(u, j)$  y  $P_i(v, j)$ , representan el puntaje de incrementos significativos para la canción  $j$ , a partir del análisis de vectores  $a_i$  por los usuarios  $u$  y  $v$  respectivamente. De igual forma  $P_i(\bar{u})$  y  $P_i(\bar{v})$  representan los valores promedio para cada uno.



La vecindad para el usuario solicitante puede determinarse usando este factor de similitud de la misma forma como se describe de forma similar a la vecindad tradicional en el algoritmo 4. Sin embargo, en este caso el conjunto de datos de entrada esta compuesto por la lista de puntajes  $P_i$  para todas las canciones escuchadas por los usuarios en el sistema.

## 4.2. Predicción

En la sección anterior se definió el concepto de vecindad y se presentaron enfoques alternativos para el cálculo de la misma, mediante la definición de los tres factores de similitud entre usuarios que utilizan la información emocional recolectada; de esta forma se cumple con primer objetivo específico de la presente monografía: “Proponer una técnica de similitud entre usuarios basada en la comparación de sus respuestas emocionales al momento de escuchar música”. En esta sección se procede con la definición un técnica de agregación que permite utilizar retroalimentación de los usuarios presentes en dicha vecindad, con el fin de predecir la calificación de una canción desconocida por el usuario solicitante.

### 4.2.1. Predicción basada en calificaciones ponderadas

Para hacer recomendaciones de ítems, el filtrado colaborativo tradicional combina la calificación de los usuarios pertenecientes a una vecindad de usuarios similares  $N$  (ver sección 2.2.3). En la Ecuación 4.5 se presenta la ecuación para filtrado colaborativo tradicional.

$$c(u, j) = r_u + \frac{\sum_{v \in N} s(u, v)(r_{v,j} - r'_v)}{\sum_{v \in N} ||s(u, v)||} \quad (4.5)$$

En la ecuación anterior al restar la calificación promedio  $r_v$  de cada usuario presente en la vecindad, se busca compensar la diferencia con la que dichos usuarios usan la escala de ratings (estrellas / votos / etc..). Esto se debe a que algunas personas tienden a utilizar valores altos para expresar su preferencia por un ítem [Ekstrand et al. \(2011\)](#), mientras que otros usan por lo general calificaciones bajas. En el contexto de la recomendación de música este procedimiento inicia como se describe en el algoritmo 5, identificando aquellas canciones escuchadas por la vecindad de usuarios y que son desconocidas para el usuario solicitante (líneas 5 y 6). Posteriormente predice la calificación de cada canción para este usuario, ponderando la calificación de sus usuarios vecinos. Además, se asigna mayor peso a la calificación de aquellos usuarios con un alto valor de similitud (líneas 9 y 10 ). Los parámetros de entrada para este enfoque de predicción son los siguientes:

- Usuario solicitante.
- Canción objetivo por la que se espera una calificación predicha.

## Capítulo 4. Vecindad de usuarios y predicción

---

- Lista de usuarios vecinos al usuario solicitante (Vecindad tradicional, sección 4.1.1).
- Calificación de los usuarios en el sistema. Esta información se compone por una lista de registros que tienen el siguiente formato:  $\{User : u, Song : j, Score : r_{u,j}\}$ ; donde  $u$  es un usuario que brinda la calificación  $r(u, j)$  para la canción  $j$ . Esta calificación puede ser obtenida de forma explícita (ratings) o implícita (inferida a partir del historial de reproducción).

---

### Algoritmo 5 Filtrado colaborativo tradicional

---

- 1: **INPUTS** : Usuario solicitante  $u$ , Cancion objetivo  $j$ , Vecindad mediante factor de similitud  $sep_i = N$ , set  $SR$  /\*  $SR$  es el conjunto de calificaciones explicitas asignadas por los usuarios, o inferidas a partir de su consumo para cada canción : cada registro tiene la forma  $\{User : u, Song : j, Score : r_{u,j}\}$  \*/ , integer  $topN$
  - 2: **OUTPUTS** : float  $predictedRating$  /\* predicción realizada por el sistema para la canción  $u$ .
  - 3: **BEGIN**
  - 4:  $U' \leftarrow lookupUsersFromNeighborhood(N, SR, j)$  /\* usuarios que han calificado la canción objetivo, y que pertenecen a la vecindad \*/
  - 5:  $r(u, j) \leftarrow c(u, j) = r_u + \frac{\sum_{v \in N} s(u,v)(r_{v,j} - r_v)}{\sum_{v \in N} ||s(u,v)||}$
  - 6:
  - 7:  $predictedRating = r(u, j)$  /\*
  - 8: **end for**
  - 9: **Return**  $predictedRating$
  - 10: **END**
- 

### 4.2.2. Predicción mediante vecindades basadas en información emocional

Para cumplir con el objetivo general de este proyecto, se propone utilizar la técnica de predicción expuesta en la sección anterior (calificaciones ponderadas); teniendo en cuenta el calculo de tres tipos de vecindades alternativas basadas en información emocional (Sección 4.1.2).

La adaptación para hacer una predicción basada en información emocional considera el uso de la ecuación 4.1; reemplazando el factor de similitud  $s$  como se muestra a continuación:

#### 4.2.2.1. Predicción por correlación promedio de señales emocionales $a_i$ .

Este tipo de predicción utiliza las calificaciones realizadas por usuarios similares al solicitante, ponderándolas de acuerdo a un factor de similitud igual al promedio de la correlación de sus respuestas emocionales; las cuales fueron descritas como señales discretas. Además, de esta predicción se derivan 5 alternativas que dependen del tipo

de señal emocional  $i$  seleccionada ( $1 < i < 5 = \{interés, compromiso, concentración, relajación, excitación\}$ ). La predicción en este caso se calcula mediante la ecuación 4.6.

$$cep_i(u, j) = r'_u + \frac{\sum_{v \in N_{sep_i}} sep_i(u, v)(r_{v,j} - r'_v)}{\sum_{v \in N_{sep_i}} ||sep_i(u, v)||} \quad (4.6)$$

---

**Algoritmo 6** Predicción por correlación promedio de señales emocionales  $a_i$

---

- 1: **INPUTS** : Usuario solicitante  $u$ , Cancion objetivo  $j$ , Vecindad mediante factor de similitud  $sep_i = N_{sep_i}$ , set  $SR$  /\*  $SR$  es el conjunto de calificaciones explicitas asignadas por los usuarios, o inferidas a partir de su consumo para cada canción : cada registro tiene la forma  $\{User : u, Song : j, Score : r_{u,j}\}$  \*/
  - 2: **OUTPUTS** : float  $predictedRating$  /\* predicción realizada por el sistema para la canción  $u$ .
  - 3: **BEGIN**
  - 4:  $U' \leftarrow lookUpUsersFromNeighborhood(N_{sep_i}, SR, j)$  /\* usuarios que han calificado la canción objetivo, y que pertenecen a la vecindad \*/
  - 5:  $r(u, j) \leftarrow cep_i(u, j) = r'_u + \frac{\sum_{v \in N_{sep_i}} sep_i(u, v)(r_{v,j} - r'_v)}{\sum_{v \in N_{sep_i}} ||sep_i(u, v)||}$  /\* lista de calificaciones para las canciones comunes entre el usuario  $u$  y  $v$  \*/
  - 6:  $predictedRating = r(u, j)$
  - 7: **end for**
  - 8: **Return**  $predictedRating$
  - 9: **END**
- 

En la anterior ecuación  $cep_i$  es la predicción calculada para una canción objetivo  $j$ , por un usuario solicitante  $u$ . Por su parte  $N_{sep_i}$  corresponde a la vecindad de usuarios mediante la similitud  $sep_i$  (Ecuación 4.2). Por último  $r'_u$  y  $r'_v$  corresponde a la calificación promedio para las canciones escuchadas de los usuarios  $u$  y  $v$  respectivamente. Este procedimiento se describe en el algoritmo 6.

### 4.2.2.2. Predicción por correlación de señales emocionales $a_i$ agregadas.

Esta predicción pondera la calificación de los usuarios similares al usuario solicitante, de acuerdo a un factor de similitud igual a la correlación de sus respuestas emocionales agregadas para todas las canciones escuchadas. Al igual que en el enfoque anterior las respuestas emocionales fueron descritas como señales discretas y la predicción se deriva en 5 alternativas según la señal emocional  $i$  seleccionada. En este caso la predicción se calcula mediante la ecuación 4.6.

$$cea_i = r'_u + \frac{\sum_{v \in N_{sea_i}} sea_i(u, v)(r_{v,j} - r'_v)}{\sum_{v \in N_{sea_i}} ||sea_i(u, v)||} \quad (4.7)$$

## Capítulo 4. Vecindad de usuarios y predicción

---



---

### Algoritmo 7 Predicción por correlación de señales emocionales $a_i$ agregadas

---

- 1: **INPUTS** : Usuario solicitante  $u$ , Cancion objetivo  $j$ , Vecindad mediante factor de similitud  $sep_i = N_{sep_i}$ , set  $SR$  /\*  $SR$  es el conjunto de calificaciones explicitas asignadas por los usuarios, o inferidas a partir de su consumo para cada canción : cada registro tiene la forma  $\{User : u, Song : j, Score : r_{u,j}\}$  \*/
  - 2: **OUTPUTS** : float  $predictedRating$  /\* predicción realizada por el sistema para la canción  $u$ .
  - 3: **BEGIN**
  - 4:  $U' \leftarrow lookUpUsersFromNeighborhood(N_{sep_i}, SR, j)$  /\* usuarios que han calificado la canción objetivo, y que pertenecen a la vecindad \*/
  - 5:  $r(u, j) \leftarrow cea_i = r'_u + \frac{\sum_{v \in N_{sea_i}} sea_i(u, v)(r_{v,j} - r'_v)}{\sum_{v \in N_{sea_i}} \|sea_i(u, v)\|}$  /\* lista de calificaciones para las canciones comunes entre el usuario  $u$  y  $v$  \*/
  - 6:  $predictedRating = r(u, j)$
  - 7: **end for**
  - 8: **Return**  $predictedRating$
  - 9: **END**
- 

En la anterior ecuación  $cea_i$  es la predicción calculada para una canción objetivo  $j$ , por un usuario solicitante  $u$ . Por su parte  $N_{sea_i}$  corresponde a la vecindad de usuarios mediante la similitud  $sea_i$  (Ecuación 4.3). Por último  $r'_u$  y  $r'_v$  corresponde a la calificación promedio para las canciones escuchadas de los usuarios  $u$  y  $v$  respectivamente. Este procedimiento se describe en el algoritmo 7.

#### 4.2.2.3. Predicción por puntaje emocional $P_i$ .

A diferencia de los 2 enfoques anteriores, en este caso las respuestas emocionales fueron descritas como un puntaje calculado a partir de la detección de incrementos significativos de sus señales emocionales discretas. De esta forma esta predicción pondera la calificación de los usuarios similares al usuario solicitante, de acuerdo al factor de similitud igual a la correlación los puntajes  $P_i$  para las canciones en común. En este caso la predicción únicamente tiene en cuenta la emoción *excitación* ( $i = 5$ ), puesto que fue la única que presento una variación suficiente para generar calificaciones mayores a 0 según el procedimiento descrito en la sección 3.3. En este caso la predicción se calcula mediante la ecuación 4.6.

$$cp_i = r'_u + \frac{\sum_{v \in N_{sp_i}} sp_i(u, v)(r_{v,j} - r'_v)}{\sum_{v \in N_{sp_i}} \|sp_i(u, v)\|} \quad (4.8)$$

En la anterior ecuación  $cp_i$  es la predicción calculada para una canción objetivo  $j$ , por un usuario solicitante  $u$ . Por su parte  $N_{sp_i}$  corresponde a la vecindad de usuarios mediante la similitud  $sp_i$  (Ecuación 4.4). Por último  $r'_u$  y  $r'_v$  corresponde a la calificación promedio para las canciones escuchadas de los usuarios  $u$  y  $v$  respectivamente. Este procedimiento se describe en el algoritmo 8 .

**Algoritmo 8** Predicción por puntaje emocional  $P_i$ 

- 
- 1: **INPUTS** : Usuario solicitante  $u$ , Cancion objetivo  $j$ , Vecindad mediante factor de similitud  $sp_i = N_{sp_i}$ , set  $SR$  /\*  $SR$  es el conjunto de calificaciones explicitas asignadas por los usuarios, o inferidas a partir de su consumo para cada canción : cada registro tiene la forma  $\{User : u, Song : j, Score : r_{u,j}\}$  \*/
  - 2: **OUTPUTS** : float  $predictedRating$  /\* predicción realizada por el sistema para la canción  $u$ .
  - 3: **BEGIN**
  - 4:  $U' \leftarrow lookUpUsersFromNeighborhood(N_{sp_i}, SR, j)$  /\* usuarios que han calificado la canción objetivo, y que pertenecen a la vecindad \*/
  - 5:  $r(u, j) \leftarrow cp_i = r'_u + \frac{\sum_{v \in N_{sp_i}} sp_i(u, v)(r_{v, j} - r'_v)}{\sum_{v \in N_{sp_i}} ||sp_i(u, v)||}$  /\* lista de calificaciones para las canciones comunes entre el usaurio  $u$  y  $v^*$  \*/
  - 6:  $predictedRating = r(u, j)$
  - 7: **end for**
  - 8: **Return**  $predictedRating$
  - 9: **END**
- 

### 4.3. Resumen

En este capítulo se exploraron los componentes y procedimientos que usan SRM basados en filtrado colaborativo para predecir la calificación de los usuarios. Lo anterior, a fin de comparar la forma en que estas técnicas determinan vecindades de usuarios con una alternativa que tiene en cuenta la captura de respuestas emocionales al escuchar música. La principal diferencia entre la vecindad tradicional y la vecindad propuesta en este proyecto, es que el factor de similitud utilizado para comparar a los usuarios del sistema se basa en la descripción “emocional” de las canciones. Esta se determina mediante la recolección de información sobre cambios en 5 emociones detectadas por Emotiv insight, a partir de la clasificación de señales EEG.

En términos generales: se plantearon tres tipos de vecindad de usuarios, aplicando distintos enfoques sobre cómo comparar los cambios en las emociones detectadas por Emotiv durante el transcurso de la canción (sección 4.1). De esta forma se utilizó este estudio para plantear alternativas sobre la predicción realizada en el filtrado colaborativo tradicional (sección 4.2.2). Un resumen de las técnicas planteadas en este capítulo se muestra en el cuadro 4.1.

## Capítulo 4. Vecindad de usuarios y predicción

---

<b>Característica</b>	<b>Predicción tradicional</b> Ecuación 4.5 (Algoritmo 5)	<b>Predicción por correlación promedio de señales emocionales</b> $a_i$ . Ecuación 4.6 (Algoritmo 6)	<b>Predicción por correlación de señales emocionales <math>a_i</math> agregadas.</b> Ecuación 4.7 (Algoritmo 7)	<b>Predicción por puntaje emocional <math>P_i</math>.</b> Ecuación 4.8 (Algoritmo 8)
<b>Datos de soporte</b>	- Historial, calificación explícita (estrellas / likes)	- Vectores $a_i$ , de usuarios vecinos - Historial, calificación explícita (estrellas / likes)		- Puntaje $P_i$ , de usuarios vecinos - Historial, calificación explícita (estrellas / likes)
<b>Calificación</b>	Historial, calificación explícita (estrellas / likes)			
<b>Vecindad</b>	Tradicional (algoritmo 1)	mediante factor de similitud $sep_i$ (algoritmo 2)	mediante factor de similitud $sea_i$ (algoritmo 3)	mediante factor de similitud $sp_i$ (algoritmo 4)
<b>Explicación</b>	“Las canciones preferidas por personas con tus mismos gustos”	“Las canciones preferidas por personas con tus mismas respuestas emocionales”		

Cuadro 4.1: Técnicas de predicción propuestas

## Parte III

# Experimentación y resultados

# Capítulo 5

## Descripción de la solución

Para cumplir con el objetivo general del presente proyecto y en el marco del segundo objetivo específico: “Implementar un mecanismo de predicción que utilice la técnica de similitud de usuarios propuesta”, este capítulo contiene un resumen del proceso metodológico utilizado para el desarrollo e implementación de “BraiM”; una plataforma Web de recomendación de música, que utiliza información sobre las respuestas emocionales de los usuarios para sugerir canciones mediante la técnica de predicción propuesta en la sección 4.2. En ese orden de ideas a continuación se describen las metodologías utilizadas para la documentación arquitectural y desarrollo de dicha aplicación (Sección 5.1); posteriormente se presenta al lector una descripción detallada del sistema mediante vistas basadas en la metodología Views&Beyond [Garlan et al. \(2010\)](#). Por último se expone una relación entre las vistas de la arquitectura planteada con el objetivo de entender el sistema desde una perspectiva global.

### 5.1. Metodologías utilizadas

#### 5.1.1. Scrum

Scrum es un marco para gestionar proyectos o desarrollar productos y aplicaciones software que se caracteriza por ser ágil, iterativo e incremental. Es flexible y no está ligado a un único proceso estandarizado de pasos predefinidos durante el desarrollo del proyecto; por el contrario es el equipo de trabajo quien está encargado implementar buenas prácticas para la gestión del mismo a partir de una serie de lineamientos básicos [Rubin \(2012\)](#). Este enfoque es ideal para la creación de prototipos software debido a que está pensado para funcionar en entornos reales donde es muy común la aparición de inconvenientes impredecibles, que afectan el desarrollo del proyecto al no ser manejados adecuadamente por las metodologías tradicionales de planificación. Scrum adopta una visión empírica que se centra en la entrega rápida de resultados mediante iteraciones de corta duración, que permiten tener versiones funcionales de la aplicación de forma anticipada, descartando riesgos críticos que puedan aparecer en una etapa avanzada del proyecto.

La implementación de esta metodología en este proyecto de investigación inicia mediante la definición de roles y responsabilidades. Dado que Scrum es un marco de



trabajo, este puede ser adaptado a las condiciones del equipo. En este caso los roles que se tuvieron en cuenta según la metodología son los siguientes:

- **Product Owner:** Es el encargado de definir y refinar una lista de historias de usuario priorizadas. Además, es el encargado de definir los criterios de aceptación de cada historia y decide la duración máxima que debe tener cada iteración de trabajo. Cada historia de usuario representa un requisito en lenguaje sencillo que describe el resultado deseado en la aplicación y debe tener la siguiente estructura:

Como <rol> quiero <objetivo / propósito> para <beneficio / razón>

- **Desarrollador:** Es el encargado de desarrollar cada historia de usuario y seleccionar cuales van a ser trabajadas en cada iteración. En este proyecto solo se cuenta con un estudiante como integrante del equipo de desarrollo, por ello es quien decide como líder del equipo la forma en que se hace seguimiento al trabajo realizado.

### 5.1.1.1. Flujo de trabajo

1. El flujo de trabajo inicia mediante la definición de una lista de historias de usuario priorizadas (**Product Backlog**) y la duración que tendrá cada ciclo de desarrollo (**Sprint**).
2. Se realiza una definición de planificación de Sprint. En esta etapa se deciden los elementos del product backlog se intentarán desarrollar durante la ejecución de cada iteración. Por su parte el equipo de desarrollo debe estimar la cantidad de tiempo que tomara desarrollar cada elemento.
3. El equipo de desarrollo inicia con la construcción de la solución a partir de las historias seleccionadas, especificando en un documento online el estado actual de cada una. Así, el product owner puede aprobar o rechazar una historia completa en cualquier momento. Se tuvieron en cuenta 7 estados para las historias de usuario:
  - a) **Urgente:** un item urgente que va a ser siempre el primero en la cola. Puede afectar el flujo de trabajo de otros elementos (ejemplo. el sistema esta offline).
  - b) **Con fallas:** un item que falla después de ser desplegado en producción (ejemplo. la interfaz tiene un bug), puede ir de primero en la cola dependiendo de la naturaleza del problema.
  - c) **Rechazado:** un item que ha sido rechazado por el product owner y no puede ser enviado a producción antes de ser revisado.
  - d) **Seleccionado:** un item seleccionado por el equipo de desarrollo para ser implementado.

## Capítulo 5. Descripción de la solución

- e) **En revisión:** un item que ha sido completado y esta esperando revision del product owner.
- f) **Completo:** un item que ha sido completado y esta listo para ser desplegado en un entorno real.
- g) **Descartado:** en cualquier momento un item puede descartarse, sin embargo puede seguir en el backlog y ser tenido en cuenta si es necesario en el futuro.

4. Al final de cada sprint se realiza una reunión de retrospectiva; donde el equipo reflexiona sobre su propio proceso, inspeccionan su comportamiento y adoptan las medidas para adaptarlo en los futuros Sprints.

### 5.1.1.2. Adaptación

- Las historias que no se completan durante la ejecución del sprint, vuelven al product backlog.
- Al final de cada Sprint se obtiene como resultado un versión usable del prototipo; este ciclo se repetirá tantas veces sea necesario hasta completar el producto.
- Un sprint inicia con una reunión de planificación y termina en la reunión de retrospectiva.
- El estado de cada historia de usuario puede ser actualizado en un documento online por el equipo de trabajo o el product owner. En la figura 5.1 se puede visualizar la plantilla utilizada para hacer este proceso durante cada sprint.

Estados	0-Urgente	1-Con fallas	2-Rechazado	3-Seleccionado				
Tipos	4-En revisión	5-Complete	6-Backlog	7-Descartado				
Tiempo estimado	Historia de Usuario	Bug	Trabajo técnico	Adquisición de conocimiento				
	? - 0 - 0,5 - 1 - 2 - 3 - 5 - 8 - 13 - 20 - 40 - 100 - infinite							
ID	Tipo	Nombre	Como	Quiero	Para	Estimate	Sprint	Status
8	Historia de Usuario	Login y Registro	Usuario	Una interfaz de login	iniciar sesión	8	1	5-Complete
9	Historia de Usuario	Login y Registro	Usuario	Una interfaz de registro	ingresar datos personales	13	1	5-Complete
17	Historia de Usuario	Login y Registro	Usuario	Una barra lateral de opciones	mejorar la navegabilidad de la plataforma	4	1	5-Complete
11	Historia de Usuario	Emotiv SDK	Usuario	Una interfaz con el estado de los sensores	visualizar el estado actual del dispositivo	20	1	5-Complete
10	Historia de Usuario	Emotiv SDK	Usuario	Una interfaz en la barra superior con el estado general del sensor	visualizar el estado actual del dispositivo	20	1	5-Complete
12	Historia de Usuario	Spotify SDK	Usuario	Una interfaz de búsqueda de canciones	escuchar la canción deseada	20	1	5-Complete
13	Historia de Usuario	Spotify SDK	Usuario	Una perfil de usuario con el historial de reproducción	visualizar las canciones previam	20	2	5-Complete
14	Historia de Usuario	Emotiv Performance metrics Suite	Usuario	Un modal con los registros obtenidos despues de escuchar cada canción en el historial	visualizar las emociones del usuario durante la canción	20	2	3-Picked
15	Historia de Usuario	Emotiv Performance metrics Suite	Usuario	Una interfaz que muestre la información obtenida por el suite de emotiv	visualizar las emociones del usuario en tiempo real	20	2	3-Picked

Figura 5.1: Vista del Sprint

### 5.1.2. View and Beyond (V&B)

Con el objetivo de mejorar la toma de decisiones sobre los distintos elementos estructurales pertenecientes a BraiM: sus interfaces, comportamiento y composición; se utilizó V&B como herramienta para la documentación de arquitecturas software, permitiendo que cada componente sea diseñado bajo altos criterios de calidad. Adicionalmente, este proceso funciona como registro sobre las decisiones tomadas durante la etapa de diseño, para entender cómo se construyó la solución planteada y continuar adicionando funcionalidades en el futuro. V&B es una guía para documentar distintos tipos de información en una arquitectura, como sus estructuras, interfaces, comportamientos, relaciones, fundamentos, contexto, etc [Rubin \(2012\)](#). Además funciona muy bien cuando se utiliza en conjunto con metodologías de desarrollo ágil.

## 5.2. Vistas del sistema

V&B enfatiza en la “Vista” como principio fundamental en una arquitectura, definiendo este concepto como la representación de un conjunto de elementos del sistema cuando se aplica un “estilo arquitectural”; cada estilo plantea lineamientos y herramientas de análisis e implementación, que permiten agilizar el proceso de documentación de la arquitectura software. A continuación se expone la aplicación de los tres estilos de arquitectura según V&B en el presente proyecto, definidos por Garlan y otros [Garlan et al. \(2010\)](#): Módulos, C&C (Componentes y Conectores) y Asignación.

### 5.2.1. Módulos

Este tipo de estilo de arquitectura permite representar cómo está construido el sistema mediante unidades de implementación (módulos), detallando sus responsabilidades y relaciones. Además, se hace énfasis en la jerarquía de cada componente. Teniendo en cuenta lo anterior en la figura 5.2 se muestra la Vista de descomposición para la presentación general del sistema.

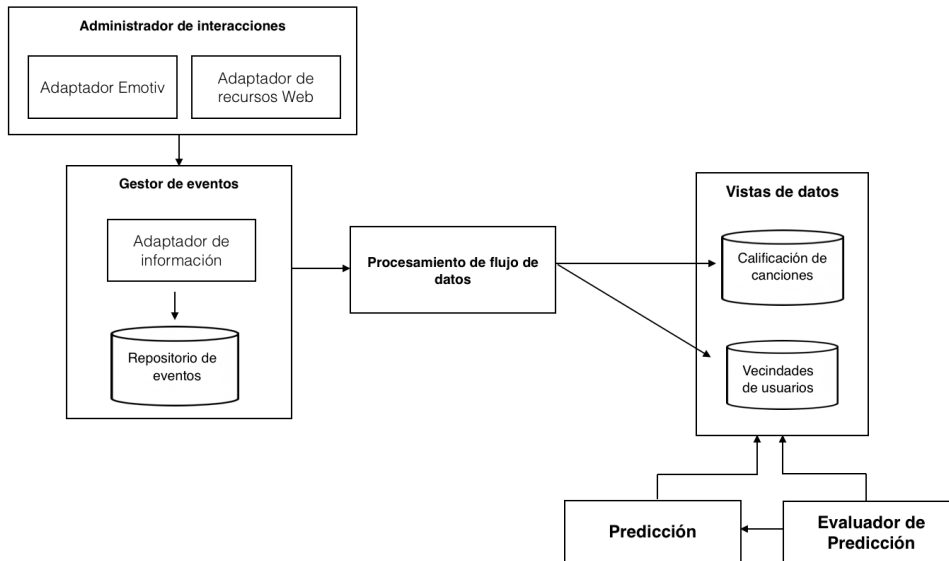


Figura 5.2: Vista de descomposición del sistema

La arquitectura planteada se basa en capturar todos los eventos en crudo sobre el comportamiento de los usuarios en la aplicación, y aplicar tareas sobre dicha información para generar “vistas de datos” con información preprocesada. Este enfoque está basado en arquitecturas que se usan comúnmente para procesar grandes volúmenes de datos, (Arquitectura lambda [Marz and Warren \(2015\)](#)) y en este caso permitirá agilizar la consulta realizada por algoritmo de recomendación.

### 5.2.1.1. Catálogo de componentes

**Administrador de interacciones:** encargado de gestionar los componentes que hacen posible la interacción del usuario final con la aplicación. Los elementos que soportan este módulo son:

- **Adaptador Emotiv:** permite la comunicación con el dispositivo Emotiv Insight vía Bluetooth LE. De esta forma se puede visualizar el estado actual del dispositivo y determinar calidad en el desempeño de cada sensor. Además se encarga de utilizar las librerías con que cuenta el suite de medidas de rendimiento (sección 3.2), para hacer una medición constante sobre la respuesta emocional del usuario al escuchar música en la aplicación.
- **Adaptador de recursos Web:** gestiona la búsqueda de canciones o artistas mediante recursos Web REST, permitiendo al usuario escuchar la música que desea y acceder a su historial de reproducción.

**Gestor de eventos:** módulo encargado de capturar las acciones realizadas por el usuario a través del administrador de interacciones para su posterior análisis. Este módulo está soportado por el siguiente conjunto de sub-módulos:

field	datatype
user_id	INTEGER
song_id	INTEGER
excitement	ARRAY
relaxation	ARRAY
focus	ARRAY
interest	ARRAY
engagement	ARRAY
timestamp	FLOAT

Cuadro 5.1: Esquema JSON para el evento **recording**

field	datatype
user_id	INTEGER
song_id	INTEGER
rating	INTEGER
timestamp	FLOAT

Cuadro 5.2: Esquema JSON para el evento **rating**

- **Adaptador de información:** gracias a este componente se persisten los datos sobre la interacción del usuario con el sistema en forma de eventos. BraiM tiene en cuenta dos tipos de eventos principales: *recording* y *rating*. El evento *recording* registra la información recolectada por el adaptador emotiv cuando cualquier usuario escucha al menos 30 segundos de una canción. Por su parte *rating* hace referencia a su calificación explícita en una escala de 5 estrellas para dicha canción. Cada evento se serializa en un JSON con una lista de atributos predefinidos, como se muestra en el cuadro 5.1 y cuadro 5.2 respectivamente.
- **Repositorio de eventos:** repositorio que almacena todos los eventos registrados a través de BraiM. Funciona como un registro inmutable de información, utilizado generalmente en arquitecturas software para manejar grandes volúmenes de datos [Marz and Warren \(2015\)](#). Los registros en esta clase de repositorios únicamente pueden ser añadidos, mas no eliminados o modificados, puesto que se consideran eternamente verdaderos. Cabe mencionar que estos datos deben pasar por una etapa de procesamiento previo antes de que puedan ser utilizados por el algoritmo de predicción.

**Procesamiento de flujo de datos:** módulo encargado de ejecutar tareas sobre los eventos una vez son persistidos en la base de datos, con el fin de *generar dos “vistas”* que contienen información elaborada, necesaria por el algoritmo de predicción: una vista contiene el registro actualizado de las calificaciones explícitas para cada canción; la segunda vista contiene las vecindades para cada usuario en el sistema, dependiendo del enfoque que sea seleccionado por el administrador de la aplicación. En la sección

## Capítulo 5. Descripción de la solución

---

4.1 se presentó el cálculo de la vecindad tradicional basada en la calificación explícita de los usuarios y tres alternativas que tienen en cuenta su respuesta emocional al escuchar música.

***Predicción:*** módulo encargado de implementar el mecanismo de predicción presentado en la sección 4.2, mediante un enfoque colaborativo basado en el uso de vecindades de usuarios similares. Utiliza como datos de entrada las vistas de información generadas por el módulo de procesamiento de flujo de datos, de esta forma las consultas a esas vistas se pueden resolver con tiempos bajos de respuesta. Como se mencionó anteriormente estas vistas corresponden a la calificación actual de los usuarios para las canciones escuchadas y su lista de usuarios vecinos (según el enfoque utilizado por BraiM: vecindad tradicional o emocional, sección 4.1).

***Evaluador de predicción:*** módulo encargado de realizar mediciones sobre la precisión del algoritmo de predicción utilizado por BraiM. Este componente se utiliza para la etapa de experimentación y evaluación expuesta en el capítulo 6.

### 5.2.1.2. Guía de Variabilidad

El módulo más susceptible a cambios bajo la arquitectura propuesta es el Adaptador de recursos Web. Esto se debe a que su funcionamiento se centra en APIs y recursos propietarios de empresas como Spotify y EchoNest. Es de gran utilidad manejar pruebas automáticas para este tipo de módulos claves en el sistema, puesto que permite detectar a tiempo cuando se produce un cambio importante en las APIs mencionadas o se hagan modificaciones críticas en sus protocolos de autenticación y comunicación. De esta forma se evita que se vea afectada la experiencia del usuario final.

### 5.2.1.3. Decisiones arquitecturales y de implementación

Los módulos y sub-módulos que componen el sistema fueron desarrollados aprovechando las ventajas que brindan los lenguajes de programación Ruby y Python. Ambos son lenguajes interpretados, de tipado dinámico, bastante poderosos y de código abierto. Ruby cuenta con una gran cantidad de herramientas que facilitan el desarrollo de aplicaciones Web. RubyOnRails por ejemplo, es un framework de código abierto que utiliza el paradigma de desarrollo MVC (Modelo Vista Controlador); cuenta con una comunidad activa de desarrolladores que publican librerías empaquetadas denominadas en ‘Gemas’ continuamente, que se pueden instalar de forma sencilla en cualquier aplicación. Este framework fue seleccionado para el desarrollo BraiM debido a que facilita generar servicios y funcionalidades de forma ágil y confiable.

Python por su parte se caracteriza por ser bastante popular en áreas de investigación asociadas con el análisis de datos, debido a que cuenta con una gran cantidad de librerías que facilitan la manipulación de datos a gran escala. Este lenguaje de programación fue utilizado para el desarrollo del módulo de evaluación, utilizado en

el capítulo 6 para comparar la precisión de la técnica de predicción propuesta con relación al filtrado colaborativo basado en vecindades tradicionales.

### 5.2.2. Estilo de Componentes y Conectores

Este estilo de arquitectura permite describir el comportamiento del sistema mediante un conjunto de elementos denominados componentes, los cuales interactúan unos entre otros en tiempo de ejecución, como por ejemplo servicios, procesos, hilos, filtros, clientes, servidores o repositorios. El mecanismo de interacción entre componentes se denomina conector; el cual puede ser un protocolo petición-respuesta, invocación directa de componentes o el uso canales de comunicación bidireccional. Entre los diferentes estilos de arquitectura de componentes y conectores, se destaca para este proyecto de investigación el estilo call-return. Este estilo de arquitectura especifica componentes que ofrecen una serie de servicios, los cuales a su vez son consumidos por otros componentes. En la figura 5.3 se presenta una vista de alto nivel del sistema bajo este estilo de arquitectura.

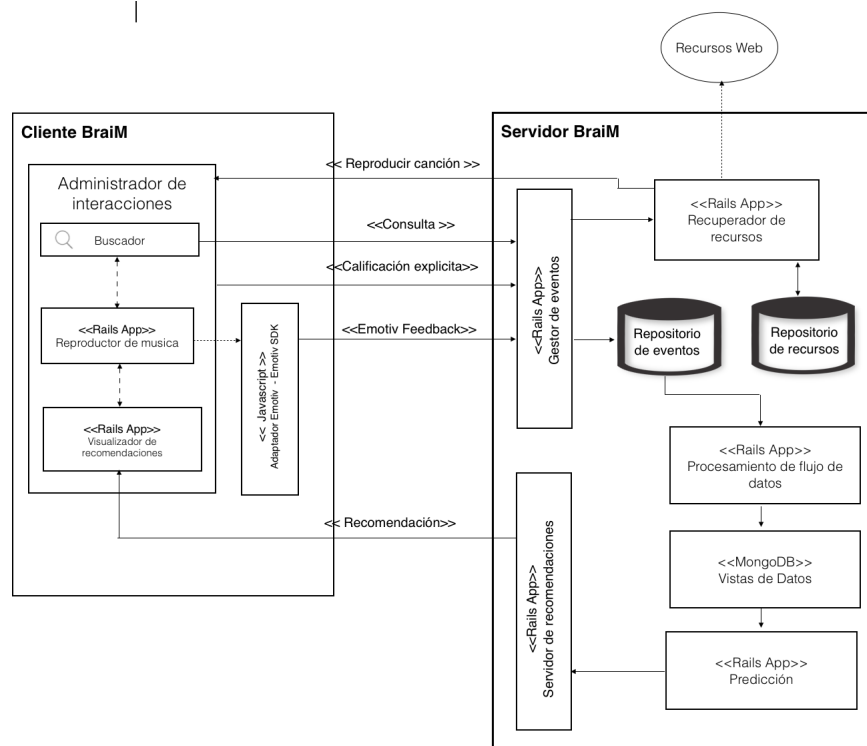


Figura 5.3: Vista Call-Return (Arquitectura general del sistema)

#### 5.2.2.1. Cliente - Servidor BraiM

La aplicación cuenta con un esquema cliente - servidor, implementado gracias al framework de desarrollo Web Ruby on Rails. Rails, permite la construcción de aplica-

## Capítulo 5. Descripción de la solución

---

ciones ‘fullstack’ que integran ambos componentes, siendo esta la opción seleccionada para la primera versión del prototipo. Gracias a la vista de componentes y conectores que se presenta en esta sección, es posible apreciar las interacciones más importantes que se dan entre cliente y servidor, facilitando en caso de ser necesario, el cambio por una tecnología distinta en el cliente para nuevas versiones de la aplicación. Del lado del servidor Rails permite construir aplicaciones ‘RestFull’, de forma sencilla y confiable, facilitando el acceso a la información procesada por el sistema y hacer recomendaciones de música mediante la técnica de predicción propuesta. De esta forma el cliente puede ser reemplazado por otro tipo de interfaz web o móvil.

### 5.2.2.2. Catálogo de componentes

Algunos de los elementos expuestos en la figura 5.3, ya fueron detallados en la sección anterior. Por este motivo a continuación se exponen solo los componentes faltantes, o aquellos que, gracias a este tipo de estilo de documentación arquitectural pueden ser explicados de una forma más detallada, especificando su comportamiento y la interacción con otros componentes durante la ejecución del sistema.

#### Cliente

**Buscador:** sencilla interfaz de búsqueda que permite realizar la petición al servidor sobre una canción o artista, proporcionando una lista ordenada con las coincidencias encontradas. Una vez el usuario selecciona una canción, el sistema se encarga de almacenar en la base de datos toda la información obtenida sobre la petición del usuario y los datos encontrados en los recursos web de Spotify y Echonest. De esta forma los datos recolectados quedan a disposición de BraiM, haciendo que el tiempo de respuesta de la plataforma sea más corto cuando se selecciona la misma canción por cualquier usuario en el sistema.

**Reproductor de música:** una vez se completa la petición del usuario al seleccionar una canción, se cuenta en la base de datos con información asociada que posteriormente puede ser utilizada por la aplicación para hacer streaming de música desde Spotify. Spotify cuenta con un modelo de negocio tipo freemium, que permite escuchar canciones a los usuarios de forma gratuita con anuncios publicitarios cada 5 o 6 canciones aproximadamente <sup>1</sup>.

**Visualizador de recomendaciones:** las recomendaciones obtenidas por el sistema se presentan en forma de lista ordenada, mostrando las N de mayor de preferencia encontrado por el algoritmo de predicción. El alcance del presente proyecto de investigación no considera una evaluación de la percepción del usuario para la recomendación entregada. Por esta razón se evalúa únicamente la precisión con que el sistema predice el gusto por una canción desconocida. Sin embargo, la plataforma

---

<sup>1</sup><https://developer.spotify.com/technologies/widgets/terms-of-use/>



permite adaptar formas de recomendación más complejas que pueden abordarse a medida que el número de usuarios en la aplicación crezca.

### Servidor

**Recuperador de recursos:** este módulo se encarga de recuperar los recursos con base en las intenciones de búsqueda de los usuarios.

**Repositorio de recursos:** repositorio donde se almacenan los datos sobre las canciones provenientes de los recursos en la Web, para que de esta forma el tiempo de respuesta disminuya cuando se selecciona una canción que ha sido previamente reproducida en la aplicación. Además, se almacena toda la información recolectada durante el registro de usuario en la plataforma.

**Gestor de recomendaciones:** se encarga de seleccionar las recomendaciones que serán visualizadas en la interfaz de usuario. Este componente se comunica directamente con el módulo de predicción, obteniendo una lista ordenada de predicciones sobre la calificación de canciones desconocidas por el usuario solicitante y filtrando el resultado obtenido de acuerdo con el número de recomendaciones solicitadas.

#### 5.2.2.3. Guía de variabilidad

Los puntos susceptibles a cambiar fueron descritos en la sección 5.2.1.2.

#### 5.2.2.4. Decisiones arquitecturales y de Implementación

Los elementos que componen el sistema fueron desarrollados en su mayoría usando Ruby on Rails, a excepción del módulo de evaluación, desarrollado en Python. A continuación se listan las librerías más importantes utilizadas para el desarrollo de la aplicación. En primer lugar para el cliente Web, se destacan:

**Emotiv Browser SDK:** gestiona los dispositivos Emotiv conectados en el cliente Web. Para su correcto funcionamiento el navegador elegido por el usuario debe contar con el plugin para exploradores proporcionado por Emotiv, que puede ser descargado una vez el usuario ingresa a la página de BraiM. Adicionalmente esta librería cuenta con los paquetes correspondientes al suite de medidas de rendimiento (Performance Metrics Suite) mencionado en la sección 3.2, que permite medir distintas respuestas emocionales del usuario.

**Highcharts**<sup>2</sup>: es una librería escrita en JavaScript que ofrece un mecanismo sencillo para añadir gráficos interactivos en cualquier aplicación web. Fue utilizada para visualizar la información obtenida mediante las librerías de Emotiv, permitiendo que el usuario pueda hacer seguimiento de sus respuestas al escuchar una canción. Además

---

<sup>2</sup><http://www.highcharts.com/>

## Capítulo 5. Descripción de la solución

---

brinda la posibilidad de graficar en tiempo de ejecución los cambios emocionales del usuario.

**Spotify Play button Widget:** permite reproducir una canción directamente desde Spotify utilizando un identificador único para cada pieza musical. Este identificador es obtenido previamente por el recuperador de recursos cuando el usuario hace la búsqueda de cualquier contenido musical o artista favorito.

De igual forma se listan a continuación las librerías más importantes que fueron utilizadas para el desarrollo de los distintos elementos en el servidor:

**Rspotify:** librería que proporciona un conjunto de herramientas para consultar de forma sencilla el API Web de Spotify desde cualquier aplicación escrita en Ruby. Permite consultar toda la información sobre canciones y artistas consultados por los usuarios para que sea almacenada en los repositorios de información.

**Pandas:** es una librería de código abierto para el lenguaje de programación Python y provee herramientas de alto rendimiento para análisis de datos.

### 5.2.3. Estilo de asignación

Este estilo de arquitectura busca describir las relaciones del sistema con estructuras externas a la aplicación. Es decir, permite la documentación de las relaciones entre el sistema software con su entorno de ejecución.

#### 5.2.3.1. Vista de despliegue

A continuación se describe el diagrama de despliegue de la plataforma, distribuyendo los elementos mencionados en la vista de Componentes y Conectores de la sección anterior:

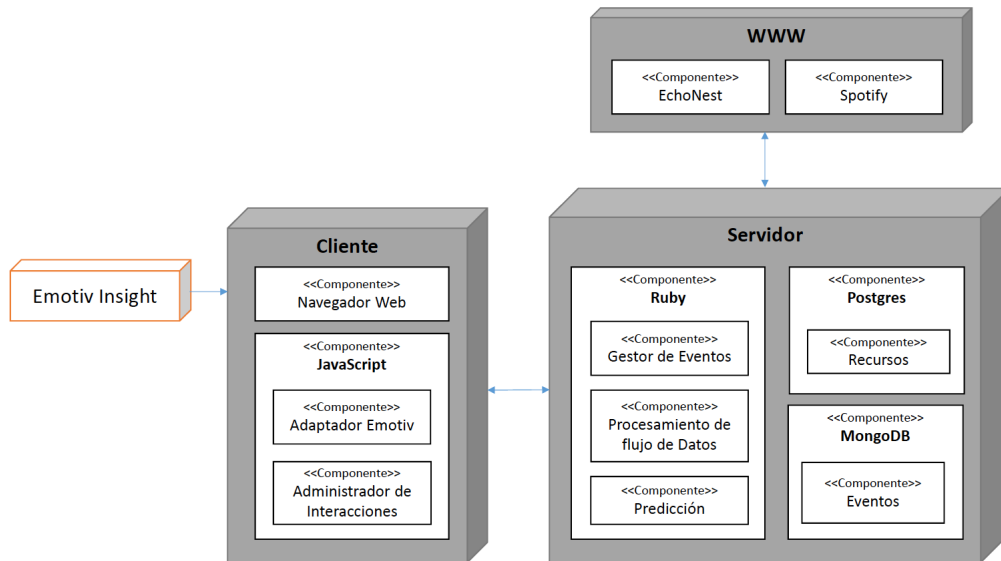


Figura 5.4: Vista de despliegue del sistema

### 5.2.3.2. Catálogo de elementos

En la vista de despliegue presentada en esta sección podemos apreciar cómo fueron distribuidos los elementos del sistema. A continuación se listan las características de los equipos utilizados para el presente proyecto de investigación.

**Cliente:** este elemento es utilizado para representar al usuario que accede al sistema gracias a su navegador web, de esta forma puede visualizar los recursos de la plataforma e interactuar con la aplicación.

**Servidor:** se encarga de llevar a cabo todos los procesos que fueron descritos en la vista de Componentes y Conectores. Para su despliegue se utilizó Microsoft Azure como plataforma de computación en la nube, puesto que ofrece una gran variedad de servicios para distintos tipos de aplicaciones. Una de sus vertientes más importantes es Infraestructura como servicio (IaaS), permitiendo instanciar máquinas virtuales que son desplegadas en la nube de Microsoft, sin la necesidad de un sistema operativo subyacente. Las características de la máquina virtual escogida para el presente proyecto de investigación se exponen a continuación:

- Sistema operativo: Ubuntu 14.04 LTS
- Núcleos Virtuales: 2
- Memoria Ram: 7GB
- Disco Duro: 100GB

## Capítulo 5. Descripción de la solución

---

**Emotiv insight:** las características hardware del dispositivo Emotiv insight se presentan en la sección 2.1.3.1. Esta herramienta se comunica con el navegador Web vía Bluetooth LE, y es utilizada para interactuar BraiM, proporcionando la información sobre los cambios en los estados afectivos del usuario.

### 5.2.3.3. Decisiones arquitecturales y de implementación

Las soluciones de Infraestructura como servicio ofrecen una alternativa bastante accesible para gestionar servidores en la nube de forma sencilla. En este proyecto de investigación Microsoft Azure fue seleccionado puesto que reduce costos asociados a la adquisición y mantenimiento hardware costoso. Además ofrece una sistema flexible que permite potenciar las características del servidor en caso de ser necesario.

### 5.2.3.4. Relación entre vistas

Módulos	C&C	Asignación
<b>Administrador de interacciones</b>	Buscador	Cliente
	Reproductor de música	Cliente
	Recuperador de recursos	Servidor
	Adaptador Emotiv	Cliente
	Visualizador de recomendaciones	Cliente
<b>Gestor de eventos</b>	Adaptador de información	Servidor
	Repositorio de eventos	Servidor
<b>Procesamiento de flujo de datos</b>	Procesamiento de flujo de datos	Servidor
<b>Vistas de datos</b>	Calificación de canciones	Servidor
	Vecindades de usuarios	Servidor
<b>Predicción</b>	Predicción	Servidor
	Servidor de recomendaciones	Servidor

Cuadro 5.3: Relación entre vistas de Descomposición, C&C y Asignación

En esta sección se describen las asociaciones existentes entre las vistas presentadas en la sección anterior con el fin de obtener una visión general del sistema. En el cuadro 5.3 se puede apreciar la asociación entre componentes de cada módulo principal y el equipo en el que se encuentran desplegados según la vista de asignación.

## 5.3. Resumen

Este capítulo contiene toda la documentación sobre arquitectura utilizada para detallar la aplicación BraiM, desarrollada para el presente proyecto de investigación como una herramienta que permite validar el algoritmo de predicción propuesto, y que hace recomendaciones con base en las predicciones realizadas sobre la preferencia de

un usuario por canciones desconocidas. Así, en este capítulo se describe la metodología utilizada para el desarrollo e implementación del mismo.

Los artefactos utilizados para describir el sistema fueron definidos mediante Views&Beyond (V&B), teniendo en cuenta esta metodología se crean una serie de vistas que surgen a partir de la aplicación de tres estilos de arquitectura distintos: de Módulos, que ofrece una vista coherente de alto nivel sobre el sistema; de Componentes y Conectores, contiene elementos del sistema con características de interacción y/o comunicación; y de Asignación, que sirve para describir cómo se relaciona cada uno de los componentes con el entorno software y hardware en el que se encuentran ejecutándose. Por último se expone una relación de las vistas para entender cómo se articulan todos los elementos del sistema.

# Capítulo 6

## Experimentación y evaluación

En este capítulo se evalúa la aproximación propuesta en el presente proyecto. A continuación se exponen dos secciones: la primera hace una descripción metodológica de la evaluación planteada y en la segunda se describen los experimentos realizados.

### 6.1. Metodología

Esta sección presenta una descripción detallada sobre la planeación del experimento realizado, para validar o refutar la hipótesis del proyecto. Además, se exponen las métricas de evaluación que fueron utilizadas.

#### 6.1.1. Planeación del experimento

##### 6.1.1.1. Definición del objetivo

El objetivo de evaluación es “medir la calidad” de la técnica de predicción propuesta, en línea con el tercer objetivo específico del presente proyecto. Para ello se comparan los resultados obtenidos con la precisión encontrada para el algoritmo tradicional de filtrado colaborativo. Ambas aproximaciones buscan calcular la calificación de una canción desconocida por el usuario solicitante

##### 6.1.1.2. Hipótesis

Este experimento busca comprobar o negar la hipótesis planteada en la sección 1.3.2, que se describe de forma más detallada a continuación:

- $H_0$  (Hipótesis Nula): Estimar la similitud de usuarios mediante un análisis de sus respuestas emocionales derivadas de señales EEG, no afecta la calidad de predicción de un SRM basado en filtrado colaborativo.
- $H_a$  (Hipótesis Alternativa): Estimar la similitud de usuarios mediante un análisis de sus respuestas emocionales derivadas de señales EEG, produce una mejora en la calidad de predicción de un SRM basado en filtrado colaborativo.

### 6.1.1.3. Selección de variables

Teniendo en cuenta el objetivo de evaluación y las métricas de calidad “offline” descritas en la sección 6.1.2, se tienen las siguientes variables a utilizar:

#### Variables independientes:

- Calificación explícita de los usuarios (En una escala de 5 estrellas).
- Descriptores  $a_i$  y  $P_i$  (Sección 3.3) para las canciones escuchadas.
- Canciones disponibles en el dataset “Million song dataset” [Bertin-Mahieux et al. \(2011\)](#).

#### Variables dependientes:

- Calificaciones determinadas por los algoritmos de predicción.

### 6.1.1.4. Selección de los sujetos

Dadas las características de la técnica propuesta, los sujetos de estudio deben interactuar con la aplicación para recolectar la información necesaria que permita realizar sugerencias personalizadas. Sin embargo, se requiere que los usuarios además, dispongan de un dispositivo Emotiv Insight; por esta razón se dificulta la captura de datos en un entorno real. Teniendo en cuenta estas limitaciones fue necesaria la configuración de un entorno de pruebas, que permitió crear el dataset con el que se realizó la evaluación de la técnica de predicción propuesta. Este dataset combina información sobre las canciones, características demográficas de los usuarios y sus respuestas emocionales al momento de reproducir contenido en la plataforma. Para especificaciones técnicas del dataset ver "**Repositorio de eventos**" en la descripción de la solución (sección 5.2.1).

Los sujetos de estudio seleccionados fueron estudiantes de Ingeniería Electrónica y Telecomunicaciones de la Universidad del Cauca entre los 19 y 33 años, en su mayoría pertenecientes a la electiva de Aplicaciones Móviles. Estas personas se encuentran radicadas principalmente en la ciudad de Popayán y no presentan ningún tipo de discapacidad física o mental. Todos fueron citados en sesiones de prueba, donde utilizaron la aplicación BraiM para escuchar clips musicales con una duración de 30 segundos, como se detalla en la sección 6.1.3.

### 6.1.1.5. Objetos Experimentales

La información utilizada para la evaluación del algoritmo de predicción propuesto, se logró recolectar gracias a la aplicación BraiM desarrollada para este proyecto de investigación. Las principales características de los datos recolectados son las siguientes:

## Capítulo 6. Experimentación y evaluación

---

- Periodo de observación: 1 semana
- Número de usuarios: 25
- Número total de canciones reproducidas: 454
- Lugar de muestra: Popayán - Cauca
- Emociones detectadas: 5

### 6.1.2. Métricas de evaluación

La técnica de evaluación seleccionada se basa en un análisis “off-line” de la técnica propuesta. Este tipo de análisis comúnmente se aplica en sistemas de aprendizaje automático, permitiendo usar datos reales previamente recolectados para medir el desempeño de la predicción realizada por el SR. Consiste en medir que tan precisa fue la predicción realizada para ítems cuya calificación ya se conoce previamente [Herlocker et al. \(2004\)](#); [Garlan et al. \(2010\)](#); de esta forma, al usar métricas offline como el MAE (mean absolute error ), se puede medir el desempeño de uno o varios algoritmos de predicción. Esta métrica se describe en detalle a continuación:

#### 6.1.2.1. MAE (Mean absolute Error)

El MAE (Mean Absolute Error) o también llamado desviación media absoluta, es el método más sencillo para medir la precisión de un algoritmo de predicción. Se obtiene calculando el promedio de la diferencia absoluta entre cada predicción realizada por el sistema para un grupo de calificaciones de prueba, como se muestra en la siguiente expresión:

$$MAE = \frac{1}{n} \sum_{u,j} ||c(u, j) - r(u, j)|| \quad (6.1)$$

En la ecuación anterior,  $r(u, j)$  hace referencia a la calificación explícita entregada por un usuario  $u$  para la canción  $j$ , y  $c(u, j)$  es el valor predicho por el algoritmo de filtrado colaborativo. Por su parte  $n$  es el número de ítems que fueron tenidos en cuenta para realizar el promedio. Los experimentos realizados en este proyecto de investigación se basan en la calificación ingresada por los usuarios en la aplicación BraiM, para un conjunto de canciones escuchadas durante las sesiones de prueba. Por su parte el cálculo del MAE se realizó gracias al módulo de evaluación de la plataforma, integrando librerías en Python para análisis de datos. De esta forma se busca determinar la calidad de la predicción realizada por la técnicas presentadas en la sección 4.2, cuando se tiene en cuenta una vecindad tradicional de usuarios (sección 4.1.1), y vecindades alternativas basadas en las respuestas emocionales de los usuarios al escuchar música ( 4.1.2).






Figura 6.1: Sesiones de prueba

### 6.1.3. Plan de ejecución de pruebas y resultados

Las pruebas que se presentan a continuación se realizaron usando al módulo de evaluación de BraiM. Dicho componente utiliza librerías para análisis y manipulación de datos, que facilitan el cálculo y la generación de reportes sobre las métricas offline presentadas en la sección anterior. Esta evaluación se centra en la comparación de los algoritmos de predicción planteados, mediante el uso de distintos tipos de vecindades de usuarios. En este orden de ideas fue necesaria la creación de un dataset de pruebas inicial reuniendo un grupo de usuarios en un entorno experimental. Esto se debe a que, aunque cualquier persona puede acceder a la plataforma y registrarse desde su ordenador, necesita un dispositivo Emotiv Insight para interactuar con la misma. Emotiv en su página oficial permite la publicación de aplicaciones desarrolladas por terceros, sin embargo el sitio aún no cuenta con una tracción de usuarios importante, y el proceso de validación que exige la compañía para permitir el uso público de sus sensores en este tipo de aplicaciones puede llevar un tiempo considerable.

#### 6.1.3.1. Captura de datos

Todos los sujetos de prueba fueron citados en las instalaciones del Instituto de Posgrado Electrónica y Telecomunicaciones (IPET), ubicación que permitió adecuar un espacio libre de interrupciones y con poco ruido externo. Como primer paso cada persona se registró en BraiM ingresando sus datos personales, posteriormente se procedió a adecuar el auricular Emotiv Insight. Este dispositivo cuenta con una serie de sensores que deben ser ubicados en sitios específicos sobre el cuero cabelludo y se sincroniza de forma automática con BraiM. De esta forma el usuario puede visualizar el estado de cada sensor, modificando su posición para mejorar la calidad en la señales detectadas. En la figura 6.1 se muestran algunas fotos realizadas durante la sesión de captura de datos.

Para propósitos de la prueba se realizó la programación de una funcionalidad adicional, encargada de reproducir clips musicales de 30 segundos aleatoriamente, con intervalos de 5 segundos entre cada canción, para agilizar las sesiones de captura de datos. El proceso se repite durante el transcurso de la sesión, aproximadamente de 30

## Capítulo 6. Experimentación y evaluación

---

a 40 minutos por usuario, tiempo en el cual cada participante alcanzó a escuchar un promedio de 45 clips musicales.

La selección de las canciones disponibles en la sesión de recolección de datos se hizo teniendo en cuenta el dataset denominado “Million Song Dataset” [Bertin-Mahieux et al. \(2011\)](#), que proporciona información detallada sobre una gran variedad de canciones y artistas, incluyendo su identificador en sitios Web como Spotify y Deezer. La razón por la cual se limitó el número de ítems disponibles fue para evitar la dispersión de los datos, siendo este uno de los problemas más importantes a tener en cuenta en sistemas de recomendación, y más aún en aquellos basados en filtrado colaborativo. En la sección 2.2.1.4 se mencionó cada uno de estos inconvenientes. Una vez se realizó la creación de este dataset, se procedió a ejecutar el plan de pruebas sobre la información recolectada.

### 6.1.3.2. Plan de pruebas - MAE

El plan de pruebas se basa en un enfoque denominado “conjunto de prueba y entrenamiento”, comúnmente utilizado en sistemas de aprendizaje automático.

**Objetivo de calidad:** evaluar y comparar la precisión de las técnicas de filtrado colaborativo implementadas por BraiM, utilizando como información de entrada el dataset creado durante las sesiones de recolección de datos (sección 6.1.3.1).

**Procedimiento:** consiste en dividir el dataset en dos grupos: grupo de entrenamiento y grupo de prueba, ejecutando técnica de predicción sobre el grupo de entrenamiento. A su vez, los registros pertenecientes al grupo de pruebas se dividen en dos: datos objetivo y datos de consulta. Posteriormente se predice la calificación de los datos objetivo teniendo como información de entrada los datos de consulta; de esta forma se puede evaluar cada algoritmo usando el MAE, indicando que tan acertada fue la predicción realizada. El proceso completo se repite mediante una técnica denominada Validación cruzada de k iteraciones (k-fold cross validation), dividiendo a los usuarios en k conjuntos iguales, usando cada grupo resultante como grupo de pruebas, y la información restante como grupo de entrenamiento.

### 6.1.4. Resultados

Después de dividir el dataset en 10 partes iguales, se determinó el MAE en cada sección del dataset, como indica el plan de pruebas. Así, en el cuadro 6.1 se presenta un análisis estadístico del MAE para el filtrado colaborativo tradicional (algoritmo 5), y para las técnicas de predicción propuestas: Predicción por correlación promedio de señales emocionales  $a_i$  (algoritmo 6), Predicción por correlación de señales emocionales  $a_i$  agregadas (algoritmo 7) y Predicción por puntaje emocional  $P_i$  (algoritmo 8). Cada vecindad se evaluó teniendo en cuenta las 5 emociones detectadas por Emotiv Insight:  $A = \{a_i\}$ ,  $1 < i < 5 = \{\text{interés, compromiso, concentración, relajación, excitación}\}$ . Sin embargo, el cálculo de  $P_i$  se realizó únicamente con la emoción excitación ( $i=5$ ),

## 6.1 Metodología

debido a que fue la única que presento variación suficiente como para generar calificaciones mayores a 0, según el procedimiento expuesto en la sección 3.3, para etiquetar de forma implícita clips musicales de 30 segundos.

	Algoritmo 5 (tradicional)	Algoritmo 6					Algoritmo 7					Algoritmo 8
	MAE	MAE- $a_1$	MAE- $a_2$	MAE- $a_3$	MAE- $a_4$	MAE- $a_5$	MAE- $a_1$	MAE- $a_2$	MAE- $a_3$	MAE- $a_4$	MAE- $a_5$	MAE- $P_5$
<b>Mean</b>	0.382830	0.6076	0.5798	0.3803	0.7244	0.5651	0.4712	0.4843	0.3192	0.6166	0.5282	0.635976
<b>Stf</b>	0.286446	0.4258	0.4362	0.3074	0.5316	0.5312	0.4255	0.2280	0.2586	0.4356	0.5479	0.629777
<b>Min</b>	0.058661	0.7839	0.0672	0.0416	0.0659	0.0452	0.0544	0.0863	0.0079	0.0890	0.0161	0.025583
<b>50%</b>	0.285274	0.5887	0.4511	0.3523	0.7299	0.4967	0.3428	0.4692	0.3184	0.6010	0.2985	0.265583
<b>Max</b>	0.888038	1.2858	1.4325	1.0795	1.9366	1.5862	1.3184	0.8649	0.7823	1.2749	1.5694	1.932345

Cuadro 6.1: Descripción estadística del MAE para cada vecindad

	Algoritmo 5 (tradicional)	Algoritmo 6	Algoritmo 7	Algoritmo 8
<b>MAE</b>	0.382830	0.5714796	0.4839644	0.635976

Cuadro 6.2: MAE promedio para cada vecindad




Figura 6.2: Resultados MAE

Esta prueba permitió identificar aquellas vecindades que tuvieron mejores resultados sobre la calidad de la predicción. Como se puede apreciar en la gráfica 6.2, el MAE es menor cuando se tiene en cuenta vecindades de usuarios a partir de las etiquetas  $a_i$  para la emoción concentración ( $i=3$ ). Sin embargo, una versión simplificada de los resultados se aprecia en el cuadro 6.2, donde se expone el valor promedio del MAE para cada vecindad; en este caso los resultados indican que las vecindades propuestas en este proyecto de investigación aumentaron el error en la predicción. Aunque mediante un análisis descriptivo se podría afirmar que no existe una diferencia importante con respecto a la técnica tradicional, es necesaria la realización de un estudio estadístico que permita determinar si la diferencia es significativa, y de esta forma aprobar o rechazar la hipótesis nula del presente experimento.

## Capítulo 6. Experimentación y evaluación

---

Teniendo en cuenta lo anterior, se plantea el uso de una *Prueba t pareada*, utilizada en estadística para realizar un análisis discriminante de los resultados obtenidos. En este caso la prueba consiste en calcular la diferencia entre cada par de mediciones del MAE para la técnica tradicional y la técnica propuesta; determinando si la media de las diferencias es estadísticamente significativa. Antes de continuar es necesario aclarar primero los conceptos de: alfa, valor-p y significancia estadística.

**Alfa:** el nivel de alfa o *nivel de significancia* es un valor entre  $[0,1]$  que indica la confianza en los resultados obtenidos. A continuación se se enumeran algunos valores de alfa y su correspondiente nivel de confianza asociado:

- Para obtener un resultado con un nivel de confianza del 90 %, el valor de alfa es de  $1 - 0,90 = 0,10$ .
- Para obtener un resultado con un nivel de confianza del 95 %, el valor de alfa es de  $1 - 0,95 = 0,05$ .
- Para obtener un resultado con un nivel de confianza del 99 %, el valor de alfa es de  $1 - 0,99 = 0,01$ .
- Para obtener un resultado con un nivel de confianza del  $n$  %, el valor de alfa es de  $1 - n/100$ .

**Valor-p:** el valor-p es la probabilidad de obtener un resultado estadístico lo más cercano al observado en la realidad, bajo el supuesto que la hipótesis nula es verdadera. Teniendo en cuenta un nivel de significancia del 10 % el valor de p puede interpretarse como se expone a continuación:

- $p \leq 0,01$ : presunción muy fuerte en contra de la hipótesis nula.
- $0,01 < p < 0,05$ : presunción fuerte en contra de la hipótesis nula.
- $0,05 < p < 0,1$ : baja presunción en contra de la hipótesis nula.
- $p > 0,1$ : no existe ninguna presunción en contra de la hipótesis nula.

**Significancia estadística:** se determina comparando los valores alfa y p de la siguiente forma:

- El valor-p es menor o igual a alfa: en este caso se considera que el resultado obtenido es estadísticamente significativo, así que la hipótesis nula es rechazada. Con esto se busca demostrar la existencia de evidencias suficientes para asegurar que existe diferencia alguna entre el MAE para el filtrado colaborativo mediante una vecindad tradicional y mediante el uso de las vecindades 'emocionales' propuestas.
- El valor-p es mayor que alfa: en este caso no se rechaza la hipótesis nula, es decir que la diferencia obtenida entre los resultados obtenidos no es estadísticamente significativo y pueden considerarse como producto del azar.

	Algoritmo 6 Vecindad $-a_i$ promedio	Algoritmo 7 Vecindad $-a_i$ agregación	Algoritmo 8 Vecindad $P_i$
Algoritmo 5 (tradicional)	Valor de t: 2.08263 Valor de p: 0.01864	Valor de t: 1.11649 Valor de p: 0.1321	Valor de t: 2.79466 Valor de p: 0.002598

Cuadro 6.3: Prueba t de Student

De acuerdo a los valores mostrados en el cuadro 6.3, y considerando un nivel de significancia estadística de 0,01, el MAE promedio para el filtrado colaborativo usando las vecindades mediante la comparación de etiquetas  $a_i$  (promedio y agregadas), no representa una diferencia estadísticamente significativa ( $p > 0,01$ ) respecto a la técnica tradicional. Sin embargo para el caso de la vecindad emocional mediante etiquetas  $P_i$  se encontró que  $p < 0,01$  y la diferencia entre esta técnica y la vecindad tradicional es significativa, razón por la cual se rechaza la hipótesis nula y se evidencia una disminución en la calidad de la predicción final, contrario a lo esperado.

### 6.1.5. Resumen

Este capítulo está enfocado en la experimentación y evaluación de los algoritmos para el cálculo de las vecindades de usuarios propuestas en la sección 4, mediante la comparación de las respuestas emocionales de los usuarios al escuchar música. Lo anterior con el fin de determinar la calidad de la predicción en un SRM basado en la métrica off-line del Error Medio Absoluto (MAE). Finalmente se discuten los resultados obtenidos y se determina la significancia estadística de la diferencia entre la calidad de la técnica propuesta y la técnica tradicional.

# Capítulo 7

## Conclusiones y trabajos futuros

Hoy en día los servicios de música digital en internet atraen a un número creciente de usuarios y creadores de contenido, en consecuencia existe una gran demanda por nuevos y mejores servicios de recomendación de música. Lo anterior sumado a la aparición en el mercado de dispositivos como Emotiv Insight, que permiten la captura de información sobre las emociones de los usuarios derivadas de señales EEG, permite a investigadores en este campo estudiar aproximaciones sobre cómo enriquecer la experiencia del usuario al interactuar con el contenido. Así pues, esta tesis de pregrado consta de un estudio sobre la utilización de esta herramienta para describir la respuesta emocional de los usuarios al escuchar una canción, y propone una técnica de predicción de calificación que tiene en cuenta vecindades de usuarios con respuestas emocionales similares.

Este capítulo describe inicialmente las principales conclusiones obtenidas, sus restricciones y posteriormente se listan los trabajos futuros.

### 7.1. Conclusiones

1. El uso de vecindades de usuarios mediante la comparación de las respuestas emocionales de los usuarios soporta la creación de algoritmos de predicción que pueden ser adaptados a un SRM. Este hecho está basado en la implementación descrita en el Capítulo 5, para la aplicación Web BraiM. Esta aplicación facilita la utilización de los algoritmos de predicción propuestos mediante la definición de un proceso de captura y pre-procesamiento de los datos recolectados.
2. Describir la respuesta emocional de los usuarios al escuchar una canción mediante las emociones detectadas por Emotiv Insight cobra sentido cuando se utiliza una representación de señales discretas. Sin embargo al reducir a un único valor las señales recolectadas se encontró que únicamente fue relevante la emoción excitación debido que fue la única que presentó una variación suficiente como para generar puntuaciones mayores a ceros en la mayoría de casos. Este hecho fue descrito mediante la exploración de los datos realizada en el capítulo 4 e implementación de la solución propuesta en el capítulo 5.

3. La calidad de la predicción mediante el uso de etiquetas para cada estado afectivo detectado durante el transcurso de la canción, no obtuvo una diferencia estadísticamente significativa respecto a la técnica tradicional, basada únicamente en la calificación explícita del usuario. Lo anterior permite afirmar que el método propuesto en los algoritmos 6 y 7 pueden reemplazar al método de f. c. tradicional con un grado de error aceptable; previendo que la similitud de usuarios basada en respuestas emocionales permitirá mejor desempeño al obtener más datos sin la acción explícita del usuario.
4. Esta monografía presenta un trabajo pionero en el área de utilización de descripción de la respuesta del usuario ante contenidos multimedia, utilizando señales discretizadas a partir de señales continuas, capturadas a partir las respuestas fisiológicas del usuario. Lo anterior permite tener en cuenta no solo características agregadas, sino un registro del comportamiento del usuario ante la influencia de contenido multimedia en un periodo limitado de tiempo. Este trabajo abre la posibilidad de utilizar este tipo de señales en sistemas de recomendación; permitiendo experimentar con nuevos tipos de respuestas a las sugerencias realizadas y explorando modelos de negocio alrededor de ellas.

## 7.2. Restricciones

1. La principal restricción al momento de evaluar la solución planteada en este proyecto se encuentra en la captura de información sobre las respuestas emocionales de los usuarios. Aunque la aplicación que se desarrolló permite que dispositivos EEG de bajo costo como Emotiv Insight puedan ser utilizados en entornos reales, no se cuenta con un número importante de usuarios en la actualidad que cuenten con esta clase de dispositivos. Por esta razón el dataset esta limitado a la información recolectada en su mayoría durante las sesiones de prueba. Es necesaria la obtención de un número mayor de participantes para lograr obtener muestras más representativas.
2. Los resultados obtenidos en el Capítulo 4, permitieron proyectar nuevas propuestas para brindar mejores recomendaciones de música, las cuales se pueden visualizar mediante la herramienta BraiM. Sin embargo, el alcance del presente proyecto sólo consideró la aplicación de una técnica basada en la predicción de la calificación de música, con el fin de probar su calidad frente a una técnica tradicional de filtrado colaborativo. La diferencia frente a dicha técnica radica en la utilización de la información emocional del usuario mediante el dispositivo Emotiv Insight, durante la etapa de similitud de usuarios.
3. Existen limitaciones a tener en cuenta al usar este tipo de tecnología en el campo de la recomendación de música. En el caso de Emotiv Insight en particular, la calidad de la señal obtenida por los sensores del dispositivo se ve afectada por distintos factores como el ruido ambiental y el ruido introducido por el

movimiento de la cabeza y de los músculos faciales. Aunque se le solicitó previamente a los participantes permanecer quietos durante las sesiones de prueba algunos modificaron su postura afectando la calidad de los datos recolectados. Además, por ser un dispositivo inalámbrico requiere ser recargado regularmente y su batería tiene una duración de entre 4 y 6 horas aproximadamente.

4. Aunque la mayoría de participantes mostraron interés por el uso de estos dispositivos, algunos expresaron sentirse incómodos con el Emotiv Insight después de media hora de uso continuo. Esto se debe a la presión que ejercen los sensores sobre el cuero cabelludo de la persona y a que el dispositivo no puede ajustarse a distintos tamaños de cabeza. Lo anterior produce que sea difícil para algunos usuarios usar el dispositivo y configurarlo para que funcione correctamente.

### 7.3. Trabajos futuros

- Extender el estudio sobre la implementación de la técnica de predicción propuesta por sistemas de recomendación de música en entornos reales. Aunque BraiM permite hacer una recomendación básica seleccionando las canciones desconocidas por el usuario solicitante con mejores calificaciones, para trabajos futuros se plantea la evaluación de nuevas aproximaciones que permitan recomendar canciones, artistas y otros usuarios con respuestas emocionales similares.
- Generar un dataset enriquecido con una cantidad mayor de usuarios registrados en la aplicación BraiM, para probar nuevas aproximaciones basadas en el análisis de las respuestas emocionales de los usuarios al escuchar música.
- Implementar una técnica de predicción basada en un Filtrado Colaborativo basado en ítems, como el presentado por Konstan [Konstas et al. \(2009\)](#).



# Bibliografía

- Adomavicius, G. and Tuzhilin, A. (2011). Context-aware recommender systems. In Ricci, F., Rokach, L., Shapira, B., and Kantor, P. B., editors, *Recommender Systems Handbook*, pages 217–253. Springer US.
- Anderson, M., Ball, M., Boley, H., Greene, S., Howse, N., McGrath, S., and Lemire, D. (2003). Racofi: A rule-applying collaborative filtering system.
- Baltrunas, L., Kaminskas, M., Ludwig, B., Moling, O., Ricci, F., Aydin, A., Lüke, K.-H., and Schwaiger, R. (2011). Incarmusic: Context-aware music recommendations in a car. In *EC-Web*, volume 11, pages 89–100. Springer.
- Bertin-Mahieux, T., Ellis, D. P., Whitman, B., and Lamere, P. (2011). The million song dataset. In *Proceedings of the 12th International Conference on Music Information Retrieval (ISMIR 2011)*.
- Blood, A. J. and Zatorre, R. J. (2001). Intensely pleasurable responses to music correlate with activity in brain regions implicated in reward and emotion. *Proceedings of the National Academy of Sciences*, 98(20):11818–11823.
- Bos, D. (2006). Eeg-based emotion recognition. *The Influence of Visual and Auditory Stimuli University*.
- Braunhofer, M., Kaminskas, M., and Ricci, F. (2013). Location-aware music recommendation. *International Journal of Multimedia Information Retrieval*, 2(1):31–44.
- Cao, C. and Li, M. (2009). Thinkit submissions for mirex2009 audio music classification and similarity tasks. *Music Information Retrieval Evaluation eXchange (MIREX)*.
- Celma (2009). Music recommendation and discovery in the long tail.
- Celma Herrada, Ò. (2009). Music recommendation and discovery in the long tail.
- Cernea, D., Kerren, A., and Ebert, A. (2011). Detecting insight and emotion in visualization applications with a commercial eeg headset. In *SIGRAD*, pages 53–60.
- Chang, H.-Y., Huang, S.-C., and Wu, J.-H. (2016). A personalized music recommendation system based on electroencephalography feedback. *Multimedia Tools and Applications*, pages 1–20.

## BIBLIOGRAFÍA

---

- Chapman, P., Clinton, J., Kerber, R., Khabaza, T., Reinhertz, T., Shearer, C., and Wirth, R. (2002). Cross industry standard process for data mining process (crisp), crisp 1.0 process and user guide. retrieved march 10, 2002.
- Deng, S., Wang, D., Li, X., and Xu, G. (2015). Exploring user emotion in microblogs for music recommendation. *Expert Systems with Applications*, 42(23):9284 – 9293.
- Dillman Carpentier, F. R. and Potter, R. F. (2007). Effects of music on physiological arousal: Explorations into tempo and genre. *Media Psychology*, 10(3):339–363.
- Duvinage, M., Castermans, T., Dutoit, T., Petieau, M., Hoellinger, T., Saedeleer, C. D., Seetharaman, K., and Cheron, G. (2012). A p300-based quantitative comparison between the emotiv epoc headset and a medical eeg device. *Biomedical Engineering*, 765:2012–764.
- Eerola, T., Lartillot, O., and Toiviainen, P. (2009). Prediction of multidimensional emotional ratings in music from audio using multivariate regression models. *Society for Music Information Conference*.
- Ekman, P. E. and Davidson, R. J. (1994). *The nature of emotion: Fundamental questions*. Oxford University Press.
- Ekstrand, M. D., Riedl, J. T., and Konstan, J. A. (2011). Collaborative filtering recommender systems. *Foundations and Trends in Human-Computer Interaction*, 4(2):81–173.
- Ferwerda, B. and Schedl, M. (2014). Enhancing music recommender systems with personality information and emotional states: A proposal. In *UMAP Workshops*.
- Garlan, D., Bachmann, F., Ivers, J., Stafford, J., Bass, L., Clements, P., and Merson, P. (2010). *Documenting Software Architectures Views and Beyond*. Addison Wesley Professional, 2nd edition.
- Guo, Y., Wu, C., and Peteiro-Barral, D. (2012a). An eeg-based brain informatics application for enhancing music experience. In Zanzotto, F., Tsumoto, S., Taatgen, N., and Yao, Y., editors, *Brain Informatics*, volume 7670 of *Lecture Notes in Computer Science*, pages 265–276. Springer Berlin Heidelberg.
- Guo, Y., Wu, C., and Peteiro-Barral, D. (2012b). An eeg-based brain informatics application for enhancing music experience. In Zanzotto, F., Tsumoto, S., Taatgen, N., and Yao, Y., editors, *Brain Informatics*, volume 7670 of *Lecture Notes in Computer Science*, pages 265–276. Springer Berlin Heidelberg.
- Haag, A., Goronzy, S., Schaich, P., and Williams, J. (2004). Emotion recognition using bio-sensors: First steps towards an automatic system. In *ADS*, pages 36–48. Springer.
- Harrison, T. (2013). The emotiv mind: Investigating the accuracy of the emotiv epoc in identifying emotions and its use in an intelligent tutoring system.

- Herlocker, J. L., Konstan, J. A., and Riedl, J. (2000). Explaining collaborative filtering recommendations. In *Proceedings of the 2000 ACM Conference on Computer Supported Cooperative Work, CSCW '00*, pages 241–250, New York, NY, USA. ACM.
- Herlocker, J. L., Konstan, J. A., Terveen, L. G., and Riedl, J. T. (2004). Evaluating collaborative filtering recommender systems. *ACM Trans. Inf. Syst.*, 22(1):5–53.
- Hevner, K. (1935). Expression in music - a discussion of experimental studies and theories. *Psychological Review*, 42:186–204.
- Inventado, P. S., Legaspi, R., Bui, T., and Suarez, M. (2010). Predicting students appraisal of feedback in an its using previous affective states and continuous affect labels from eeg data. In *Proceedings of the 18th International Conference on Computers in Education, Putrajaya, Malaysia*.
- Jennings, D. (2007). *Net, blogs and rock'n'roll: how digital discovery works and what it means for consumers, creators and culture*. Nicholas Brealey Publishing.
- Kaminskas, M. and Ricci, F. (2012a). Contextual music information retrieval and recommendation: State of the art and challenges. *Computer Science Review*, 6(2-3):89 – 119.
- Kaminskas, M. and Ricci, F. (2012b). Contextual music information retrieval and recommendation: State of the art and challenges. *Computer Science Review*, 6(2-3):89 – 119.
- Kim, Y. E., Schmidt, E. M., Migneco, R., Richardson, B. G. M. P., Scott, J., Speck, J. A., and Turnbull, D. (2010). Music emotion recognition: A state of the art review.
- Koelstra, S., MuAahl, C., Soleymani, M., Lee, J.-S., Yazdani, A., Ebrahimi, T., Pun, T., Nijholt, A., and Patras, I. Y. (2012). Deap: A database for emotion analysis using physiological signals. *IEEE TRANSACTIONS ON AFFECTIVE COMPUTING*, 3.
- Konstas, I., Stathopoulos, V., and Jose, J. M. (2009). On social networks and collaborative recommendation. In *Proceedings of the 32nd international ACM SIGIR conference on Research and development in information retrieval*, pages 195–202. ACM.
- Koutepova, T., Liu, Y., Lan, X., and Jeong, J. (2010). Enhancing video games in real time with biofeedback data. In *ACM SIGGRAPH ASIA 2010 Posters*, page 56. ACM.
- Krepki, R., Blankertz, B., Curio, G., and MÅÆller, K.-R. (2007). The berlin brain-computer interface (bbci) .towards a new communication channel for online control in gaming applications. *Multimedia Tools and Applications*, 33(1):73–90.

## BIBLIOGRAFÍA

---

- Lang, M. (2012). Investigating the emotiv epoc for cognitive control in limited training time. *Honours report, University of Canterbury*, page 8.
- Le, N. T. (2010a). *EmuPlayer: Music Recommendation System Based on User Emotion Using Vital-sensor*. PhD thesis, Keio University.
- Le, N. T. (2010b). *EmuPlayer: Music Recommendation System Based on User Emotion Using Vital-sensor*. PhD thesis, Keio University.
- Li, Q., Kim, B. M., Guan, D. H., et al. (2004). A music recommender based on audio features. In *Proceedings of the 27th annual international ACM SIGIR conference on Research and development in information retrieval*, pages 532–533. ACM.
- Li, T. and Ogihara, M. (2003). Detecting Emotion in Music.
- Liu, Y., Sourina, O., and Nguyen, M. K. (2010). Real-time eeg-based human emotion recognition and visualization. In *Proceedings of the 2010 International Conference on Cyberworlds, CW '10*, pages 262–269, Washington, DC, USA. IEEE Computer Society.
- Maes, P. (1994). Agents that reduce work and information overload. *Commun. ACM*, 37(7):30–40.
- Marz, N. and Warren, J. (2015). *Big Data: Principles and best practices of scalable realtime data systems*. Manning Publications Co.
- Millán, J. d. R., Rupp, R., Müller-Putz, G. R., Murray-Smith, R., Giugliemma, C., Tangermann, M., Vidaurre, C., Cincotti, F., Kübler, A., Leeb, R., et al. (2010). Combining brain–computer interfaces and assistive technologies: state-of-the-art and challenges. *Frontiers in neuroscience*, 4.
- Miller, F., Stiksel, M., and Jones, R. (2008). Last. fm in numbers. *Last. fm press material*.
- Mion, L. and Poli, G. D. (2008). Score-independent audio features for description of music expression. *IEEE Transactions on Audio, Speech and Language Processing*, 16:458–466.
- Mühl, C., Gürkök, H., Plass-Oude Bos, D., Thurlings, M. E., Scherffig, L., Duvinage, M., Elbakyan, A. A., Kang, S., Poel, M., and Heylen, D. (2010). Bacteria hunt: A multimodal, multiparadigm bci game.
- Myers, D. G. (2004). Theories of emotion. *Psychology: Seventh Edition, New York, NY: Worth Publishers*, 500.
- Neumayer, R. and Rauber, A. (2008). Multimodal analysis of text and audio features for music information retrieval. In *Multimodal Processing and Interaction*, pages 1–17. Springer.

- Niedermeyer, E. and da Silva, F. L. (2005). *Electroencephalography: basic principles, clinical applications, and related fields*. Lippincott Williams & Wilkins.
- Nijholt, A., Bos, D. P.-O., and Reuderink, B. (2009). Turning shortcomings into challenges: Brain-computer interfaces for games. *Entertainment Computing*, 1(2):85–94.
- Panda, R., Rocha, B., and Paiva, R. P. (2015). Music emotion recognition with standard and melodic audio features. *Applied Artificial Intelligence*, 29(4):313–334.
- Peeters, G. (2008). A generic training and classification system for mirex08 classification tasks: Audio music mood, audio genre, audio artist and audio tag. In *Proc. of the 9th International Conference on Music Information Retrieval (ISMIR)*, Philadelphia.
- Plutchik, R. and Kellerman, H. (2013). *Theories of emotion*, volume 1. Academic Press.
- Pohle, T., Pampalk, E., and Widmer, G. (2005). Evaluation of frequently used audio features for classification of music into perceptual categories. In *Proceedings of the Fourth International Workshop on Content-Based Multimedia Indexing*, volume 162. Citeseer.
- Radinsky, K., Kapoor, A., Oron, A., and Master, K. (2011a). Brain-computer interfaces for music recommendation.
- Radinsky, K., Kapoor, A., Oron, A., and Master, K. (2011b). Brain-computer interfaces for music recommendation. *Neural Information Processing Systems Foundations Workshop 2011*.
- Ricci, F., Rokach, L., Shapira, B., and Kantor, P. B. (2011). Introduction to recommender systems handbook. In Ricci, F., Rokach, L., Shapira, B., and Kantor, P. B., editors, *Recommender Systems Handbook*, pages 1–35. Springer US.
- Rojas-Potosi, L., Suarez-Meza, L., Ordóñez-Ante, L., and Corrales, J. (2012). Web resources recommendation based on dynamic prediction of user consumption on the social web. *AAAI Spring Symposium Series*.
- Rubin, K. S. (2012). *Essential Scrum: A practical guide to the most popular Agile process*. Addison-Wesley.
- Russell, J. A. (2003). Core affect and the psychological construction of emotion. *Psychological review*, 110(1):145.
- Sadie, S. (2001). The new grove. dictionary of music and musicians. volume 18.
- Sami, R. and Harmala, M. (2009). Si 583 - recommender systems course.

- Sawata, R., Ogawa, T., and Haseyama, M. (2015). Human-centered favorite music estimation: Eeg-based extraction of audio features reflecting individual preference. In *Digital Signal Processing (DSP), 2015 IEEE International Conference on*, pages 818–822. IEEE.
- Shin, S., Jang, D., Lee, J., jin Jang, S., and Kim, J.-H. (2014). Mymusicshuffler: Mood-based music recommendation with the practical usage of brainwave signals. In *Consumer Electronics (ICCE), 2014 IEEE International Conference on*, pages 355–356.
- Song, Y., Dixon, S., and Pearce, M. (2012a). A survey of music recommendation systems and future perspectives. In *9th international symposium on computer music modelling and retrieval (CMMR 2012)*, pages 19–22.
- Song, Y., Dixon, S., and Pearce, M. (2012b). A survey of music recommendation systems and future perspectives. In *9th international symposium on computer music modelling and retrieval (CMMR 2012)*, pages 19–22.
- Su, J.-H., Yeh, H.-H., Yu, P. S., and Tseng, V. S. (2010). Music recommendation using content and context information mining. *Intelligent Systems, IEEE*, 25(1):16–26.
- Thompson, T., Steffert, T., Ros, T., Leach, J., and Gruzelier, J. (2008). {EEG} applications for sport and performance. *Methods*, 45(4):279 – 288. Neuroimaging in the sports sciences.
- Turnbull, D., Barrington, L., Torres, D., and Lanckriet, G. (2008). Semantic annotation and retrieval of music and sound effects.
- Typke, R., Wiering, F., and Veltkamp, R. C. (2005). A survey of music information retrieval systems. In *The annual Conference of the International Society for Music Information Retrieval (ISMIR) 2005*, pages 153–160.
- Von Ahn, L. (2006). Games with a purpose. *Computer*, 39(6):92–94.
- Zentner, M., Grandjean, D., and Scherer, K. R. (2008). Emotions evoked by the sound of music: characterization, classification, and measurement. *Emotion*, 8(4):494.

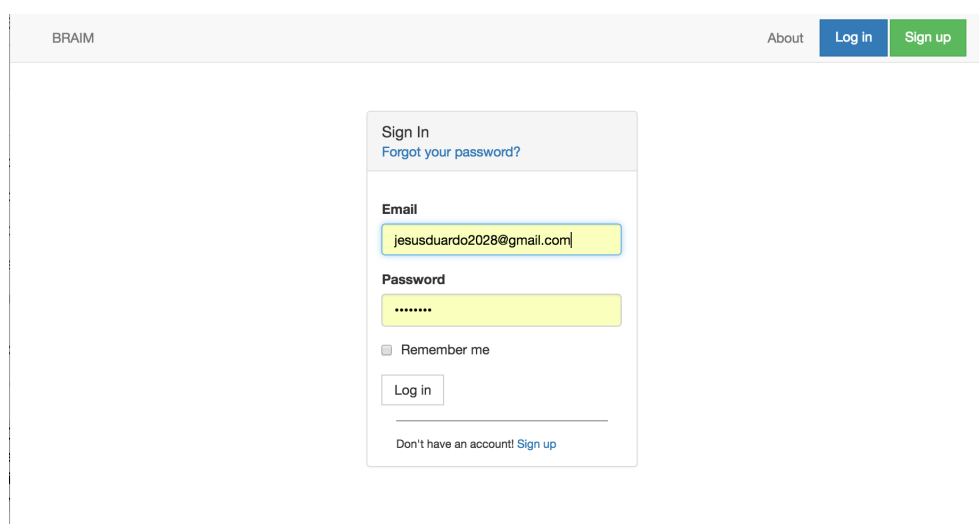
# Apéndice A

## Modelo de diseño de BraiM - Interfaz de usuario

A continuación se describe el diagrama de navegabilidad para la implementación de la interfaz gráfica de la herramienta BraiM, que fue desarrollada utilizando el framework Ruby on Rails.

### A.1. Registro y sesión de usuarios

Interfaz gráfica que permite a los usuarios el registro básico en la plataforma (Figura A.2), e inicio de sesión (Figura A.1). Además, permite al usuario recobrar su contraseña si lo desea, mediante su correo electrónico (Figura A.3).



The image shows a web browser window displaying the BraiM login page. The browser's address bar shows 'BRAIM'. The page header includes 'About', 'Log in', and 'Sign up' buttons. The main content area features a 'Sign In' form with the following elements: a 'Forgot your password?' link, an 'Email' input field containing 'jesusduardo2028@gmail.com', a 'Password' input field with masked characters, a 'Remember me' checkbox, a 'Log in' button, and a 'Don't have an account! Sign up' link.

Figura A.1: Interfaz gráfica - Inicio de sesión

## Capítulo A. Modelo de diseño de BraiM - Interfaz de usuario

---

The image shows a web interface for the BraiM application. At the top, there is a navigation bar with the text "BRAIM" on the left, "About" in the center, and two buttons: "Log in" (blue) and "Sign up" (green). Below the navigation bar is a "Sign Up" form. The form has a title "Sign Up" and a "Log in" link. It contains several input fields: "Email", "Name", "Last name", "Country" (a dropdown menu), "Password", and "Password confirmation". The "Password" field has a note "8 characters minimum". A "Sign up" button is located at the bottom right of the form.

Figura A.2: Interfaz gráfica - Registro Básico

The image shows a web interface for the BraiM application. At the top, there is a navigation bar with the text "BRAIM" on the left, "About" in the center, and two buttons: "Log in" (blue) and "Sign up" (green). Below the navigation bar is a "Forgot your password?" form. The form has a title "Forgot your password?". It contains an "Email" input field and a "Send me reset password instructions" button. At the bottom of the form, there are two links: "Log in" and "Sign up".

Figura A.3: Interfaz gráfica - Recuperar contraseña



## A.2. Configuración Emotiv Insight

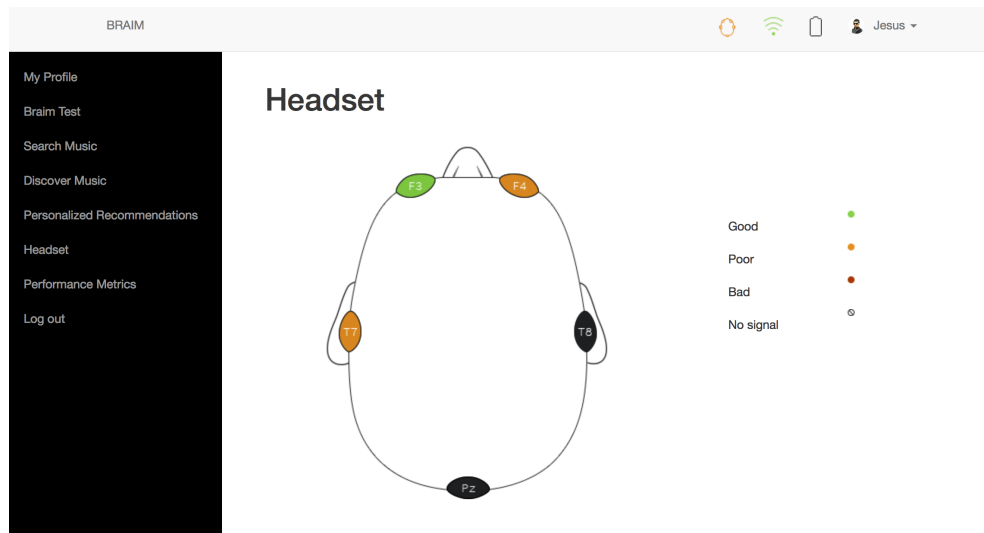


Figura A.4: Configuración Emotiv Insight

Una vez los usuarios ingresan en la plataforma deben descargar el plugin para navegadores Web de Emotiv Insight. Para ello BraiM presenta un mensaje con el link de descarga en caso de no contar la herramienta instalada. Una vez el usuario instala el plugin y reinicia su navegador, puede acceder a la interfaz de configuración (Figura A.4), donde se visualiza el estado actual de cada sensor. Los colores verde, amarillo, rojo y indican la calidad de la señal obtenida. Adicionalmente, en la barra superior de la interfaz se puede apreciar en todo momento una versión en miniatura sobre estos indicadores, junto con la carga batería del dispositivo y la calidad en la señal Bluetooth.

## A.3. Búsqueda de canciones

Interfaz que permite hacer una búsqueda en la Web de cualquier canción o artista. Los resultados se listan como muestra la gráfica A.5.

## Capítulo A. Modelo de diseño de BraiM - Interfaz de usuario

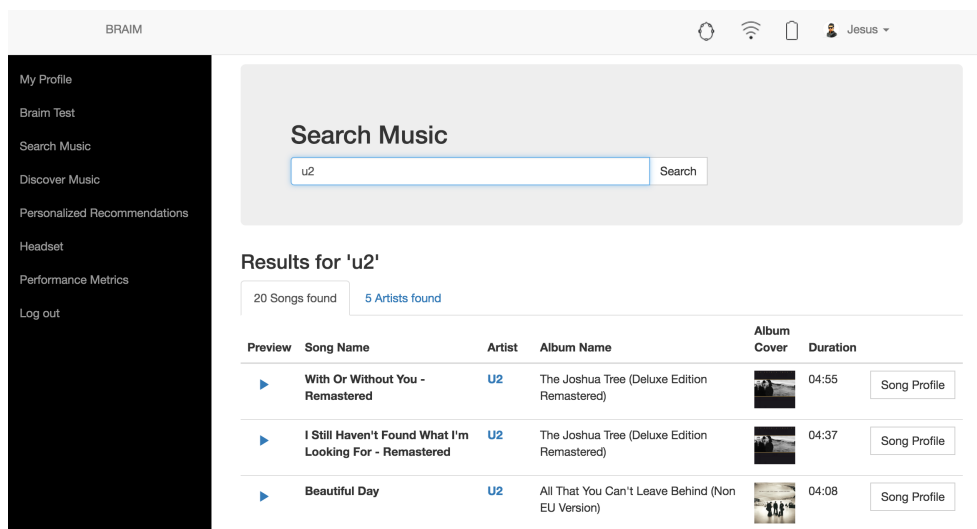


Figura A.5: Interfaz gráfica - Consulta de canciones y artistas

Además, los usuarios pueden acceder a su historial de reproducción (Figura A.6), y conocer lo que otros usuarios de la plataforma han escuchado en el pasado para comparar sus respuestas (Figura A.7).

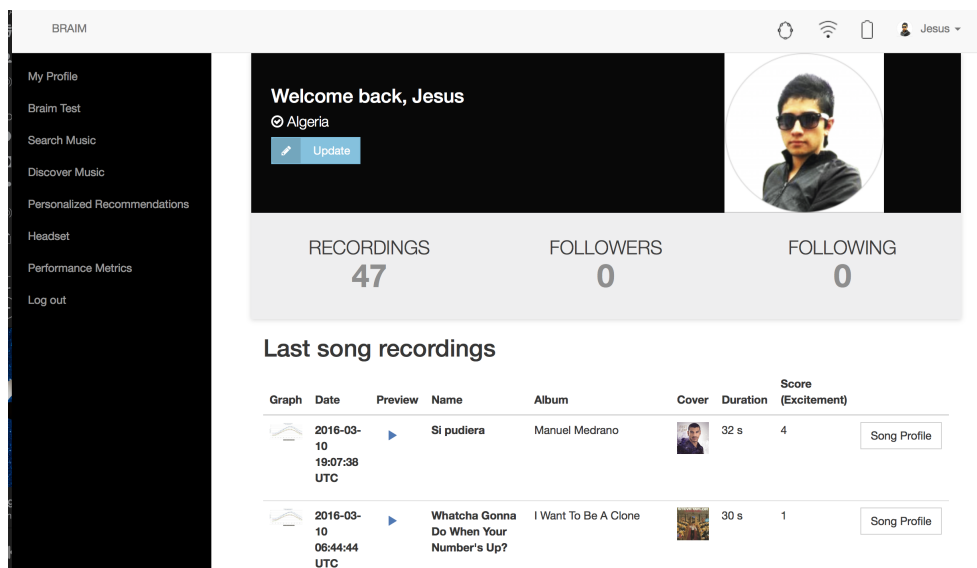


Figura A.6: Interfaz gráfica - Historial de usuario

## A.4 Reproducción y captura de emociones

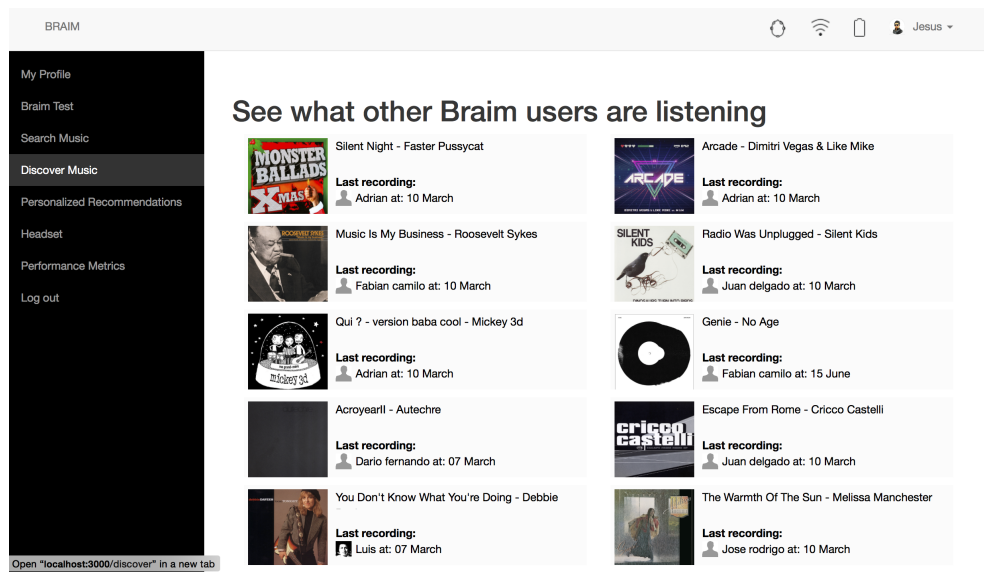


Figura A.7: Interfaz gráfica - Reproducciones de otros usuarios

## A.4. Reproducción y captura de emociones

Una vez el usuario selecciona una canción, se presenta al usuario una interfaz con información relacionada y la opción para escucharla mediante el api Web de Spotify. Además puede asignar una calificación explícita en una escala de 5 estrellas (Figura A.8). Posteriormente el usuario puede conocer el registros emocionales capturados por Emotiv insight para cada canción presente en su historial como muestra la Figura A.9.




Figura A.8: Interfaz gráfica - Reproducción y calificación de música

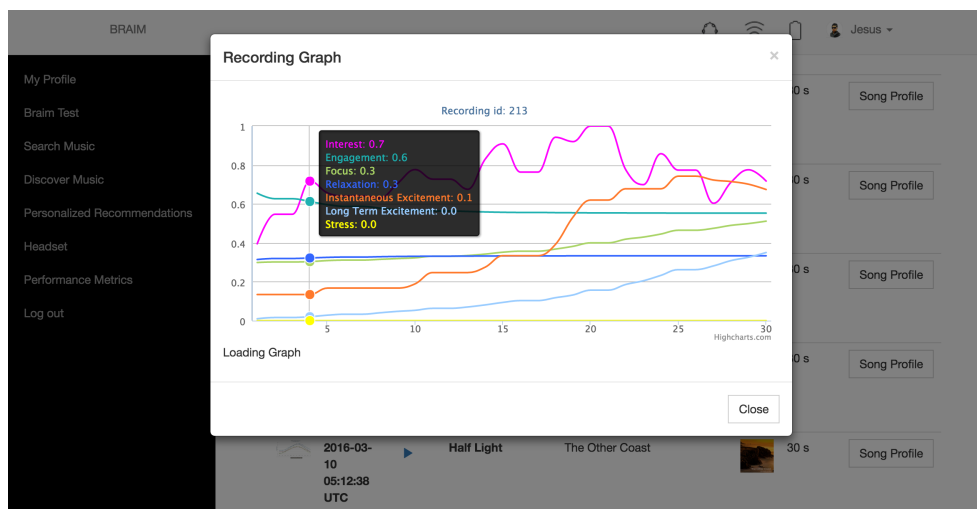


Figura A.9: Interfaz gráfica - Registros detectados por Emotiv Insight para una canción

### A.5. Sesión de pruebas y recolección de datos

Como se presentó en el capítulo 6, se realizó la implementación de una interfaz para la sesión de pruebas, con el fin de agilizar el proceso de captura de datos. En la figura A.10 se muestra la canción reproducida de forma aleatoria y como al finalizar automáticamente el usuario selecciona la puntuación para dicha canción en la figura A.11.

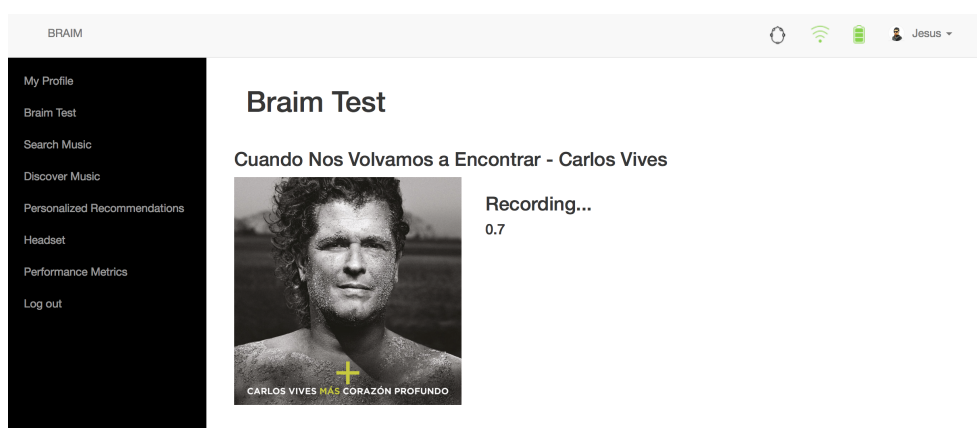


Figura A.10: Interfaz gráfica - Sesión de pruebas

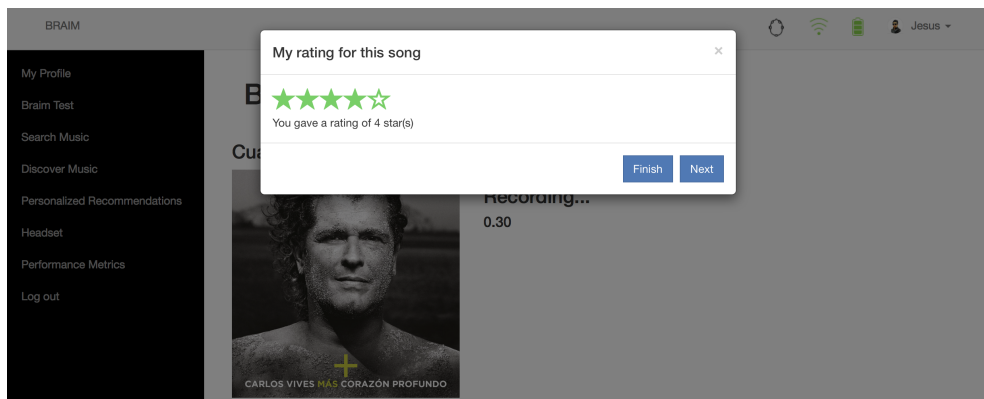


Figura A.11: Interfaz gráfica - Sesión de pruebas - calificación

## A.6. Recomendación de música

Interfaz básica de recomendación para mostrar las canciones que obtuvieron una calificación más alta, utilizando la técnica de predicción propuesta en este proyecto (Figura A.12).

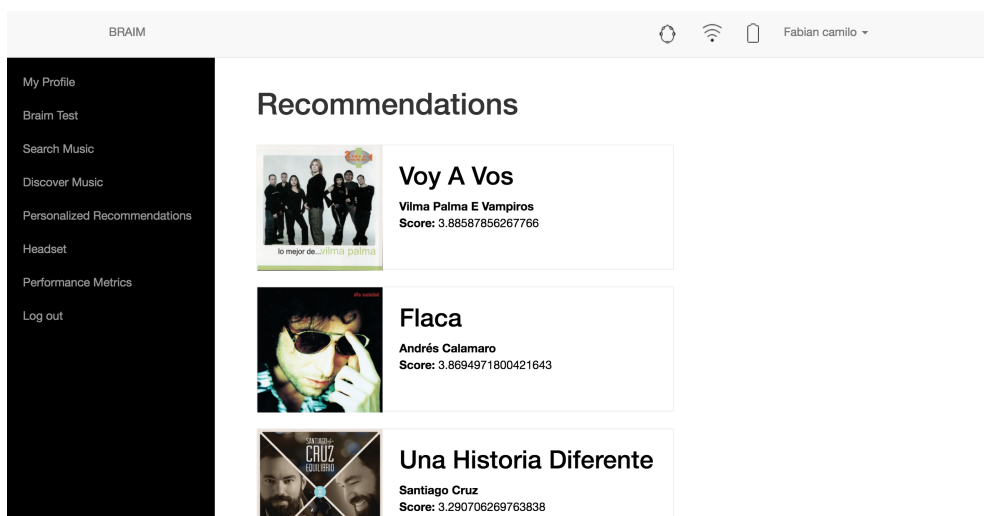


Figura A.12: Interfaz gráfica - Recomendación básica de canciones