

**SISTEMA DE RECOMENDACIONES PARA EL SERVICIO DE VOD,  
BASADO EN LA INFERENCIA DE EMOCIONES A PARTIR DE  
VARIABLES DEL CONTEXTO DE USUARIO**



Mauricio Sánchez Barragán  
Luis Alejandro Solarte Moncayo

**Director:** Mag. Gabriel Elías Chanchí Golondrino  
**Co-Director:** PhD. José Luis Arciniegas Herrera

*Universidad del Cauca*

**Facultad de Ingeniería Electrónica y Telecomunicaciones  
Departamento de Telemática  
Línea de investigación en servicios avanzados de telecomunicaciones  
Popayán, Agosto de 2016**



**SISTEMA DE RECOMENDACIONES PARA EL SERVICIO DE VOD,  
BASADO EN LA INFERENCIA DE EMOCIONES A PARTIR DE  
VARIABLES DEL CONTEXTO DE USUARIO**

**Trabajo de grado presentado como requisito para obtener el título de  
Ingeniero en Electrónica y Telecomunicaciones**

Mauricio Sánchez Barragán  
Luis Alejandro Solarte Moncayo

**Director:** Mag. Gabriel Elías Chanchí Golondrino  
**Co-Director:** PhD. José Luis Arciniegas Herrera

*Universidad del Cauca*

**Facultad de Ingeniería Electrónica y Telecomunicaciones  
Departamento de Telemática  
Línea de investigación en servicios avanzados de telecomunicaciones  
Popayán, Agosto de 2016**



# Contenido

<b>CAPÍTULO 1</b> .....	<b>1</b>
<b>INTRODUCCIÓN</b> .....	<b>1</b>
1.1 INTRODUCCIÓN.....	1
1.2 CONTEXTO GENERAL.....	1
1.2.1 <i>Video bajo demanda</i> .....	1
1.2.2 <i>Streaming</i> .....	2
1.2.3 <i>IPTV</i> .....	3
1.3 PLANTEAMIENTO DEL PROBLEMA.....	4
1.4 ESCENARIO DE MOTIVACIÓN.....	6
1.5 ESTADO ACTUAL DEL CONOCIMIENTO.....	7
1.5.1 <i>Sistemas de recomendaciones basados en contexto para contenidos multimedia</i> .....	7
1.5.2 <i>Sistemas de análisis de medidas fisiológicas</i> .....	10
1.6 APORTES DEL PROYECTO.....	12
1.6.1 <i>Brechas Existentes</i> .....	12
1.6.2 <i>Aportes Académicos</i> .....	13
1.7 OBJETIVOS.....	14
1.7.1 <i>Objetivo General</i> .....	14
1.7.2 <i>Objetivos Específicos</i> .....	14
1.8 ENFOQUE.....	14
1.9 ACTIVIDADES.....	15
1.10 ESTRUCTURA DEL TRABAJO DE GRADO.....	16
<b>CAPÍTULO 2</b> .....	<b>19</b>
<b>DATASET DE CONTENIDOS MUSICALES DE VIDEO</b> .....	<b>19</b>
2.1 INTRODUCCIÓN.....	19
2.2 METODOLOGÍA PARA LA GENERACIÓN DEL <i>DATASET</i> .....	19
2.3 CARACTERÍSTICAS MUSICALES.....	20
2.4 EMOCIÓN.....	21
2.4.1 <i>Estructura de las emociones</i> .....	22
2.4.2 <i>Modelo circunflejo</i> .....	22
2.4.3 <i>Modelo de Hevner</i> .....	23
2.4.4 <i>Modelo tridimensional</i> .....	24
2.4.5 <i>Modelo de plutchick</i> .....	24
2.5 SOLUCIONES COMERCIALES.....	25
2.5.1 <i>Musicoverly</i> .....	25
2.5.2 <i>EchoNest</i> .....	26
2.5.3 <i>Gracenote</i> .....	27
2.6 CONFORMACIÓN DEL <i>DATASET</i> MUSICAL DE VIDEO.....	28
2.6.1 <i>Modelo de emociones</i> .....	28
2.6.2 <i>Reconocimiento de emociones del contenido</i> .....	29
2.6.3 <i>Diagrama de flujo del dataset de contenidos</i> .....	31
2.7 EVALUACIÓN DEL <i>DATASET</i> DE CONTENIDOS.....	33
<b>CAPÍTULO 3</b> .....	<b>37</b>
<b>MÉTODO COMPUTACIONAL PARA LA INFERENCIA</b> .....	<b>37</b>

3.1 INTRODUCCIÓN.....	37
3.2 SISTEMA DE MEDIDAS FISIOLÓGICAS .....	37
3.3 VARIABLES DEL CONTEXTO DE USUARIO.....	38
3.3.1 Variabilidad de la frecuencia cardíaca .....	39
3.3.2 Parámetros de medición de la VFC .....	39
3.3.2.1 Métodos en el dominio del tiempo.....	40
3.3.2.1.1 RMSSD.....	40
3.3.2.1.2 pNN50.....	40
3.3.2.1.3 mRR.....	40
3.3.2.1.4 SDNN.....	41
3.3.2.2 Medida del nivel de estrés mental .....	41
3.3.2.2.1 RMSSD y pNN50 .....	41
3.3.2.2.2 Índice de estrés.....	42
3.4 MEDIDA DE RESPUESTA GALVÁNICA DE LA PIEL (RGP O GSR) .....	43
3.4.1 Regresión Lineal y pendiente.....	44
3.5 MEDIDA ELECTROMIOGRÁFICA DE SUPERFICIE .....	45
3.5.1 Cálculo de la valence.....	46
3.6 EQUIPOS PARA MEDIDAS FISIOLÓGICAS .....	47
3.6.1 Sensor de pulso cardíaco para arduino .....	47
3.6.2 Cinturon Zephyr HxM BT.....	48
3.6.3 Cinturón Polar .....	49
3.6.4 Sensor Grove .....	49
3.6.5 Sensor EMG.....	50
3.6.6 Arduino Yún .....	51
3.7 DISEÑO SISTEMA HARDWARE-SOFTWARE.....	51
3.8 MÉTODO COMPUTACIONAL DE INFERENCIA.....	54
<b>CAPÍTULO 4.....</b>	<b>57</b>
<b>SISTEMA DE RECOMENDACIONES.....</b>	<b>57</b>
4.1 INTRODUCCIÓN.....	57
4.2 CONCEPTO DE S.R. ....	57
4.3 ENFOQUE CLÁSICO DE LOS S.R. ....	58
4.3.1 Enfoque basado en contenido.....	58
4.3.1.1 Clasificador Bayesiano.....	60
4.3.2 S.R. colaborativos.....	62
4.4 S.R. BASADOS EN CONTEXTO.....	63
4.5 DISEÑO DEL S.R. BASADO EN CONTEXTO .....	64
4.5.1 Diseño del clasificador bayesiano .....	66
4.5.2 Servicio de VoD .....	69
<b>CAPÍTULO 5.....</b>	<b>73</b>
<b>EVALUACIÓN Y PRUEBAS .....</b>	<b>73</b>
5.1 INTRODUCCIÓN.....	73
5.2 PRUEBAS S.R. CLÁSICO .....	73
5.2.1 Resumen de predicciones .....	73
5.2.2 Matriz de confusión .....	75
5.3 PRUEBAS S.R. CONTEXTO.....	76
5.3.1 Métodos de comparación lineal .....	76
5.3.1.1 Distancia Euclidiana .....	76
5.3.1.2 Distancia Manhattan.....	77

5.3.1.3 Similitud del Coseno .....	77
5.3.1.4 Coeficiente de correlación de Pearson .....	78
5.3.1.5 Coeficiente mínimos cuadrados ordinarios (Ordinary Least Squares, OLS) .....	78
<b>5.3.2 Evaluación del S.R. basado en contexto .....</b>	<b>79</b>
5.3.2.1 Resultados de media aritmética.....	79
5.3.2.2 Resultados de desviación estándar .....	84
5.3.2.3 Análisis métricas de comparación .....	87
<b>5.4 PRUEBAS DE CARGA Y ESTRÉS .....</b>	<b>90</b>
5.4.1 Servidor de Procesamiento .....	90
5.4.2 Servidor de contexto .....	92
5.4.3 Sistema hardware-software (Arduino Yún).....	94
<b>CAPÍTULO 6 .....</b>	<b>97</b>
<b>CONCLUSIONES, TRABAJOS FUTUROS Y OTROS.....</b>	<b>97</b>
6.1 CONCLUSIONES .....	97
6.2 TRABAJOS FUTUROS .....	101
6.3 PUBLICACIONES .....	102
6.3.1 Publicaciones en Congresos .....	102
6.3.2 Publicaciones en Revistas .....	102
6.4 REGISTROS SOFTWARE .....	102
<b>BIBLIOGRAFÍA.....</b>	<b>103</b>



# Lista de Figuras

Figura 1.1 Ejemplo de video bajo demanda de vimeo, adaptado de [3].....	2
Figura 1.2 Arquitectura de streaming, tomado de [4].....	3
Figura 1.3 Arquitectura de IPTV, tomado de [5].....	3
Figura 1.4 Diagrama de temáticas consideradas en el trabajo de grado, fuente: propia.....	7
Figura 2.1 Metodología para la generación del dataset, fuente: propia.....	19
Figura 2.2 Modelos de emociones, tomado de [37].....	22
Figura 2.3 Modelo circunflejo de las emociones adaptado por Russell, tomado de [41].....	23
Figura 2.4 Modelo de las emociones de Hevner, tomado de [42].....	24
Figura 2.5 Modelo tridimensional de plutchick, tomado de [43].....	25
Figura 2.6 Interfaz de usuario Musicoverly, tomado de [44].....	26
Figura 2.7 Página web oficial de EchoNest, tomado de [45].....	27
Figura 2.8 Página web oficial de gracernote, tomado de [46].....	28
Figura 2.9 Modelo de arousal-valence adaptado a 5 emociones, fuente: propia.....	29
Figura 2.10 Reconocimiento de emociones musicales, fuente: propia.....	30
Figura 2.11 Bloques funcionales herramienta java, fuente: propia.....	30
Figura 2.12 Diagrama de flujo del dataset de contenidos multimedia, fuente: propia.....	31
Figura 2.13 Muestra del archivo JSON generado, fuente: propia.....	33
Figura 2.14 Arquitectura para el despliegue del servicio de VoD, fuente: propia.....	34
Figura 2.15 Interfaz de usuario del servicio de VoD, fuente: propia.....	35
Figura 3.1 Sistema de medidas fisiológicas, fuente: propia.....	38
Figura 3.2 Variables del contexto, fuente: propia.....	38
Figura 3.3 Variabilidad de la frecuencia cardíaca, tomado de [51].....	39
Figura 3.4 Glándula sudorípara, tomado de [51].....	43
Figura 3.5 Gráfico señal RGP, tomado de [57].....	43
Figura 3.6 Gráfico regresión lineal a conjunto de datos, fuente: propia.....	44
Figura 3.7 Método para cálculo de regresión lineal, fuente: propia.....	45
Figura 3.8 Músculos faciales, tomado de [59].....	45
Figura 3.9 Dispositivo sensor de pulso cardíaco-arduino, fuente: propia.....	48
Figura 3.10 Dispositivo sensor zephyr, fuente: propia.....	48
Figura 3.11 Dispositivo sensor polar, fuente: propia.....	49
Figura 3.12 Dispositivo sensor Grove para la RGP, fuente: propia.....	50
Figura 3.13 Dispositivo sensor MyoWare para la EMG, fuente: propia.....	50
Figura 3.14 Tarjeta hardware Arduino Yún, fuente: propia.....	51
Figura 3.15 Módulos funcionales para las variables fisiológicas, fuente: propia.....	52
Figura 3.16 Medidas de análisis para la VFC, fuente: propia.....	53
Figura 3.17 Gráfico estados de ánimo asociados a un índice de estrés (SI), fuente: propia.....	53
Figura 3.18 Medidas capturadas del dispositivo sensor RGP, fuente: propia.....	54
Figura 3.19 Medidas capturadas del dispositivo sensor EMG, fuente: propia.....	54
Figura 3.20 Diagrama de flujo del método de inferencia de emociones, fuente:propia.....	55
Figura 3. 21 Método computacional de inferencia, fuente: propia.....	56
Figura 4.1 Arquitectura básica del S.R., fuente: propia.....	58
Figura 4.2 Arquitectura de los S.R. basados en contenido, tomado de [13].....	59
Figura 4.3 Diagrama de secuencia de un S.R. basado en contenido, fuente: propia.....	60
Figura 4.4 Diagrama de secuencia de un S.R. basado en filtros colaborativos, fuente: propia.....	63
Figura 4.5 Diagrama de secuencia de un S.R. basado en contexto, fuente: propia.....	64
Figura 4.6 Arquitectura del S.R. basado en contexto, fuente: propia.....	65
Figura 4.7 Diseño del S.R. basado en contexto, fuente: propia.....	66

---

Figura 4.8 Diagrama final del clasificador bayesiano, fuente: propia.....	69
Figura 4.9 Arquitectura del servicio de VoD, fuente: propia.....	69
Figura 4.10 Interfaz validación de usuario del servicio de VoD, fuente: propia.....	70
Figura 4.11 Sistema de captura de datos, fuente: propia.....	71
Figura 4.12 Interfaz principal de usuario del servicio de VoD, fuente: propia.....	71
Figura 4.13 Arquitectura del servicio de VoD, fuente: propia.....	72
Figura 5.1 Resumen de predicciones del clasificador bayesiano, fuente: propia.....	74
Figura 5.2 Matriz de confusión del clasificador bayesiano, fuente: propia.....	75
Figura 5.3 Diagrama de evaluación S.R., fuente: propia.....	79
Figura 5.4 Métricas de comparación vs medidas (media aritmética), fuente: propia.....	82
Figura 5.5 Desviación estándar vs medidas, fuente: propia.....	86
Figura 5.6 Análisis métricas de comparación, fuente: propia.....	89
Figura 5.7 Pruebas de carga, servidor de procesamiento, fuente: propia.....	91
Figura 5.8 Pruebas de estrés, servidor de procesamiento, fuente: propia.....	92
Figura 5.9 Pruebas de carga, servidor de contexto, fuente: propia.....	92
Figura 5.10 Pruebas de estrés, servidor de contexto, fuente: propia.....	93
Figura 5.11 Pruebas de carga, sistema hardware-software, fuente: propia.....	94
Figura 5.12 Pruebas de estrés, sistema hardware-software, fuente: propia.....	95

## Lista de Tablas

Tabla 1.1 Cronograma de actividades, fuente: propia.....	15
Tabla 2.1 Características musicales del contenido, fuente: propia.....	20
Tabla 2.2 Estados de emoción según el rango de ángulos, fuente: propia.....	29
Tabla 2.3 Características musicales para cada video, archivo JSON, fuente: propia.....	33
Tabla 3.1 Medidas estadísticas y nivel de estrés, fuente: propia.....	41
Tabla 3.2 Rangos SI asociados a cada estado, fuente: propia.....	42
Tabla 4.1 Ejemplo del teorema de Naive Bayes, fuente: propia.....	61
Tabla 4.2 Ejemplo de clasificador bayesiano con valores booleanos, fuente: propia.....	66
Tabla 4.3 Ejemplo de discretización con un contenido original (sin discretizar), fuente: propia.....	68
Tabla 4.4 Ejemplo de discretización con un contenido original (discretizados), fuente: propia.....	68
Tabla 5.1 Ejemplo matriz de confusión, fuente: propia.....	75
Tabla 5.2 Abreviaturas de media aritmética para métricas de comparación, fuente: propia.....	80
Tabla 5.3 Abreviaturas de desviación estándar para métricas de comparación, fuente: propia.....	84



## Lista de Ecuaciones

Ecuación 2.1 Formulas de normalización: arousal y valence .....	32
Ecuación 3.1 Formula para calcular RMSSD.....	40
Ecuación 3.2 Formula para calcular pNN50.....	40
Ecuación 3.3 Formula para calcular mRR.....	40
Ecuación 3.4 Formula para calcular SDNN.....	41
Ecuación 3.5 Formula Índice de estrés .....	42
Ecuación 3.6 Formulas cálculo de valence .....	47
Ecuación 4.1 Formula de probabilidad condicionada de A dado B.....	60
Ecuación 4.2 Formula de Naive Bayes.....	61
Ecuación 4.3 Probabilidad condicionada, Naive Bayes.....	61
Ecuación 4.4 Formula para la estimación de Laplace.....	61
Ecuación 4.5 Formulas para discretizar arousal y valence.....	67
Ecuación 4.6 Formulas para normalizar y discretizar el tempo.....	67
Ecuación 4.7 Formula para discretizar calificación del contenido.....	67
Ecuación 5.1 Distancia Euclidiana .....	77
Ecuación 5.2 Distancia Manhattan .....	77
Ecuación 5.3 Similitud del Coseno .....	77
Ecuación 5.4 Formula parametrización, similitud del coseno.....	78
Ecuación 5.5 Coeficiente de Correlación de Pearson.....	78
Ecuación 5.6 Coeficiente OLS .....	78



# Capítulo 1

## Introducción

### 1.1 Introducción

En este capítulo se introduce al lector en el trabajo de grado desarrollado, comenzando con los conceptos más relevantes tales como: video bajo demanda, streaming, IPTV; además de plantear la descripción del problema y la motivación del mismo. El lector podrá observar los trabajos relacionados para las dos temáticas tratadas: Los sistemas de recomendaciones y medidas fisiológicas. También son planteados una serie de objetivos a cumplir durante el desarrollo, los aportes a realizar y una serie de actividades para llevarlo a cabo, siendo el enfoque del presente trabajo brindar una solución al problema de arranque en frío presente en los sistemas de recomendaciones y los limitados métodos de entrada con que estos cuentan para realizar la sugerencia de contenidos.

### 1.2 Contexto General

#### 1.2.1 Video bajo demanda

VoD (*Video on Demand*), son sistemas basados en una arquitectura cliente-servidor y los cuales permiten a los usuarios seleccionar el contenido que deseen, estos realizan la entrega de contenido de vídeo a través del protocolo de internet (IP, *Internet Protocol*) de banda ancha al espectador [1]. Para su implementación, es necesario contar con las siguientes características: buena capacidad de almacenamiento, gran ancho de banda, servicio en tiempo real (reproducir, detener, avanzar) y buena calidad, por lo cual la técnica de streaming es apropiada por su sencillez y flexibilidad [2]. En la figura 1.1, es posible apreciar un ejemplo de servicio de VoD conocido como vimeo, el cual funciona también como red social. Además, existen otros proveedores del servicio de VoD como youtube, dailymotion, Netflix, entre otros.

The image shows a screenshot of a Vimeo video player. The video is titled "Multiple Choice" by Michael Goode. The video content shows three young men standing in front of a blue van. The van has a multiple-choice question on its side: "A) Multi", "B) ple", "C) Choi", "D) ce". The video player interface includes a search bar at the top right with a magnifying glass icon and the text "7 Buscar videos, personas y más". The video player itself has a play button, a progress bar, and a "HD" indicator. Below the video player, the video title "Multiple Choice" is displayed, along with the creator's name "de Michael Goode" and a "Seguir" button. The video has 41.3K views, 209 likes, 12 comments, and 9 shares. The description includes the text: "Ever tell a lie to get out of taking a test? Here's your cautionary tale. Created in collaboration with The Feds, Hallway Sydney, and John Jameson Productions. Starring Daniel Lissing, Nathaniel Buzolic, and Daniel Webber. Directed by Mike Goode." Below the description, there are four categories: "Narrativa", "Comedia", and "Comedia". To the right of the video player, there is a section titled "Más de Comedia" with a "6" next to it, indicating the number of recommendations. This section includes a "Reproducción automática activada" toggle and several video thumbnails with titles like "Multiple Choice", "I DON'T LIKE ANYTHING I DO", "Teams vs. Star Slinger - Close To Me", and "The Joy of Matte Painting".

Figura 1.1 Ejemplo de video bajo demanda de vimeo, adaptado de [3]

En este servicio de video es común encontrar elementos tales como, componentes de reproducción en “1”, numero de vistas o reproducciones “2”, valoración del contenido “3”, descripción del mismo “4”, categorías o características del contenido “5”, recomendación y/o relacionados “6” y el buscador de contenidos “7”. Siendo los elementos más representativos para efectuar las recomendaciones de contenido, el número de reproducciones, valoración del contenido y categorías.

### 1.2.2 Streaming

Es la distribución de contenido multimedia, recibido de forma continua y presentado al usuario final, mientras es entregado por el proveedor de contenidos [4]. En la figura 1.2, es posible apreciar la arquitectura típica de un sistema de streaming.

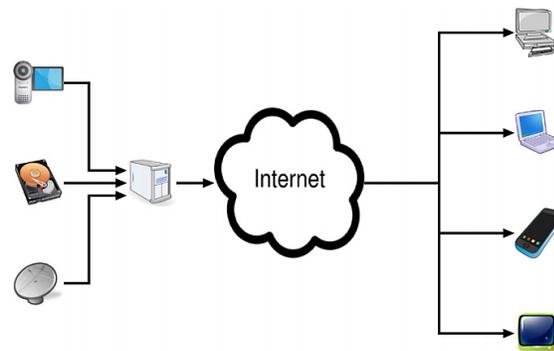


Figura 1.2 Arquitectura de streaming, tomado de [4]

Como es apreciado en la figura 1.2, el contenido de video puede estar disponible como una transmisión en vivo, un archivo guardado o una comunicación por satélite, esta es almacenada en un servidor que la transmite a través de internet a una multitud de clientes heterogéneos.

### 1.2.3 IPTV

IPTV (*Internet Protocol Television*) es definido como el envío de servicios multimedia (televisión, video, audio, texto, gráficos y datos) de alta calidad a través de redes IP de banda ancha. Además del uso de protocolos y tecnologías de streaming en la transmisión, en [5]. En la figura 1.3, es mostrada la arquitectura típica de un sistema IPTV.

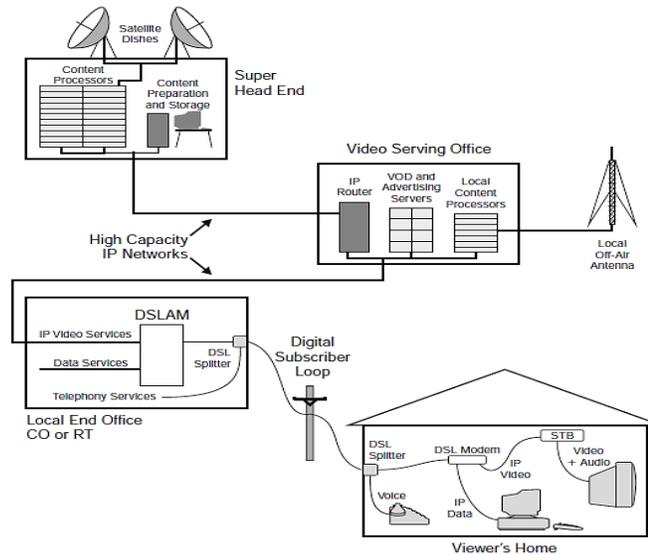


Figura 1.3 Arquitectura de IPTV, tomado de [5]

Para sistemas de entrega de IPTV muy grandes, es muy común encontrar una jerarquía de instalaciones construidas para entregar señales de video a través de una gran extensión del

territorio. Una o dos instalaciones para la recuperación por desastres conocidos como súper cabecera (SHE), puede servir a millones de clientes mediante el procesamiento de los canales de video que son comunes a todos los abonados a través de la zona de servicio, una oficina de servicio de video (VSO) necesaria para manejar la programación local y canales específicos de una sola ciudad o área geográfica. Oficina central (CO) o terminal remoto (TR) pueden servir como una oficina de extremo local (LEO, *Local Environmental Observer*), la cual contiene lo necesario para entregar programación a los clientes en un área local, esto es propiedad de una compañía la cual lo opera.

### 1.3 Planteamiento del Problema

Cada mes el tráfico en las redes aumenta exponencialmente, según [6] una persona necesitará por encima de cinco millones de años para observar la cantidad de vídeo que circulará por la red en el año 2019. Además, a nivel mundial, el tráfico de vídeo por Internet será el 80% de su tráfico global. De igual manera, comparado al de televisión será el 17% en 2019, superior al 16% existente en 2014. Según [6] y [7], el servicio de vídeo bajo demanda (VoD) en alta definición (HD) llegará a ser el 70% del tráfico de VoD proyectado a 2019, superior al 59% existente en 2014; ello implica que deben ser desarrollados sistemas los cuales permitan agilizar el acceso a los contenidos y su búsqueda eficiente [8] [9].

En cuanto al servicio de VoD, hoy en día está ampliamente difundido en internet [10], lo cual posibilita al usuario el pedido de videos a la carta, acceder a contenidos multimedia de alta calidad además de permitirle controlar el modo de reproducción, siendo los proveedores más representativos del servicio: Netflix, YouTube y Vimeo. A pesar de los beneficios del servicio de VoD, existen un conjunto de problemas que dificultan la experiencia e interacción del usuario en el entorno de televisión, dentro de estos están: el crecimiento de los catálogos de contenidos multimedia, el tiempo empleado por un usuario navegando por estos, los limitados métodos de entrada para navegar a través de ellos, entre otros. De acuerdo a lo anterior, los dos principales retos del servicio de VoD son: **agilizar el acceso y permitir el consumo adecuado** del contenido multimedia en entornos televisivos.

Con respecto al reto del problema de arranque en frío, una de las opciones utilizadas para hacerle frente son los sistemas de recomendaciones [11], encargados de identificar las preferencias del usuario y realizar sugerencias personalizadas en la selección a partir de diversas opciones [12]. De acuerdo a [8] y [13], los sistemas de recomendaciones son clasificados, principalmente, en colaborativos y basados en contenido. Los primeros toman en cuenta las preferencias de otros usuarios para la sugerencia de contenido, estos grupos son denominados comúnmente vecindades. Los últimos, realizan las sugerencias de

acuerdo al análisis del comportamiento del usuario, entre ellos los historiales de navegación y valoraciones existentes, además de tener en cuenta las características del contenido [13].

Según [14] y [15] existen problemáticas presentes en los sistemas de recomendaciones tales como: escasez de datos y el problema de arranque en frío [16] [17]. El primero afecta a los sistemas de recomendaciones colaborativos debido a la falta de información suficiente de las vecindades, para realizar la predicción y clasificación del contenido al usuario [18]. El segundo hace referencia al problema de recomendar cuando el sistema está en estados preliminares, es decir, cuando el usuario no ha interactuado con el sistema, por lo cual no hay contenido relevante para ser recomendado al usuario. Para estos problemas suelen utilizarse estrategias híbridas que integran sistemas de dominio de conocimiento [8] [19].

Los sistemas de recomendaciones basados en contexto, los cuales son una subdivisión de los basados en conocimiento, tienen la función de inferir las preferencias del usuario, cuando el sistema está en estados preliminares. Una de las formas de realizar esta inferencia es por medio de variables del contexto de usuario [19] [20], las cuales son definidas como información que puede ser utilizada para caracterizar el estado de una entidad, siendo la entidad, una persona, lugar u objeto relevante para las interacciones entre el usuario y la aplicación [21] [22] [23], las cuales proveen de información al sistema con datos que hacen posible la recomendación de contenido en estados preliminares.

El contexto de usuario es amplio y cuenta con diversas variables las cuales pueden ser analizadas, por ello es necesario establecer aquellas que permitan enfrentar el problema del arranque en frío, para de esta manera poder recomendar contenidos multimedia relevantes o interesantes a los usuarios. Las variables fisiológicas pueden aportar a la solución del problema mencionado, estas permiten evaluar el comportamiento de un individuo a partir del funcionamiento de su organismo teniendo en cuenta la tasa de respiración, la circulación sanguínea, la respuesta galvánica de la piel, entre otros. Estas variables son importantes al problema mencionado, pues permiten realizar la inferencia de emociones [24] [25] [26].

La inferencia de emociones a partir de contenido multimedia está siendo tenida en cuenta para su utilización en los sistemas de recomendaciones. Esta permite analizar, de manera inteligente, el estado de un usuario y con base en él, recomendar el contenido según sus necesidades emocionales. Las propiedades afectivas del contenido tales como: la *valence*, *tempo* y *arousal*, entre otras, son tomadas en cuenta [24] [25] [26] [27] [28]. Una aproximación a los gustos de los usuarios puede ser obtenida por medio de métodos probabilísticos y de clasificación. Con base en lo expuesto, la siguiente pregunta de investigación es planteada: **¿Cómo mejorar el acceso a contenidos multimedia del servicio de video bajo demanda, teniendo en cuenta información del contexto de usuario?**

El presente proyecto pretende aportar a la solución de la anterior pregunta de investigación por medio de un sistema de recomendaciones basado en contexto, el cual tome en cuenta parámetros del usuario [24] [25] [26] [27], como son las medidas fisiológicas para la inferencia de emociones; entre estas medidas están: la variación de la frecuencia cardíaca (VFC), la respuesta galvánica de la piel (RGP) y la medida electromiográfica (EMG). Estas variables logran dotar al sistema de datos que permitan realizar la recomendación de contenido en estados preliminares [28] [29] [30] [31]. Así la hipótesis del presente trabajo es: **“Un sistema de recomendaciones basado en contexto para el servicio de video bajo demanda permitirá agilizar el acceso al contenido multimedia”**.

## 1.4 Escenario de Motivación

Los contenidos multimedia son de principal agrado a la hora de navegar por Internet, los usuarios buscan videos, fotos, música, entre otros tipos de contenido; convirtiéndose en un hobby que consume bastante tiempo. La sociedad de hoy en día ya no cuenta con el tiempo necesario para navegar los contenidos alojados en las redes, por diversos motivos como: el trabajo, la familia, el estudio, entre otros; volviéndose una tarea tediosa encontrar contenidos adecuados a los gustos de los usuarios.

Los sistemas de recomendaciones han venido implementándose con miras a lograr agilizar el acceso al contenido, y ayudar a minimizar el tiempo empleado por un usuario en la navegación, pero como es mencionado en el planteamiento del problema los sistemas de recomendaciones presentan unas problemáticas las cuales impiden un mejor desempeño a la hora de efectuar recomendaciones a los usuarios [8].

Al tener en cuenta los avances en la tecnología y su visión de conectar todo a la red, conocido comúnmente como internet de las cosas<sup>1</sup>, es posible pensar en dispositivos que permitan determinar los gustos de cada persona y de acuerdo a esto proporcionar recomendaciones de cualquier tipo de contenido. Con base en lo anterior, la motivación del presente trabajo es aportar ideas a la solución de las problemáticas mencionadas en el planteamiento del problema, en la búsqueda de lograr el acceso ágil a los contenidos multimedia del servicio de VoD. Es propuesto como mecanismo para abordar el problema el uso de los sistemas de recomendaciones, capaces de sugerir contenidos multimedia con base en las emociones y el contexto de usuario.

---

<sup>1</sup> Internet de las Cosas (IoT) es un entorno donde los objetos, animales o personas cuentan con identificadores únicos y la capacidad de transferir datos a través de una red. <http://whatis.techtarget.com/definition/Internet-of-Things>.

## 1.5 Estado Actual del Conocimiento

En esta sección están descritos un conjunto de trabajos que han sido tomados en cuenta para el planteamiento y formulación del presente trabajo de grado. Este proyecto abarca dos temáticas principales: **sistemas de recomendaciones basados en contexto para contenidos multimedia** y **sistemas de análisis de medidas fisiológicas** (ver figura 1.4).

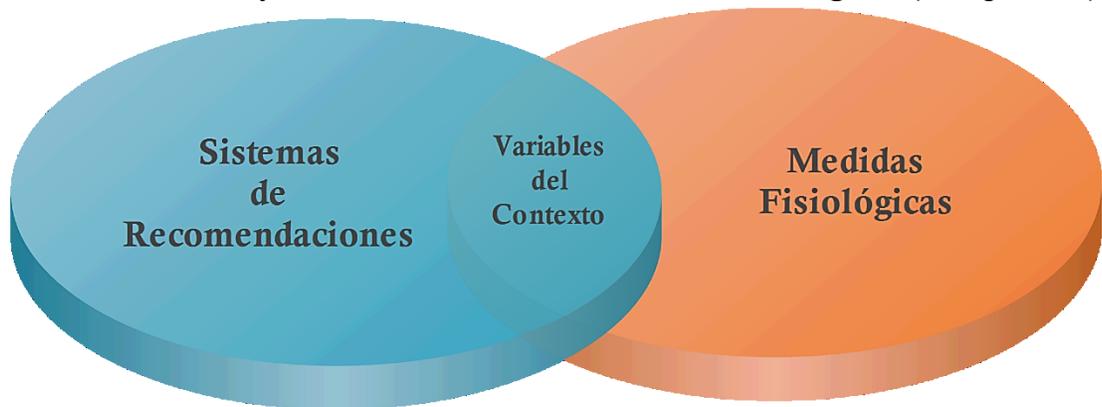


Figura 1.4 Diagrama de temáticas consideradas en el trabajo de grado, fuente: propia

### 1.5.1 Sistemas de recomendaciones basados en contexto para contenidos multimedia

Esta sección presenta un conjunto de trabajos tenidos en cuenta con respecto a la temática de sistemas de recomendaciones basados en contexto.

**Developing a recommender system in a consumer electronic device (2015)** [16]. Este artículo presenta un sistema de recomendaciones de contenidos multimedia para entornos móviles Android (smartphone y tablet) basado en contenido, el cual hace uso de información estática de usuario, además, métodos de calificación y clasificación son usados para filtrar el contenido multimedia a recomendar. El sistema inicialmente necesita de un proceso de calificación de géneros de películas, con el fin de obtener información inicial de usuario; posterior a ello esta información es cotejada con una base de datos de películas que han sido previamente etiquetadas de acuerdo a su género. Este trabajo presenta un aporte a los sistemas de recomendaciones, pues considera de gran importancia las características hardware del dispositivo de acceso (memoria, CPU, batería, entre otros.), y las características de red desde donde es consumido el servicio (contexto de red); a tal punto que el sistema es capaz de recomendar con o sin acceso a la red (nivel local o en línea), además de contribuir concepto de categorización de las películas, el cual ayuda a mejorar y optimizar el número de entradas al sistema de recomendación, este aporte puede ser tenido en cuenta en el desarrollo del presente trabajo de investigación. En este estudio no se

consideran las variables del contexto de usuario, como una posible solución al problema de arranque en frío en los sistemas de recomendaciones.

**Generating Context-aware Recommendations using Banking Data in a Mobile Recommender System (2012)** [17]. Este artículo presenta un modelo basado en contexto para los sistemas de recomendaciones móviles, el cual considera información del contexto de usuario (actividad corriente diaria, ubicación, hora, etc.) e información estática de usuario, las cuales provienen de dos fuentes principales: el usuario e información bancaria del mismo proporcionada por un banco reconocido de España. Además, el usuario inicialmente debe proveer entradas al sistema, como lo es la selección de las categorías de lugares (hoteles, restaurantes, parques, otros.), lo cual ayude a enriquecer al sistema. En este estudio es necesaria información personal, social y bancaria de otros clientes, propios de los sistemas de recomendaciones colaborativos; con el fin de ayudar a filtrar, adaptar y personalizar el perfil de usuario, y así finalmente recomendar lugares cercanos asociados al perfil de usuario. Este modelo no considera variables fisiológicas, las cuales pueden ayudar a describir los gustos y necesidades del mismo, dotando de datos al sistema en estados preliminares, para realizar las sugerencias. Aun cuando el trabajo está orientado a tecnologías móviles, este trabajo tiene buenos aportes en la consideración de variables del contexto de usuario, que puede ayudar a solucionar el problema de arranque en frío. Además, implementa un ciclo de tres fases (Contexto social, localización y de usuario), con el fin de adaptar mejor los sistemas de recomendaciones.

**Combining Multiple Criteria and Multidimension for Movie Recommender System (2009)** [18]. Este artículo presenta un sistema de recomendaciones híbrido para contenidos multimedia, el cual tiene en cuenta información del contexto de usuario (lugar, día, hora, etc.) y procesos de calificación de las películas; además consideran en este trabajo el uso de filtros colaborativos, mediante el uso de métodos de regresión lineal y vecindades. El sistema inicialmente necesita de un proceso de calificación de las características (género, frecuencia de selección, premios, etc.) asociadas a las películas, por parte del usuario y un grupo de amigos. Este sistema no considera la inferencia de estados emocionales del usuario (ritmo cardíaco, estado de ánimo, otros.) es decir, no emplea las variables fisiológicas para generar las recomendaciones, además no tiene en cuenta las características de hardware del dispositivo de acceso y las características de la red. Este trabajo presenta buenos aportes en los métodos de análisis de datos, utilizados en los sistemas de recomendaciones, los cuales pueden ser tenidos en cuenta en el presente trabajo de investigación.

**SVR-based Music Mood Classification and Context-based Music Recommendation (2009)** [32]. Este artículo presenta un sistema de recomendaciones basado en contexto para contenidos multimedia musicales, teniendo en cuenta el estado de ánimo del usuario. El sistema de recomendaciones provee dos modos diferentes de respuesta: por un lado,

entrega una recomendación basada en filtros colaborativos centrada en los ítems valorados, y por otro lado, una recomendación basada en inferencia (a partir de una ontología), la cual relaciona el estado de ánimo del usuario con contenidos multimedia musicales previamente clasificados. El estado de ánimo del usuario es determinado a partir de variables del contexto, mientras que la clasificación del contenido multimedia musical, es obtenida a partir del cálculo del factor musical de *arousal/valence* (a partir de características como tonalidad, ritmo, intensidad, escala, etc.) y del uso del método de regresión de vector de soporte (SVR). A partir de lo anterior cada canción es clasificada dentro de 11 categorías posibles de estado de ánimo (enojado, aburrido, calmado, emocionado, feliz, nervioso, tranquilo, contento, relajado, triste y somnoliento). Este artículo no incluye dentro del sistema de recomendaciones los filtros basados en contenido, ni medidas fisiológicas, lo cual puede mejorar aún más la precisión del recomendador. Este trabajo aporta importantes ideas en cuanto a la clasificación del contenido de video musical en estados de ánimo que pueden ser tenidas en cuenta para el diseño e implementación del recomendador propuesto en el presente trabajo de grado.

**A study of user behavior in online VoD services (2014)** [9]. En este trabajo es presentado un modelo del comportamiento de usuarios, frente al consumo del servicio de video bajo demanda en internet; con el fin de analizar, configurar y ordenar de una mejor manera, contenido multimedia al usuario. El modelo propuesto está encargado de analizar la calidad de experiencia (QoE) del usuario, a través de una serie de sesiones vinculadas a los contenidos de video; además el trabajo vincula en su desarrollo a un proveedor del servicio de video bajo demanda para el consumo de contenidos. Este estudio propone un reproductor de video en el lado del cliente, con el fin de recolectar información del comportamiento de usuario, y así poder ayudar a mejorar el rendimiento del sistema e índice de popularidad de videos. Esta investigación no considera el planteamiento de una arquitectura, ni la definición de un esquema para el consumo de servicios de video bajo demanda; además no presenta un sistema de recomendaciones de contenidos multimedia. Este artículo presenta distintos tipos de métricas de similitud, considerados en los sistemas de recomendaciones basados en filtros colaborativos.

**Web mining based framework for solving usual problems in recommender systems: A case study for movies recommendation (2015)** [21]. Este artículo propone un marco basado en minería web para hacer frente a los problemas principales mencionados por los autores para los sistemas de recomendaciones: escalabilidad, escasez de datos, primer calificador, problemas de arranque en frío. Los autores plantean dos procesos, uno efectuado de manera off-line: corresponde a la inducción de la predicción de los modelos, toma la información de los nuevos usuarios. Y un proceso online: hace las recomendaciones a los usuarios mediante la comprobación de los modelos inducidos. La recomendación está basada en modelos de bajo nivel y alto nivel. La diferencia radica en que los primeros tienen

en cuenta las características del video y el usuario y los últimos solo en las calificaciones que el usuario hace del video. El autor realiza una comparación de los distintos algoritmos de clasificación asociativa y no asociativa, siendo el algoritmo de clasificación asociativa CMAR (clasificación basada en Múltiples Reglas de Asociación) el de mejor precisión. Este artículo está centrado en la generación de un modelo predictivo aplicando algoritmos para la minería de datos y no plantea como solución a los problemas el uso de variables del contexto, ni toma en cuenta características afectivas de los contenidos.

### 1.5.2 Sistemas de análisis de medidas fisiológicas

Esta sección presenta un conjunto de trabajos que fueron tenidos en cuenta con respecto a la temática de sistemas de análisis de medidas fisiológicas.

#### **Children in Schoolyards: Tracking movement patterns and physical activity in schoolyards using global positioning system and heart rate monitoring (2009) [28].**

Este artículo presenta un sistema de análisis de localización global GPS y actividad física, de un grupo de niños estudiantes entre los 6 a 7 años; el estudio fue llevado a cabo en dos centros educativos del sur de Noruega. El sistema inicialmente analiza y organiza una serie de ortofotos<sup>2</sup> del centro educativo, posterior a ello son realizadas medidas de posición de cada niño, mediante el sistema de localización GPS; con el fin de cotejar la información y almacenar los patrones de movimiento de los mismos en una base de datos. Este trabajo considera medidas del nivel de actividad física de cada niño, obtenidas a través de un reloj de pulso polar<sup>3</sup>; con el fin de aportar al análisis del comportamiento y quema de calorías de los niños estudiados. Este trabajo no considera variables del contexto geográfico del lugar (estado del tiempo, hora, posición geográfica, etc.), además que solo pretende realizar el estudio del comportamiento físico de un determinado grupo de estudio; el cual deja libre su línea de investigación y campo de acción. Este artículo si bien no pertenece como tal al ámbito de sistemas de recomendaciones, brinda un aporte en el análisis de los patrones de movimiento de un usuario, los cuales pueden considerarse para retroalimentar los sistemas de recomendaciones y aportar una posible solución al problema de arranque en frío. Este trabajo brinda un buen aporte en considerar medidas de frecuencia cardíaca, las cuales pueden tenerse en cuenta en el trabajo de investigación.

**A Stress Sensor Based on Galvanic Skin Response (GSR) Controlled by ZigBee (2012) [29].** En este artículo los autores diseñaron un dispositivo RGP (respuesta galvánica de la piel), con el fin de detectar la conductancia de la piel cuando una persona está bajo estrés, para ello utilizan tan sólo dos electrodos colocados en los dedos. Este dispositivo

---

<sup>2</sup> Fotografía aérea corregida geoméricamente, online: <http://grafcan.es/ortofotos>.

<sup>3</sup> Reloj deportivo con GPS para medidas de frecuencia cardíaca, online: <http://relojesgps.es>.

envía datos diferentes a través de un coordinador ZigBee y, al mismo tiempo, este enviará la información a un ordenador. Con el fin de comprobar el rendimiento del dispositivo, han utilizado 16 adultos (ocho mujeres y ocho hombres) los cuales completaron diferentes pruebas que requieren un cierto grado de esfuerzo, como resolver operaciones matemáticas o realizar respiración profunda. Al finalizar, es posible apreciar como la RGP es capaz de detectar los dos estados estudiados (relajado, nervioso) de cada usuario, con una tasa de éxito de 76,56%, este artículo proporciona medidas o valores experimentales de tensión, que mediante la experimentación los autores obtuvieron, estos datos permiten establecer una relación con los diferentes estados emocionales de las personas, y establecer de esta manera márgenes de caracterización de dichos estados.

**Computing Emotion Awareness through Galvanic Skin Response and Facial Electromyography (2008)** [30]. En este artículo los autores buscan un primer paso a un sistema que reconoce emociones de los usuarios individuales, esta investigación está centrada en cómo los estados emocionales son expresados por medio de seis parámetros (es decir, la desviación absoluta media, desviación estándar, la varianza, la asimetría y la curtosis) por medio de la utilización de medidas fisiológicas tales como: la respuesta galvánica de la piel (RGP) y señales electromiográficas. En el proyecto fue solicitado a 24 participantes ver escenas de una película de 120 segundos, posteriormente fueron calificadas por ellos. Estos valores han permitido distinguir cuatro categorías de emociones: negativo, positivo, mixtas y neutras, gracias a las bioseñales tomadas. Este artículo aporta al trabajo, en cuanto a los formas para caracterizar las emociones, ya sean positivas o negativas, además permite evidenciar que la respuesta galvánica de la piel puede ser uno de los mecanismos para capturar cómo una persona está emocionalmente en un instante.

**Intelligent Data Analysis Algorithms on Biofeedback Signals for Estimating Emotions (2014)** [33]. En este artículo los autores explican cómo las bioseñales están relacionadas con los estados de ánimo; cuando el cuerpo humano experimenta diferentes emociones como el miedo, la ira, la tristeza y la alegría. Estas bioseñales son: conductancia de la piel (RGP), volumen sanguíneo (BVP), ondas cerebrales (EEG), la tensión muscular, temperatura y la respiración. El objetivo general de este trabajo es diseñar y desarrollar un sistema portátil, el cual permite medir diferentes parámetros del sistema nervioso autónomo (RGP, temperatura, frecuencia cardíaca, EEG) de una persona y mostrarlo en cualquiera de los dispositivos de salida mediante el uso de un algoritmo efectivo para el reconocimiento de estrés utilizando sistemas de aprendizaje. Este artículo aporta al proyecto de investigación medidas experimentales y brinda información de cómo varían las bioseñales con base a los estados de ánimo (enojado, miedo, alegría, entre otros).

**Mental Stress Evaluation using Heart Rate Variability Analysis: A Review (2015)** [31]. Este artículo analiza cómo influye VFC (variabilidad de la frecuencia cardíaca) en la

evaluación del estrés mental. Diversas técnicas disponibles para la evaluación de la VFC en el dominio del tiempo y el dominio de frecuencia son analizadas, los resultados son revisados para la comprensión de su importancia. Los resultados son obtenidos a partir de dos estudios de caso realizados en dos diferentes ambientes para el establecimiento de relación entre VFC y el estrés mental percibido. Este artículo aporta en el conocimiento de las técnicas para la evaluación del estrés mental a partir de la frecuencia cardíaca, y permite visualizar de una manera experimental cuales de estas son las más eficientes, permitiendo obtener datos que posibiliten la predicción del estado de ánimo de la persona.

## 1.6 Aportes del Proyecto

### 1.6.1 Brechas Existentes

A partir del estado del arte generado se encontraron las siguientes brechas en el desarrollo del trabajo:

- De acuerdo a la revisión teórica realizada, los sistemas de recomendaciones analizados propuestos no toman en cuenta medidas fisiológicas como método de entrada para realizar las recomendaciones, entre las que es posible destacar a la frecuencia cardíaca y la conductancia de la piel.
- De acuerdo a la literatura encontrada, para las medidas fisiológicas no se ha evidenciado la existencia de sistemas que involucren código fuente abierto y libre, que sean utilizados en la rutina diaria de los usuarios para la captura de medidas fisiológicas.
- En la revisión literaria no fue posible evidenciar sistemas de recomendaciones para el servicio de video bajo demanda, donde sea aplicada la temática de internet de las cosas, para la caracterización del contexto de usuario.
- De acuerdo a la revisión literaria realizada, es posible concluir que hay un limitado uso de variables del contexto de usuario utilizadas para la recomendación de contenido multimedia, pues en su mayoría utilizan características del contenido, entre ellas: el autor, genero, tipo, etc.
- A partir de la revisión literaria no fue posible evidenciar la existencia de sistemas de recomendaciones basados en contexto para contenido de video musical.

- De acuerdo a la revisión de artículos, no fue posible encontrar trabajos que implementen la computación afectiva<sup>4</sup> como mecanismo para la recomendación de contenido musical de video bajo demanda.

### 1.6.2 Aportes Académicos

De acuerdo a los objetivos planteados se pretende en el presente trabajo realizar los siguientes aportes:

- Construcción de un sistema hardware-software, el cual permita la monitorización continua y captura de medidas fisiológicas de usuario, con el fin de mejorar la caracterización del perfil de usuario utilizado en los sistemas de recomendaciones.
- Adaptación de un método para inferencia de contenidos multimedia afectivos del servicio de video bajo demanda, a partir de variables del contexto de usuario, con el fin de aportar una posible solución al problema de arranque en frío (*cold start*)<sup>5</sup> que presentan los sistemas de recomendaciones.
- Un *dataset*<sup>6</sup> de contenidos multimedia afectivos para el servicio de video bajo demanda, considerando las características de los parámetros auditivos musicales asociados a los contenidos multimedia.
- Un servicio de video bajo demanda para contenidos multimedia afectivos, teniendo en cuenta información del *dataset*. Este aporte permite proveer de contenidos de video musicales al sistema de recomendaciones.
- Diseño de un sistema de recomendaciones basado en contexto para contenidos multimedia afectivos.
- Construcción de un prototipo del sistema de recomendaciones basado en el contexto de usuario para el servicio de video bajo demanda, para un caso de estudio de contenidos multimedia musicales.

---

<sup>4</sup> La computación afectiva es la línea de estudio enfocada en interpretar el comportamiento y gestos de los seres humanos. <http://h4dm.com/que-es-la-computacion-afectiva>.

<sup>5</sup> El problema de arranque en frío (*cold start*) consiste en la incapacidad del sistema de recomendaciones para recomendar contenidos cuando aún no se dispone de la información necesaria de usuario. <http://sciencedirect.com/science/article/pii/S0957417413007240>.

<sup>6</sup> Representación de datos residente en memoria, además proporciona un modelo de programación relacional coherente independientemente del origen de datos. <http://redalyc.org/articulo.oa?id=94419100008>.

## 1.7 Objetivos

### 1.7.1 Objetivo General

Proponer un sistema de recomendaciones para el servicio de VoD, basado en la inferencia de emociones a partir de variables del contexto de usuario.

### 1.7.2 Objetivos Específicos

- Generar un *dataset* de contenidos multimedia afectivos, teniendo en cuenta las características de los parámetros auditivos musicales<sup>7</sup>.
- Adaptar un método para la inferencia de contenidos multimedia afectivos, a partir de variables del contexto de usuario.
- Diseñar un sistema de recomendaciones de contenidos multimedia afectivos, considerando el método de inferencia adaptado.
- Evaluar funcionalmente el sistema de recomendaciones diseñado, mediante un prototipo para el servicio de VoD de contenidos musicales.

## 1.8 Enfoque

El estado del arte elaborado permitió conocer diferentes clasificaciones de sistemas de recomendaciones como son los colaborativos y basados en contenido; pero como es mencionado en el planteamiento del problema estos evidencian los problemas de escasez de datos y arranque en frío. Existen sistemas de recomendaciones híbridos basados en conocimiento, cuyo funcionamiento se basan en la inferencia de las preferencias de usuario en estados preliminares.

Por otra parte, la consulta teórica permitió observar distintas variables a tener en cuenta en el proceso de diseño y desarrollo, siendo más pertinentes para el proyecto las medidas fisiológicas. Por esta razón se propone un sistema de recomendaciones que tenga en cuenta las variables del contexto de usuario, para el servicio de video bajo demanda.

Por lo tanto, el enfoque del presente proyecto comienza con la conformación y clasificación del catálogo de contenidos multimedia, teniendo en cuenta el modelo de *arousal-valence*,

---

<sup>7</sup> Los parámetros auditivos (*arousal*, *valence*, tono, etc.) permiten distinguir y clasificar los contenidos multimedia musicales [http://audi duct.com/Lessons/8\\_Parameters.html](http://audi duct.com/Lessons/8_Parameters.html).





- *Capítulo 5: Evaluación y Pruebas:* Este capítulo desarrolla la evaluación del sistema de recomendaciones propuesto frente a los mecanismos de recomendaciones clásicos; además, se evalúan los tiempos de respuesta por medio de pruebas de carga y estrés realizadas al: módulo hardware-software, servidor de procesamiento y servidor de contexto.
- *Capítulo 6:* En este Capítulo se presentan las conclusiones a las que se llegó con el desarrollo de esta tesis, teniendo en cuenta los objetivos planteados al inicio del proyecto, así como también los trabajos futuros y publicaciones derivados del trabajo de grado.



## Capítulo 2

### ***Dataset* de contenidos musicales de video**

#### 2.1 Introducción

En el presente capítulo, es mostrada la temática relacionada con las características musicales, es decir las variables relacionadas al contenido multimedia las cuales permiten inferir las emociones relacionadas a cada video. Es presentado también los distintos modelos utilizados para estructurar las emociones y su relación con la música, además de las herramientas que existen en el mercado actual y las cuales hacen uso de las emociones para interactuar con el usuario. Adicionalmente es descrito el proceso como es realizada la conformación del *dataset* de video musical, el cual es utilizado como representación de los datos residentes en memoria como son los videos y sus características, proporcionando un modelo de programación relacional, coherente e independiente del origen de datos que contiene [35]. Además, es posible observar el modelo de emociones realizado para la generación de dicho *dataset*.

#### 2.2 Metodología para la generación del *dataset*

Para la conformación del *dataset* de contenidos de video musicales, se proponen cinco fases a saber: estudio de características musicales y modelos de emociones, exploración de soluciones comerciales basadas en emociones, propuesta de un modelo basado en emociones, diseño y construcción del *dataset* de contenidos multimedia musicales y evaluación del *dataset* de contenidos musicales de video (ver figura 2.1).

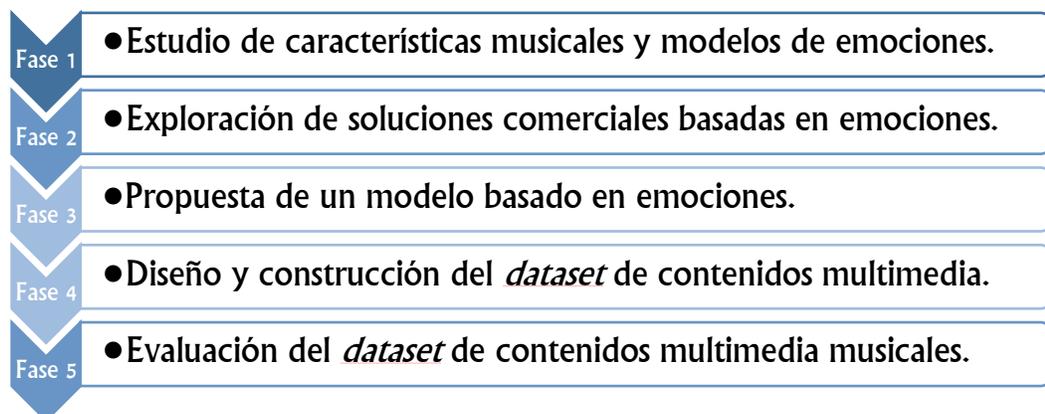


Figura 2.1 Metodología para la generación del *dataset*, fuente: propia

En la primera fase es realizado el estudio de las principales características musicales y los principales modelos de emociones, con el fin de identificar claramente la relación entre los contenidos multimedia y las emociones. En la segunda fase es realizada la exploración de las herramientas, librerías y tecnologías para la clasificación de contenidos multimedia de acuerdo a las emociones, con el propósito de identificar posibles opciones a nivel de desarrollo para la construcción del *dataset*. En la fase tres es presentada la propuesta adaptada del modelo de clasificación de emociones, obtenida a partir de los modelos presentados en la fase uno. El modelo de clasificación propuesto fue utilizado para conformar el *dataset* a partir de las tecnologías identificadas en la fase dos. Por su parte, en la fase cuatro es realizada la construcción del *dataset* de contenidos multimedia, considerando el modelo de clasificación propuesto en la fase tres y las herramientas seleccionadas en la fase dos. Finalmente, en la fase cinco, el *dataset* de contenidos multimedia es evaluado mediante la implementación de un servicio de VoD basado en emociones.

## 2.3 Características musicales

Existen determinadas características del contenido multimedia musical y las cuales permiten inferir que emoción podría generar en el usuario, al igual estas se encuentran asociadas al estado de ánimo presente en una persona durante un determinado momento. Algunas de las variables y las cuales permiten dicha inferencia de emociones son el *arousal* y la *valence*, relacionadas con diferentes patrones de señales acústicas, por ejemplo, el *arousal* está relacionado con el tempo (rápido/lento), la intensidad del tono (alta/baja), *pitch* (alto/bajo), *loudness* (alto/bajo), y el timbre (brillante/suave), en cambio la *valence* está relacionada con el modo (mayor/menor) y armonía (consonante/disonante) [36]. También se observa como la percepción de la emoción raramente depende de una única característica de la música, sino de la combinación de varias de ellas. Por ejemplo, los acordes fuertes y agudos pueden sugerir más *valence* positiva en comparación a acordes suaves y de tono bajo, cualquiera que sea el modo [37]. A continuación, son descritas las variables: *arousal*, ritmo, tempo, *speechiness*, *liveness*, *acousticness*, *danceability*, *valence*, modo (ver tabla 2.1).

Tabla 2.1 Características musicales del contenido, fuente: propia

Característica	Descripción
<i>Valence</i> (valencia o positividad)	Esta propiedad musical describe la positividad musical transmitida por una pista de audio. Las pistas con alta valence están asociadas con emociones positivas tales como: estar feliz, alegre eufórico, entre otros. Por otra parte, las pistas con baja valence están asociadas a emociones negativas o estados de ánimo tales como: tristeza, depresión, enojo [38].

<i>Arousal (energía o activación)</i>	<i>Representa una medida de percepción de la intensidad y la actividad a lo largo de la pista musical. Típicamente las pistas rápidas y las cuales cuentan con sonidos fuertes y ruido, como por ejemplo el rock pesado, tendrían una alta energía, mientras que una pista de música clásica como: Air de Beethoven, estaría bajo en la escala de energía. Otras características a tener en cuenta en este atributo son el rango dinámico, percepción del volumen, timbre, entropía general [38].</i>
<i>Rhythm (ritmo)</i>	<i>El ritmo es el patrón de pulsos o notas de fuerza variable, descrita a menudo en términos del tempo, métrica o fraseo. Una canción con un ritmo rápido a menudo es percibida como una alto arousal, además un ritmo fluido se asocia generalmente con una valence positiva, mientras que un ritmo firme está asociado con una valence negativa [39].</i>
<i>Tempo (tempo o velocidad)</i>	<i>Esta propiedad sirve en una pieza musical para transmitir emociones, de tal modo que la música rápida según estudios es percibida o relacionada con emociones activas (felicidad), en cambio la música lenta tiende a percibirse como una emoción pasiva (tristeza). El tempo varía usualmente entre 20ppm y 240ppm, aunque puede tomar valores menores o mayores a estos [38].</i>
<i>Speechiness (audible)</i>	<i>Esta es una característica que permite detectar la presencia de las palabras habladas en una pista. Los valores superiores a 0.66 describen pistas donde probablemente están hechas totalmente de palabras. Por su parte, valores comprendidos entre 0.33 y 0.66 describen pistas que pueden contener tanto música como interpretación de palabras. Finalmente, los valores por debajo de 0.33 probablemente puedan ser solo música [38].</i>
<i>Liveness (viveza)</i>	<i>Esta propiedad musical permite detectar la presencia de audiencia en la grabación. De este modo, con valores del 1.0 la probabilidad de la pista sea en vivo es alta. Los valores entre 0.6 y 0.8 describen pistas que pueden o no estar en vivo o contener audiencia simulada, por lo general está simulación es colocada al inicio o al final de la pista musical. Por último, los valores inferiores a 0.6 son grabaciones realizadas en un estudio [38].</i>
<i>Acousticness (acústica)</i>	<i>Es la característica con la cual se puede medir la probabilidad de que una grabación haya sido creada únicamente con elementos tales como la voz e instrumentos acústicos, en lugar de utilizar elementos electrónicos. Las pistas con valores bajos suelen incluir guitarras eléctricas, distorsión, sintetizadores, entre otros. Así mismo, los valores cercanos a 1 indican si la canción presenta esta característica [38].</i>
<i>Danceability (bailabilidad)</i>	<i>Esta característica sirve para conocer si un contenido es el más adecuado para el baile. Las pistas con valores cercanos a 1, son los que mayormente reflejan esta característica en todo su desarrollo. Según [38], algunos elementos pueden ayudar a caracterizarla, tales como: el tempo, la estabilidad del ritmo, la regularidad de la pista, entre otros.</i>
<i>Mode (modo)</i>	<i>Es la propiedad con la cual se puede indicar la modalidad (mayor o menor) de una pista, es decir el tipo de escala de la que deriva su contenido melódico [38].</i>

## 2.4 Emoción

En el campo de la emoción, ha sido amplia la variedad de definiciones propuestas, aunque ninguna de estas ha sido absolutamente aceptada por todos los investigadores, una definición común es la planteada a continuación. “La emoción es un conjunto complejo de interacciones entre los factores subjetivos y objetivos, mediadas por sistemas neurales-

hormonales, que pueden dar lugar a experiencias afectivas, tales como sentimientos de excitación o *arousal*, placer o displacer y los cuales conducen a un comportamiento común, pero no siempre expresivo, dirigidos hacia una meta, y adaptativos” [40].

### 2.4.1 Estructura de las emociones

Las emociones pueden ser reducidas a un núcleo afectivo específico placer o displacer. Otros estudios sugieren modelos en dos dimensiones, tales como el modelo de *arousal-valence*, donde el *arousal* puede ser alto o bajo y la *valence* puede ser positiva o negativa pudiendo caracterizar cualquier emoción por sus coordenadas en un espacio de dos dimensiones (ver figura 2.2). Como ejemplo, la felicidad usualmente tiene *valence* positiva y *arousal* moderadamente alto, en cambio la tristeza tiene un *arousal* moderadamente bajo y *valence* negativa [37].

Figura 2.2(a): Modelo de dos dimensiones

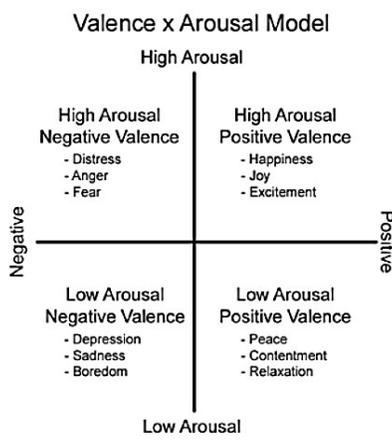


Figura 2.2(b): Modelo mixto de valence

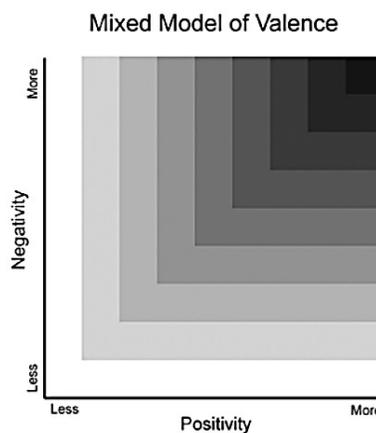


Figura 2.2 Modelos de emociones, tomado de [37]

En la figura 2.2(a) es mostrado el diagrama del modelo afectivo de dos dimensiones (*arousal-valence*), donde son mostradas ejemplos de emociones ubicadas de acuerdo a su nivel de positividad y *arousal*. En la figura 2.2(b) es apreciado el modelo de *valence* mixta, las partes más oscuras del gráfico representan una gran mezcla de sentimientos donde es compartida la activación tanto positiva como negativa variando en grados. A continuación, son descritos algunos de los modelos de emociones más difundidos, dentro de los que se encuentran: modelo circunflejo de Russell, modelo de Hevner, modelo de Plutchick.

### 2.4.2 Modelo circunflejo

El modelo circunflejo (Russell, ver figura 2.3), es tal vez uno de los modelos más investigados, una estructura circular de dos dimensiones (*valence/activación*), que parte el

espacio en cuatro cuadrantes, en el cual las emociones son trazadas basándose en su nivel de actividad (activo/pasivo) y su *valence* (positiva/negativa). El modelo circunflejo del afecto, muestra como los estados afectivos surgen de interpretaciones cognitivas de sensaciones nerviosas centrales, los cuales son el producto de dos sistemas neurofisiológicos independientes, dichos sistemas uno está relacionado con la *valence* (placer/desagrado) y el otro al *arousal* (estado de alerta). Cada emoción puede ser vista como una combinación lineal de estas dos dimensiones o diversos grados de *valence* [41].

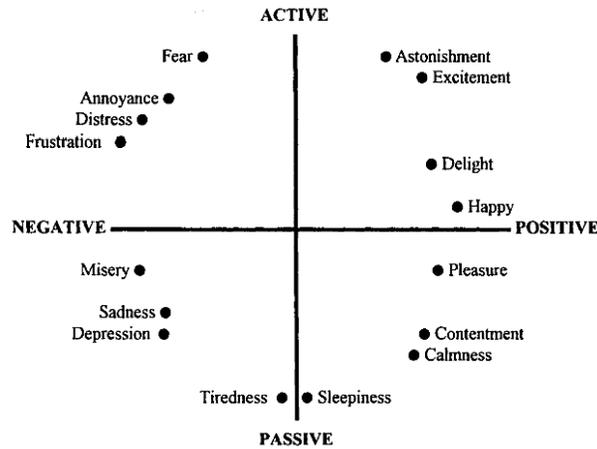


Figura 2.3 Modelo circunflejo de las emociones adaptado por Russell, tomado de [41]

El modelo posee una estructura clara que tiene implicaciones en la forma como las emociones son experimentadas en términos de la evaluación cognitiva, es decir, como bueno y como malo o deseado y no deseado, a partir de respuestas fisiológicas es decir los niveles de *arousal* y *valence*.

### 2.4.3 Modelo de Hevner

Este modelo se desarrolló con base a una experimentación en donde fueron manipuladas características musicales como: melodía, armonía, modo, ritmo y tempo, a piezas musicales. El experimento consistió en darle a escuchar a un grupo de personas, la versión original y una versión modificada, en la cual es alterada una sola característica. Después de escuchar las dos versiones, se les preguntaba a las personas acerca de la emoción que describía mejor la pieza escuchada, y les pedían señalar en el modelo dicha emoción. Lo anterior permitió realimentar el modelo inicial con diferentes emociones, tal como es mostrado en la figura 2.4 [42].

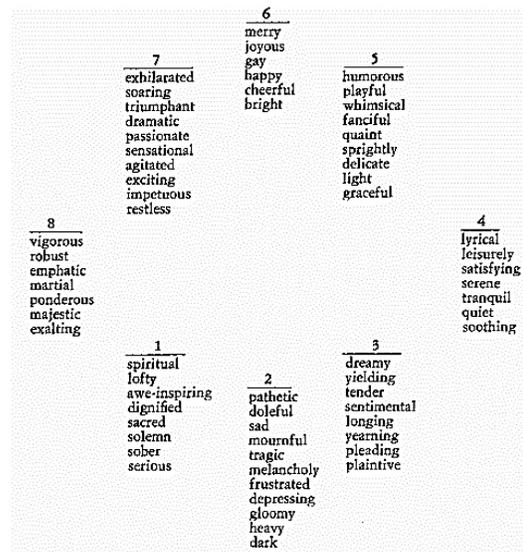


Figura 2.4 Modelo de las emociones de Hevner, tomado de [42]

Según el estudio realizado, concluyeron que utilizando la característica e identificando el estado de ánimo de los participantes, es posible modificar el estado emocional de una persona de forma gradual, siendo el tiempo y el modo las variables que más impacto generaron en los oyentes.

#### 2.4.4 Modelo tridimensional

El modelo agrega la variable de intensidad emocional, a las dimensiones de la *valence* y actividad (equivalente al *arousal* para este modelo). Dicha variable se refiere a que tan fuerte o débil es una emoción. Esta no se debe confundir con actividad, pues esta significa la desviación del estado fisiológico normal de una persona, siendo las disminuciones en este estado, representaciones de baja actividad y los aumentos una alta actividad. Así, la variable de intensidad está relacionada con el grado en que la experiencia emocional produce un cambio de un estado neutral a uno emocional.

#### 2.4.5 Modelo de plutchick

Es un modelo tridimensional en el cual son postuladas 8 emociones primarias (tristeza, sorpresa, miedo, ira, entre otras) de las cuales se derivan las demás, proponiendo que las emociones varían en polaridad, intensidad y grado de similitud, donde las emociones se intensifican a medida que se mueve desde el exterior hacia el centro de la circunferencia. A modo de ejemplo, una emoción como el aburrimiento, puede intensificarse en el odio si no es controlado. Además, cada sector del círculo tiene su emoción opuesta correspondiente (ver figura 2.5), lo contrario de la alegría y opuesto a su posición en la figura se encuentra la

tristeza. Las emociones con ningún color representan una emoción que es una mezcla de las dos emociones primarias por ejemplo la anticipación y la alegría se combinan para ser el optimismo [43].

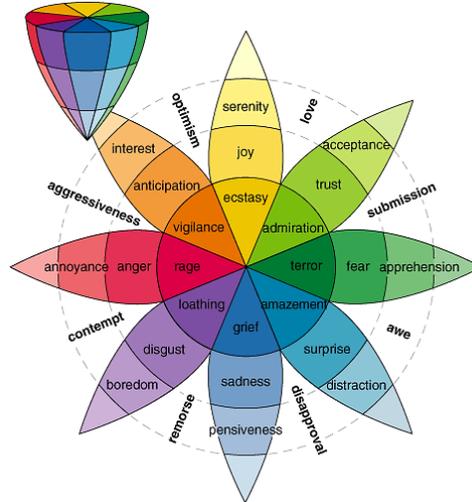


Figura 2.5 Modelo tridimensional de plutchick, tomado de [43]

En la realización de este trabajo, se decidió escoger el modelo circunflejo de dos dimensiones planteado por Russell, debido a su sencillez, amplio estudio y aceptación por diferentes profesionales del área. Así la propuesta del modelo de clasificación usada en este trabajo parte de dicho modelo y es presentada con detalle en la sección 2.6.

## 2.5 Soluciones comerciales

A continuación, son mostradas un conjunto de soluciones comerciales y/o librerías de desarrollo que utilizan las emociones con base en las características del contenido musical, para proporcionar datos que pueden usarse en la generación de recomendaciones de contenidos multimedia. Dentro de las API's exploradas se encuentran: Musicoverly, Gracenote y EchoNest.

### 2.5.1 Musicoverly

La API de Musicoverly proporciona datos para generar recomendaciones de música y listas de reproducción de todo tipo: desde un estado de ánimo, un artista, una pista, un género / estilo, un tema, un período / año (ver figura 2.6). La respuesta, una lista de pistas / artistas, se puede filtrar y personalizar con varios factores: la popularidad, país oyente, el tipo de

similitud. Puede acceder libremente a la API Musicover<sup>8</sup>, con la restricción de solo poder realizar 200 consultas en total. De este modo, es necesario solicitar una clave de API, permitiendo extender a 5000 las consultas. Para consultar sin limitación, necesita de una clave Premium. La API tiene soporte para realizar desarrollos en lenguaje PHP y el formato de respuesta del api es en JSON (JavaScript Object Notation) o XML (eXtensible Markup Language) [44].

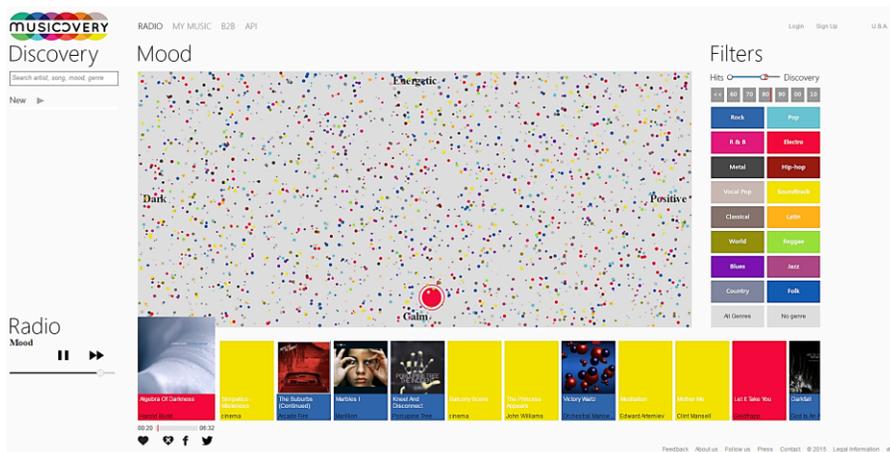


Figura 2.6 Interfaz de usuario Musicover, tomado de [44]

La interfaz de usuario de musicover muestra un servicio web de radio. Este trabaja en forma similar al modelo de *arousal-valence*, en el cual basta con presionar cualquier de los puntos en su interior y este le proporciona la canción para escuchar, además de poder realizar las búsquedas por género.

## 2.5.2 EchoNest

Es una herramienta desarrollada en los laboratorios del MIT por Tristán Jehan y Brian Whitman de la cual es propietario *Spotify*. Esta API permite obtener características del contenido tales como: la *valence*, *arousal* o energía, tempo, duración, popularidad, entre otros (ver figura 2.7). Para hacer uso de la API de EchoNest<sup>9</sup>, es necesario obtener una llave (clave) de la API, la cual da acceso o permite hacer 20 peticiones por minuto de manera ilimitada.

Esta herramienta además proporciona los mensajes de respuestas en formato JSON o XML. Entre los lenguajes a los que da soporte se encuentran: Python, Java, Ruby, PHP,

<sup>8</sup> La API de Musicover proporciona datos para la recomendación de música y generación de listas de reproducción. Página web oficial de Musicover: <http://musicover.com>.

<sup>9</sup> EchoNest es una plataforma inteligente de música, encargada del análisis de datos musicales. Página web oficial de EchoNest: <http://the.echonest.com>.

Objective-C/iOS, C++, Javascript, para los cuales proporcionan librerías que permiten implementar las funcionalidades básicas proporcionadas por EchoNest. Algunas de las librerías oficiales son: pyechonest la cual es la biblioteca para Python, Jen para clientes Java, Enios para Objective-C. Así mismo, dentro de las librerías no oficiales se encuentran: PHP echonest, Ruby echonest, node echonest para Javascript, entre otros [45].



Figura 2.7 Página web oficial de EchoNest, tomado de [45]

### 2.5.3 Gracenote

Esta API ofrece un conjunto de metadatos de música a través del protocolo de internet (HTTP, *Hypertext Transfer Protocol*), permitiendo búsquedas tales como género, región de origen y el estado de ánimo (ver figura 2.8). Además, ofrece las búsquedas de portadas de disco, imágenes biografía, artículos y otros contenidos relacionados. Para hacer uso de esta API es necesario conseguir una ID de cliente y una clave API que le autoriza hacer llamadas al servicio Gracenote<sup>10</sup> con un número limitado de peticiones. Este API ofrece clientes para aplicaciones web y móviles, el formato de respuesta del API es XML o JSON; y permite el desarrollo en lenguajes como: Python, PHP, Ruby, Java, pero no presta soporte para estos por ser proyectos no oficiales de Gracenote [46].

<sup>10</sup> Gracenote es un proveedor de metadatos de entretenimiento a usuarios y empresas. Página web oficial de Gracenote: <http://gracenote.com>.

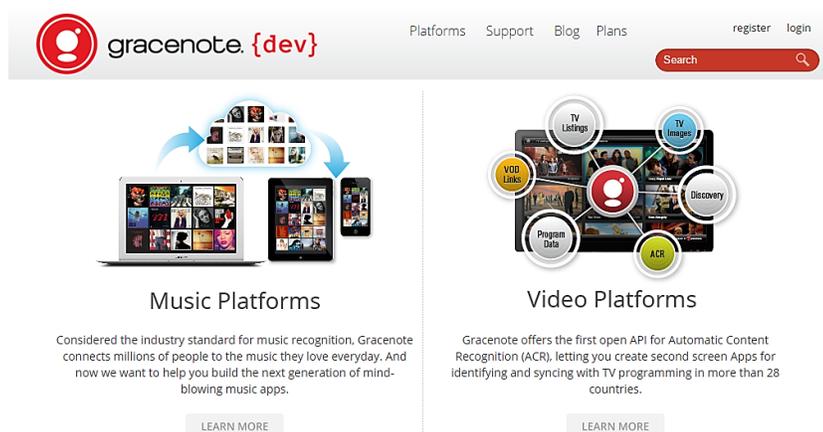


Figura 2.8 Página web oficial de gracenote, tomado de [46]

## 2.6 Conformación del *dataset* musical de video

Para la conformación del *dataset* de video, se eligió trabajar con la API de EchoNest, ya que esta permite realizar 20 consultas por minuto, estas no tienen un límite en cantidad, a diferencia de gracenote y musicoverly. Además de lo anterior, esta API presenta soporte para trabajar con lenguajes como Python y Java, los cuales han sido usados para el desarrollo de los distintos prototipos software realizados en el presente trabajo. Para el desarrollo con Python se hizo uso de la librería pyechonest<sup>11</sup>, mientras que en el caso de Java se utilizó la librería Jen<sup>12</sup>.

### 2.6.1 Modelo de emociones

El *dataset* de contenidos fue conformado teniendo en cuenta las 5 emociones consideradas por la API de EchoNest, y tomando como base el modelo de emociones de dos dimensiones (*arousal-valence*). Los estados de ánimo considerados en la representación del modelo son: excitado, feliz, relajado, triste y enojado. Además, se ha elegido trabajar con el modelo de *arousal-valence*, pues es un buen marco de referencia que facilita su uso y adaptación a nuevos diseños, debido a su simplicidad de dos coordenadas para la identificación de la emoción asociada al contenido. El nuevo modelo de emociones propuesto en esta sección es una adaptación de *arousal-valence* considerado en otros trabajos e investigaciones sobre el tema [36] [37] [47] [48]. El nuevo modelo generado es posible apreciarlo en la figura 2.9.

<sup>11</sup> Librería pyechonest de Python para el api de echonest, online: <http://echonest.github.io/pyechonest>.

<sup>12</sup> Librería Jen de Java para el api echonest, online: <https://github.com/echonest/jEN>.

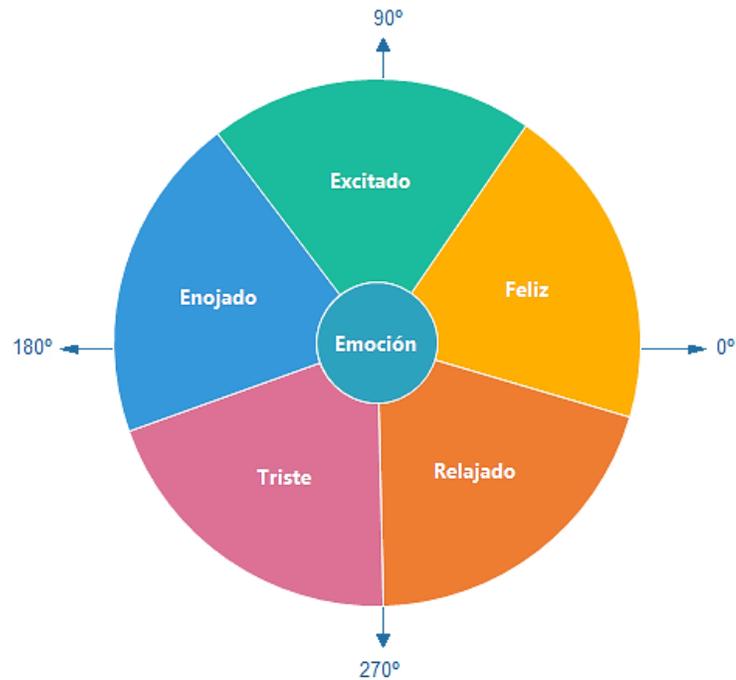


Figura 2.9 Modelo de arousal-valence adaptado a 5 emociones, fuente: propia

Cada una de las emociones descritas en la figura 2.9 tiene una amplitud de 72°, y el rango para el que está determinado cada estado de ánimo es observado en la tabla 2.2.

Tabla 2.2 Estados de emoción según el rango de ángulos, fuente: propia

RANGO DE ANGULOS	EMOCION ASOCIADA
$<54^\circ$ y $\geq 342^\circ$	Feliz
$\geq 54^\circ$ y $<126^\circ$	Excitado
$\geq 126^\circ$ y $<198^\circ$	Enojado
$\geq 198^\circ$ y $<270^\circ$	Triste
$\geq 270^\circ$ y $<342^\circ$	Relajado

### 2.6.2 Reconocimiento de emociones del contenido

Para verificar el funcionamiento del modelo de clasificación de emociones de la sección 2.6.1 y explorar la API de Echonest, se desarrolló una herramienta en lenguaje Java para el reconocimiento del estado de ánimo asociado a un contenido multimedia musical. En la aplicación desarrollada son observadas las propiedades musicales tales como: *energy* (energía o *arousal*), *valence*, tempo, el ángulo formado por la *valence* y *arousal* en el plano cartesiano, emoción, entre otros parámetros los cuales son apreciados en la figura 2.10.

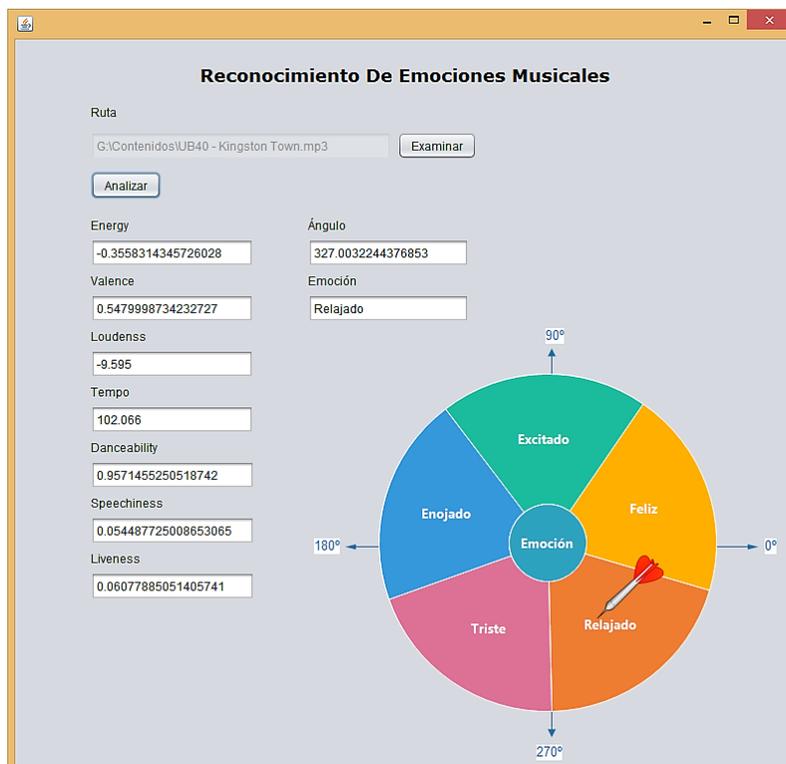


Figura 2.10 Reconocimiento de emociones musicales, fuente: propia

A modo de ejemplo, en la figura 2.10 es observado como haciendo uso de la librería Jen de Java (provista por Echonest), son analizadas las características musicales para la canción del grupo pop-reggae UB40 llamada Kingston Town. Los parámetros relevantes para conocer la emoción con la cual está asociada la canción son: el *arousal*, el cual tiene un valor de  $-0.3558$  o una representación en la mitad inferior del modelo. Al observar el valor de la *valence* proporcionada por la API, se sabe que la canción presenta una emoción positiva, por tanto, se encuentra en el cuarto cuadrante del gráfico. El ángulo resultante entre la propiedad *arousal* (eje y) y la propiedad *valence* (eje x), permite analizar de acuerdo a la tabla 2.2, la emoción asociada a la canción. El anterior proceso puede evidenciarse en el diagrama de bloques de la herramienta de clasificación desarrollada (ver figura 2.11).

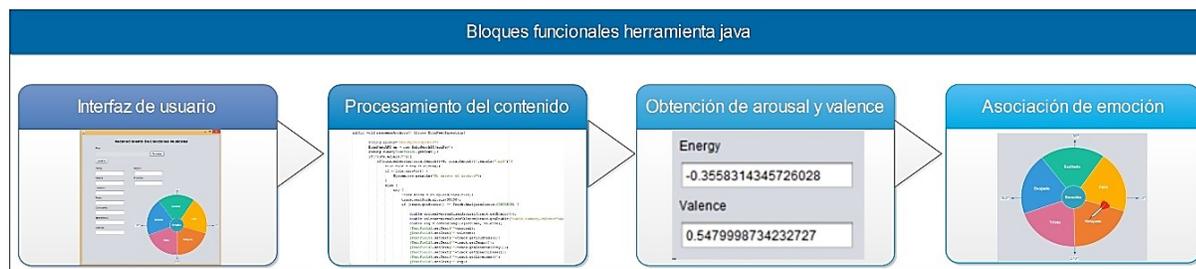


Figura 2.11 Bloques funcionales herramienta java, fuente: propia

### 2.6.3 Diagrama de flujo del *dataset* de contenidos

A continuación, son descritos los pasos realizados para la conformación del *dataset* de contenidos de video musical. Además, son mostradas las librerías y demás herramientas utilizadas para su generación. En la figura 2.12, es presentado el diagrama de flujo del proceso de generación del *dataset*, donde se incluyen las siguientes etapas: generación de listado de contenidos populares, obtención de parámetros musicales, asociación de contenidos por emociones, obtención URL youtube, consolidación del catálogo y descarga de contenidos.

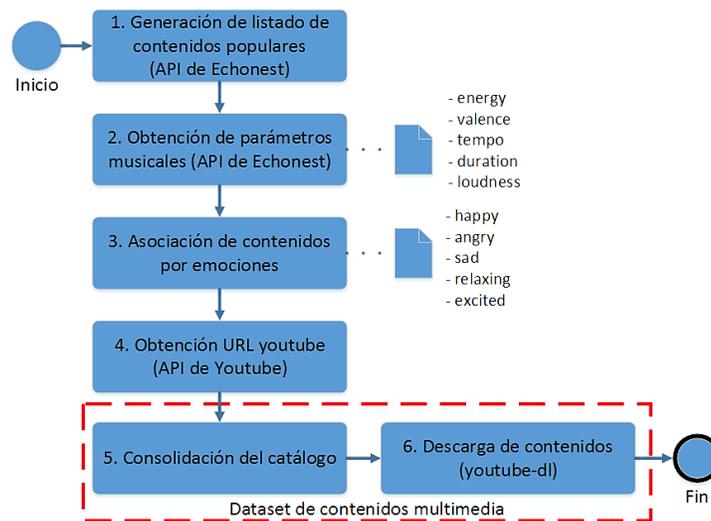


Figura 2.12 Diagrama de flujo del *dataset* de contenidos multimedia, fuente: propia

Para la generación del *dataset* de contenidos multimedia de video, se hizo uso de la librería `pyechonest` de Python, para lo cual es necesario adquirir una llave de acceso a la API, a través del registro en la página web oficial de EchoNest. En el anexo B son presentados los códigos y librerías adicionales de Python que fueron necesarias para la conformación del *dataset* como: `math`, `youtube_dl`, `urllib`, `cookieclib`, `sys`, `time`, entre otros.

A continuación, son descritos cada uno de los pasos seguidos para la generación del *dataset* de contenidos multimedia de video:

- En el paso “1” a través de la API de Echonest, se procede a generar un listado con las canciones más populares del catálogo de contenidos de Echonest. Para lo anterior, es generado un Script, encargado de realizar 18 peticiones cada 60 segundos, dadas las restricciones de acceso provistas por la API.

- En el paso “2” son obtenidas con ayuda de la API de Echonest un conjunto de características asociadas al contenido multimedia, dentro de estas se encuentran: *title*, *artist*, *energy*, *valence*, *tempo*, entre otras.
- En el paso “3” es realizada la asociación de las emociones con el contenido multimedia de video, usando para ello los valores de los parámetros de *arousal* y *valence*, los cuales permiten obtener el ángulo trigonométrico sobre el modelo de 5 emociones presentado en la sección 2.6.1. Dado que los valores obtenidos con la API de Echonest de las propiedades de *arousal* y *valence* están comprendidos entre 0 y 1, pero en el modelo de las emociones estos valores oscilan entre -1 y 1, se procede a normalizar los valores obtenidos con la API usando las ecuaciones 2.1(a) y 2.1(b). De esta forma es posible visualizar de una mejor manera si el contenido presenta una *valence* y *arousal* negativo.

$$arousal\_normalizado = 2*(arousal - 0.5) \quad (a)$$

$$valence\_normalizado = 2*(valence - 0.5) \quad (b)$$

*Ecuación 2.1 Formulas de normalización: arousal y valence*

- En el paso “4” se procede a obtener para cada contenido musical, la URL disponible en youtube del video asociado a este, para lo anterior se hizo uso de la librería `youtube-dl`<sup>13</sup> y la API de youtube. La librería de `youtube-dl` permite filtrar, seleccionar, descargar y manipular el contenido de youtube por medio de las características como la calidad, título, formato, categorías, fechas, entre otros. Adicionalmente, esta librería permite la captura de imágenes de cada uno de los videos, las cuales serán presentadas al momento de visualizar el catálogo. Con ayuda de dicha librería es realizada la búsqueda de los títulos para todos los videos en la categoría de música de la API de youtube y se hace una comparación con los proporcionados por la API de EchoNest. Para ello son filtradas las canciones con una correlación más alta a nivel del texto, haciendo uso del método `SequenceMatcher` de la librería `difflib` de Python. Este método retorna un valor entre 0 y 1, el cual representa el porcentaje de correlación entre los títulos del contenido. Una vez constatados los valores obtenidos, se seleccionan las URL que sobrepasen el valor de 0.6. Para acotar un poco más el listado de videos encontrados, es agregada la variable de videos más visitados, donde en su gran mayoría son los videos oficiales de las canciones y los de mejor resolución.
- En el paso “5”, una vez obtenidas las URL es realizada la consolidación del *dataset* en un archivo JSON, este es un formato más liviano y flexible que XML. El archivo JSON se administra por medio del gestor de base de datos “`tinydb`”, el cual está diseñado para ser simple de usar y no necesita de un servidor externo, además de ser compatible con todas las versiones modernas de Python.

<sup>13</sup> Es un programa de línea de comandos pequeña para descargar videos de YouTube.com y otros pocos sitios. Se encuentra online en: <https://github.com/rg3/youtube-dl>.

- En el paso “6” son realizadas las descargas de los contenidos en formato .mp4 haciendo uso de la librería youtube-dl.

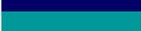
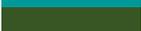
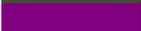
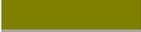
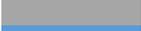
De esta manera, fueron descargados un total de 200 videos para la conformación del *dataset* de contenidos musicales de video, agrupando alrededor de 40 canciones por emoción. En la figura 2.13 es presentada una muestra de los campos asociados a cada uno de los contenidos de video musicales que constituyen el archivo JSON generado.

```
{ "_default": { "1": { "liveness": 0.094833, "energy": 0.717726, "tempo": 129.882, "speechiness": 0.106457, "currency": 0.22104064240294416, "instrumentalness": 0.338526, "duration": 313.94844, "view_count": 822693136, "mood": "Excited", "artist": "Major Lazer", "url": "http://www.youtube.com/watch?v=YqeW9_5kURI", "title": "Lean On", "acousticness": 0.033117, "danceability": 0.862321, "time_signature": 4, "loudness": -5.691, "valence": 0.421374, "mode": 0}, "2": {"liveness": 0.064907, "energy": 0.480501, "tempo": 80.025, "speechiness": 0.081512, "currency": 0.16323143005491134, "instrumentalness": 1e-06, "duration": 229.52576, "view_count": 1187333053, "mood": "Angry", "artist": "Wiz Khalifa", "url": "http://www.youtube.com/watch?v=RgKAFK5djSk", "title": "See You Again (feat. Charlie Puth)", "acousticness": 0.369444, "danceability": 0.689399, "time_signature": 4, "loudness": -7.503, "valence": 0.26631, "mode": 1}, "3": {"liveness": 0.515838,
```

Figura 2.13 Muestra del archivo JSON generado, fuente: propia

Cada video musical del *dataset* contiene los campos mostrados en la tabla 2.3. Dentro de estos campos se destaca las propiedades de *energy* (*arousal*) y *valence*, las cuales fueron usadas para determinar la emoción asociada a cada uno de los contenidos.

Tabla 2.3 Características musicales para cada video, archivo JSON, fuente: propia

CARACTERÍSTICA	VALOR	COLOR
<i>id</i>	1	
<i>liveness</i>	0.094833	
<i>energy</i>	0.717726	
<i>tempo</i>	129.882	
<i>speechiness</i>	0.106457	
<i>currency</i>	0.22104064240294416	
<i>instrumentalness</i>	0.338526	
<i>duration</i>	313.94844	
<i>view_count</i>	822693136	
<i>mood</i>	Excited	
<i>artist</i>	Major Lazer	
<i>url</i>	http://www.youtube.com/watch?v=YqeW9_5kURI	
<i>title</i>	Lean On	
<i>acousticness</i>	0.033117	
<i>danceability</i>	0.862321	
<i>time_signature</i>	4	
<i>loudness</i>	-5.691	
<i>valence</i>	0.421374	
<i>mode</i>	0	

## 2.7 Evaluación del *dataset* de contenidos

Con el propósito de evaluar el *dataset* de contenidos multimedia de video, se diseñó e implemento un servicio de VoD basado en emociones, este presenta un listado de contenidos multimedia de video clasificados por emoción. En la figura 2.14 es presentada la arquitectura básica del servicio de VoD basado en emociones, la cual está formada por los siguientes módulos funcionales: proveedor de contenido multimedia, proveedor del servicio, proveedor de red y consumidor de contenido.

El proveedor de contenido multimedia es el módulo encargado de proporcionar los contenidos de videos al servicio de VoD, a través del servidor Apache vía protocolo HTTP; es allí donde son alojados los contenidos multimedia asociados al *dataset* presentado en la sección 2.6. El proveedor del servicio, es el módulo gestor del servicio de VoD, este permite que el usuario pueda consumir los contenidos de video a través de la web; para ello se hace uso de tecnologías del lado del servidor como: PHP y el gestor base de datos MySQL, encargados de la gestión y almacenamiento de información de usuarios y el *dataset*. El módulo proveedor de red es el encargado de brindar soporte de red (acceso a internet) al usuario, para la distribución del contenido multimedia. Finalmente, el módulo consumidor o cliente se hizo uso de tecnologías como: HTML5, JavaScript y el framework Bootstrap para el diseño, lógica de la interfaz y la reproducción del contenido. Para el consumo del servicio es requerido un navegador con soporte para JavaScript y HTML5, ejemplo: Google Chrome, Firefox, Opera, entre otros.



Figura 2.14 Arquitectura para el despliegue del servicio de VoD, fuente: propia

En la figura 2.15 es presentada la interfaz web del servicio de VoD basado en emociones. Esta se encuentra formada por cuatro componentes principales: En (“1”) es mostrado un conjunto de botones que representan las cinco emociones de entrada, los cuales permiten al usuario seleccionar manualmente el tipo de contenidos musicales que desea visualizar. En (“2”) una vez el usuario escoge la emoción de entrada, es presentado un conjunto de contenidos previamente clasificados en el *dataset* de videos musicales, según el modelo de clasificación de emociones presentado en la sección 2.6.1. A partir del catálogo presentado, el usuario puede escoger el contenido a visualizar, mediante el componente de reproducción en (“3”). Finalmente, en (“4”) asociado al componente de reproducción existe un panel de

control de reproducción y el cual permite: pausar o iniciar, detener, cambiar de video (posterior o anterior video del listado), controlar el volumen y la resolución del video.



Figura 2.15 Interfaz de usuario del servicio de VoD, fuente: propia



## Capítulo 3

# Método Computacional para la inferencia

### 3.1 Introducción

En el siguiente capítulo, es mostrado al lector el desarrollo de la temática relacionada con las medidas fisiológicas en el ser humano y como pueden ser utilizadas dichas variables en miras a que permitan caracterizar el contexto de usuario. También es plasmado el diseño del módulo hardware-software encargado de la captura de variables fisiológicas en el usuario, para efectos del trabajo se consideraron variables como: la variabilidad de la frecuencia cardíaca, respuesta galvánica de la piel y señales electromiográficas, las cuales ayudan a determinar el estado de ánimo. Además, es presentado el desarrollo del método computacional para la inferencia del estado de ánimo y la matemática relacionada con este proceso, con base a que permita la clasificación de los contenidos.

### 3.2 Sistema de medidas fisiológicas

El sistema nervioso autónomo (SNA) es un sistema involuntario, el cual se encarga de controlar los sistemas viscerales del organismo humano, su función global consiste en mantener la situación de homeostasis del organismo y efectuar las respuestas de adaptación ante cambios del medioambiente externo e interno [49]. El SNA está integrado por el sistema simpático, parasimpático y entérico. Esta actividad autonómica es vista como un componente importante de la respuesta de la emoción [50]. Estas son analizadas haciendo uso de las medidas fisiológicas.

El objetivo de la fisiología humana es brindar una explicación acerca de las características y mecanismos específicos del cuerpo humano, y los cuales hacen que sea un ser vivo. El hecho de mantenerse vivo es el resultado de sistemas de control complejos, que regulan actividades como la respiración, la circulación, los sentidos, el metabolismo, la temperatura, entre otros [51]. Dichas actividades son controladas directamente por el SNA, las cuales constituyen las variables o señales fisiológicas, estas pueden ser medidas y monitorizadas con ayuda de distintos tipos de sensores. En la figura 3.1 es presentado el sistema de medidas fisiológicas considerado en el presente trabajo de grado, encargado de la captura y análisis de las variables del contexto de usuario.

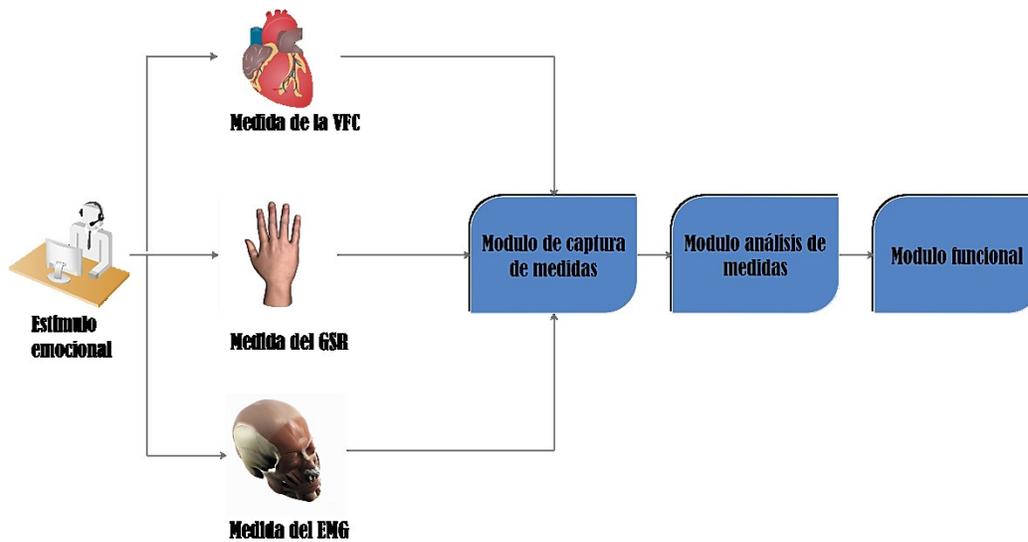


Figura 3.1 Sistema de medidas fisiológicas, fuente: propia

En la figura 3.1 el lector puede observar los módulos que componen el sistema de medidas fisiológicas de una manera general, en primera instancia, estas son obtenidas por medio de alguna plataforma hardware la cual permite censar las medidas. Una vez capturadas, se procede al análisis dependiendo de la información a obtener de cada variable fisiológica. Posteriormente, el módulo funcional recibe los datos de los módulos de análisis y este se encarga de procesar la información para el propósito de inferir las emociones en el usuario.

### 3.3 Variables del contexto de usuario

Como es mencionado en el primer capítulo, las variables del contexto de usuario son información que puede ser utilizada para caracterizar el estado de una entidad, esta puede ser una persona, lugar u objeto relevante para la interacción entre el usuario y la aplicación. En el caso del servicio de video bajo demanda se distinguen cuatro dimensiones del contexto a saber cómo es mostrado en la figura 3.2.

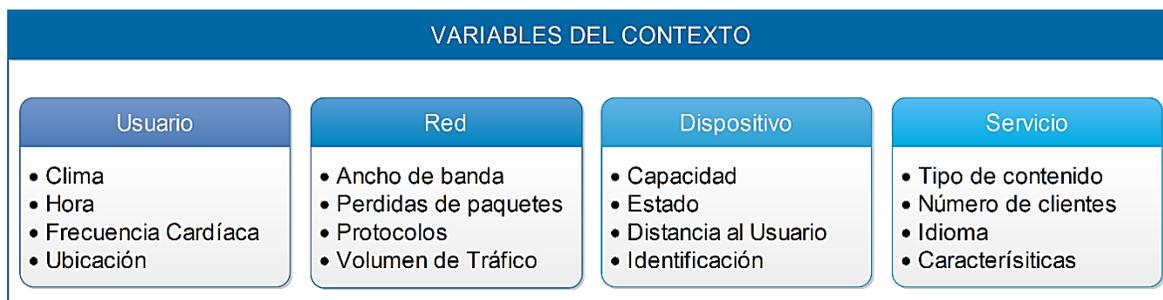


Figura 3.2 Variables del contexto, fuente: propia

Por ser este demasiado amplio y para cuestiones de desarrollo del trabajo de grado, se ha decidido trabajar con el contexto de usuario, principalmente con las variables fisiológicas de: frecuencia cardíaca, respuesta galvánica de la piel y la medida electromiográfica, las cuales permiten hacer frente al problema de arranque en frío.

### 3.3.1 Variabilidad de la frecuencia cardíaca

Uno de los métodos no invasivos más utilizados en el análisis y valoración de la actividad cardíaca, es la frecuencia cardíaca (FC). Los latidos en el corazón se producen con una frecuencia variable, es decir que el tiempo entre dos latidos va variando entre uno y otro [52]. Entonces la variación de la frecuencia cardíaca (VFC) es el cambio en frecuencia del latido cardíaco durante un intervalo de tiempo. Una manera habitual de medir esta variabilidad es por medio del electrocardiograma donde son detectadas cada una de las ondas R como se aprecia en la figura 3.3.

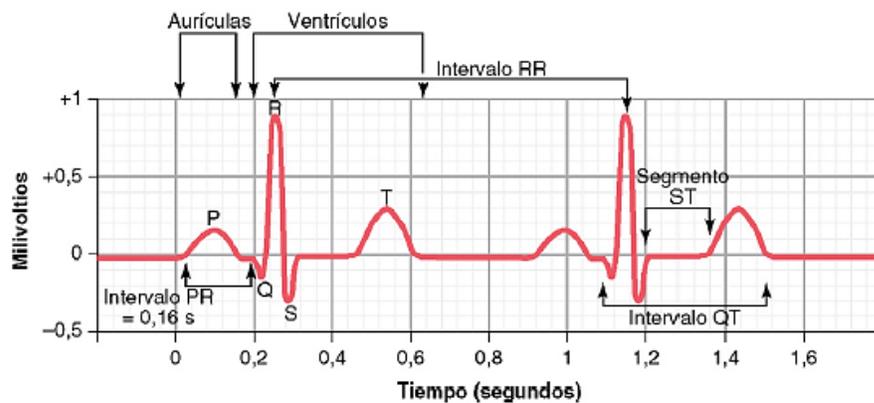


Figura 3.3 Variabilidad de la frecuencia cardíaca, tomado de [51]

Al momento de detectar cada onda R, es calculado el tiempo entre las distintas ondas consecutivas o intervalos RR. Este intervalo RR es el encargado de medir el periodo cardíaco y a la serie de intervalos RR es lo que se conoce como VFC.

### 3.3.2 Parámetros de medición de la VFC

Hay distintas medidas para el análisis de la VFC, como son: en el dominio del tiempo, frecuencia y a través de métodos geométricos. Para el desarrollo del proyecto se han escogido para el análisis del índice de estrés los métodos geométricos y en el dominio del tiempo, de los cuales el lector podrá observar su fórmula matemática y una breve explicación a continuación.

### 3.3.2.1 Métodos en el dominio del tiempo

Las medidas en el dominio del tiempo son las más simple de realizar, estas cuantifican la cantidad de variación en el intervalo entre latidos (IBI) utilizando medidas estadísticas, algunas de estas, y con las cuales se ha trabajado son: la RMSSD, pNN50, la mRR y la SDNN [53].

#### 3.3.2.1.1 RMSSD

Se refiere a la raíz cuadrada del valor medio de la suma de las diferencias al cuadrado de todos los intervalos RR sucesivos, también se le conoce como valor efectivo o RMS. La interpretación fisiológica de esta es: medir la actividad de la cadena parasimpática en la regulación de la actividad cardíaca vagal, las unidades van en milisegundos (ms) [54], ver ecuación 3.1:

$$RMSSD = \sqrt{\text{media} \left[ \left[ \begin{matrix} RR \\ i+1 \end{matrix} - \begin{matrix} RR \\ i \end{matrix} \right]^2 \right]}$$

*Ecuación 3.1 Formula para calcular RMSSD*

#### 3.3.2.1.2 pNN50

Porcentaje de los intervalos RR consecutivos que discrepan en más de 50 ms entre sí. Una interpretación fisiológica de esta medida es el índice de nivel de prevalencia de regulación del sistema parasimpática sobre el simpático (valor relativo) [54], ver ecuación 3.2:

$$pNN50 = \frac{\left[ \left| \begin{matrix} RR \\ i+1 \end{matrix} - \begin{matrix} RR \\ i \end{matrix} \right| \right] * 100}{N - 1}$$

*Ecuación 3.2 Formula para calcular pNN50*

#### 3.3.2.1.3 mRR

Esta medida hace referencia a la media de los intervalos RR, es decir el promedio del conjunto de intervalos RR capturados [54], ver ecuación 3.3:

$$mRR = \frac{(\sum_{i=1}^N RR_i)}{N}$$

*Ecuación 3.3 Formula para calcular mRR*

3.3.2.1.4 SDNN

Es la desviación estándar de los intervalos RR, cuantifica la variabilidad global o nivel de dispersión del conjunto de medidas RR [54], ver ecuación 3.4:

$$SDNN = \sqrt{\frac{\sum_{i=1}^N (RRi - mRR)^2}{N - 1}}$$

Ecuación 3.4 Formula para calcular SDNN

3.3.2.2 Medida del nivel de estrés mental

Al igual que ocurre con la emoción, no hay un común acuerdo para definir el estrés mental, pero una de las definiciones más comunes es: “El estrés puede ser interpretado como una amenaza a la integridad psicológica de un individuo que da lugar a respuestas fisiológicas y/o de comportamiento”, [55]. Para el análisis del estrés mental es posible utilizar las medidas estadísticas de RMSDD, pNN50 y la ecuación del índice de estrés propuesto por Bayevsky. A continuación, son descritas las medidas tenidas en cuenta para el cálculo y análisis del nivel de estrés mental del usuario.

3.3.2.2.1 RMSSD y pNN50

Se ha encontrado según la literatura relación entre las medidas estadísticas en función del tiempo como lo son la RMSDD y pNN50, con el estrés mental en las personas. Como se vio en la sección 3.3.2.1, la primera corresponde al valor medio de la suma de las diferencias al cuadrado de todos los intervalos RR sucesivos y la última es el porcentaje de los intervalos RR consecutivos que discrepan en más de 50 ms entre sí.

Una manera de saber cuándo el usuario comienza aumentar su nivel de estrés mental, es observando cuando las métricas presentan un valor bajo de RMSSD y pNN50, en cambio si el usuario comienza a relajarse o a disminuir su nivel de estrés mental dichas métricas se caracterizan por presentar valores altos, (ver tabla 3.1).

Tabla 3.1 Medidas estadísticas y nivel de estrés, fuente: propia

MEDIDA ESTADÍSTICA	NIVEL DE ESTRÉS
RMSSD ↓	↑
RMSSD ↑	↓
pNN50 ↓	↑
pNN50 ↑	↓

## 3.3.2.2.2 Índice de estrés

Este algoritmo surge a lo largo del trabajo desarrollado por la unión soviética en el análisis de la HRV (heart rate variability) para la medicina espacial. Este algoritmo se basa en métodos geométricos haciendo uso de la curva de distribución cardio-histograma dibujada a partir del estudio de las variaciones del pulso o ritmo cardíaco. Esta identifica características como:  $Mo$  (moda),  $AMo$  (Amplitud de la moda),  $M*DMn$  (rango de variación o varianza [54]) (ver ecuación 3.5).

$$SI = \frac{AMo}{2Mo * (M * DMn)}$$

Ecuación 3.5 Formula Índice de estrés

Dónde:

$Mo$ : Moda o el nivel presumible donde se encuentra trabajando el sistema cardiovascular. En una vista un poco más matemática, hace referencia al valor de RR que presenta el usuario con mayor regularidad en el conjunto de medidas analizado.

$AMo$ : Amplitud de la moda, en términos fisiológicos, es el índice nominal de actividad de la cadena de regulación simpática. En términos matemáticos se refiere al porcentaje o porción de los intervalos que corresponden con el valor de la moda en la muestra tomada.

$M*DMn$ : El rango de varianza, es la diferencia entre los valores máximos y mínimos de los cardio-intervalos, es mejor conocido como varianza.

$SI$ : índice de estrés, o índice del sistema de regulación de tensión. Es el nivel de tensión de los sistemas de regulación (nivel de prevalencia de la actividad de regulación central por encima de los mecanismos autonómicos). En la tabla 3.2, el lector podrá observar los rangos de índice de estrés que el usuario puede presentar, estos se encuentran asociados a tres estados anímicos, los cuales son: estresado, relajado y normal.

Tabla 3.2 Rangos SI asociados a cada estado, fuente: propia

RANGO DE SI	ESTADO ASOCIADO	NIVEL DE AROUSAL
>150	estresado	>0.5
≥40 y ≤150	normal	≥0.14 y ≤0.5
<40	relajado	<0.14

A partir de lo anterior, es posible concluir que el índice de estrés permite asociarse a tres estados emocional como es mostrado en la tabla 3.2. Estos determinan los rangos del nivel de *arousal*, los cuales son fundamentales en el sistema de recomendaciones, ya que, por

medio de estos niveles junto con la *valence*, se identifican los contenidos que responden al estado de ánimo asociado como se verá más adelante en el cuarto capítulo.

### 3.4 Medida de respuesta galvánica de la piel (RGP o GSR)

Se sabe que en la piel los humanos cuentan con una serie de glándulas sudoríparas, las cuales se encargan principalmente de la regulación térmica del cuerpo. Esta es controlada por el sistema nervioso autónomo a través de distintas hormonas, y fibras nerviosas (ver figura 3.4) [51].

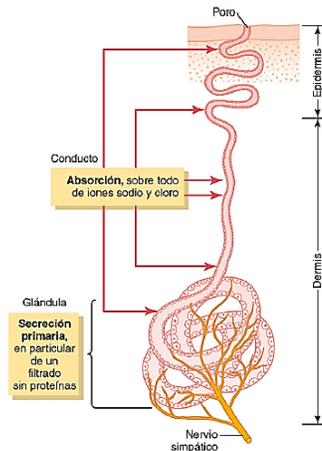


Figura 3.4 Glándula sudorípara, tomado de [51]

Según los estudios presentados en [56], se concluyó que cuando un individuo está bajo estrés mental, la actividad de las glándulas sudoríparas comienza a aumentar permitiendo la secreción de sudor, logrando de esta manera incrementar la conductividad de la piel. Las zonas con más densidad de glándulas sudoríparas son las manos y los pies. En la figura 3.5 es posible observar un ejemplo del aumento en la respuesta galvánica.

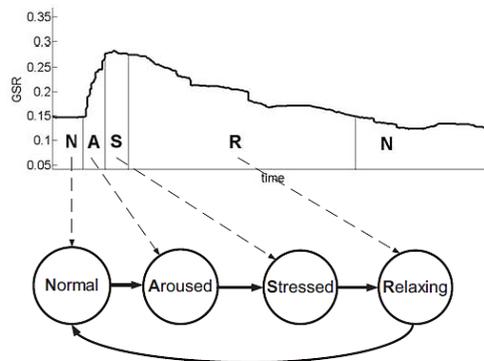


Figura 3.5 Gráfico señal RGP, tomado de [57]

Así, en la figura 3.5 se observa cómo en un principio es obtenida la señal base o normal de la persona, y a medida que es sometido al estrés mental, comienza la activación de las glándulas sudoríparas, las cuales ocasionan un aumento de la activación o *arousal* de la persona hasta llegar a un pico de estrés. Una vez la persona entre en una etapa de relajación, se observa como la conductividad poco a poco comienza a estabilizar hasta llegar a la línea base o normal del usuario.

Como conclusión cabe resaltar que la medida de la conductancia trabaja como soporte a la VFC y la EMG. El RGP determinará si el usuario comienza aumentar su nivel de estrés, o por el contrario, a relajarse. De acuerdo a esto es establecido el orden del contenido teniendo en cuenta su nivel de *arousal*. Este es desplegado a través de una lista como recomendaciones al usuario, en el servicio de video bajo demanda.

### 3.4.1 Regresión Lineal y pendiente

Para el presente proyecto, la medida del RGP se va implementar como indicador del aumento o disminución del nivel de estrés en el usuario. Como las medidas tomadas pueden variar dentro de determinados rangos, dependiendo si la persona esta estresada o se mantiene relajada. Se ha hecho uso de la regresión lineal, la cual realiza una aproximación con los datos y así poder observar si la función que describe los valores capturados, es creciente o decreciente, obteniendo el valor de su pendiente (ver figura 3.6). Dependiendo, si esta es negativa, significará que la función está decreciendo en el intervalo analizado, por el contrario, esta fuere positiva, se concluirá como la función asociada está creciendo en el intervalo o aumentando en el nivel de estrés. La función utilizada para la aplicación de la regresión lineal en el desarrollo fue "linalg.lstsq" de la librería numpy para Python (ver figura 3.7), la cual después de establecer las variables dependiente e independiente, retornara la pendiente de la recta y el corte en el eje (y) para su posterior análisis.

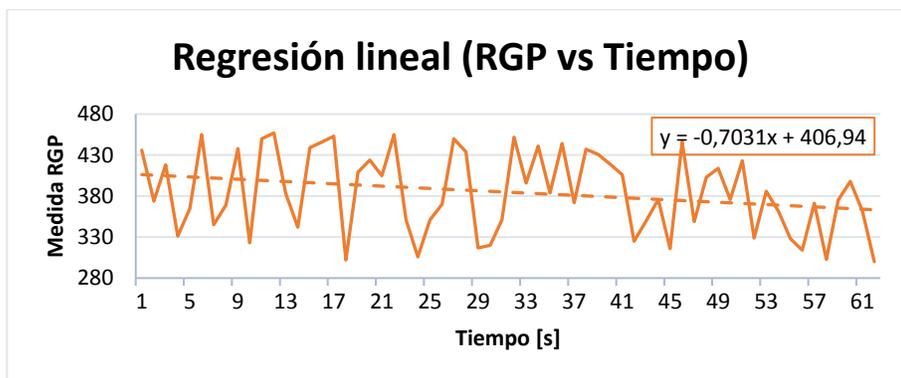


Figura 3.6 Gráfico regresión lineal a conjunto de datos, fuente: propia

```
def get_valor_estimulo(self, lista_gsr):  
    n = len(lista_gsr)  
    lista_x = list(range(1,n+1))  
    x = numpy.array(lista_x)  
    y = numpy.array(lista_gsr)  
    A = numpy.vstack([x, numpy.ones(len(x))]).T  
    p, c = numpy.linalg.lstsq(A, y)[0]  
    print "pendiente->",p," -- corte->",c  
    return p
```

Figura 3.7 Método para cálculo de regresión lineal, fuente: propia

### 3.5 Medida electromiográfica de superficie

La electromiografía es una técnica la cual permite conocer de forma aproximada el funcionamiento neuromuscular de un individuo. Esta proporciona información acerca de la actividad eléctrica muscular. Antes de producir la fuerza, pequeñas corrientes eléctricas son generadas por las fibras musculares, esto hace parte del proceso de señalización, para que dichas fibras se contraigan [58]. La señal conocida comúnmente como electromiograma es medida mediante la aplicación de elementos conductores o electrodos a la superficie de la piel, y también haciendo uso de técnicas invasivas con el uso de agujas, de manera intramuscular, (ver figura 3.8).

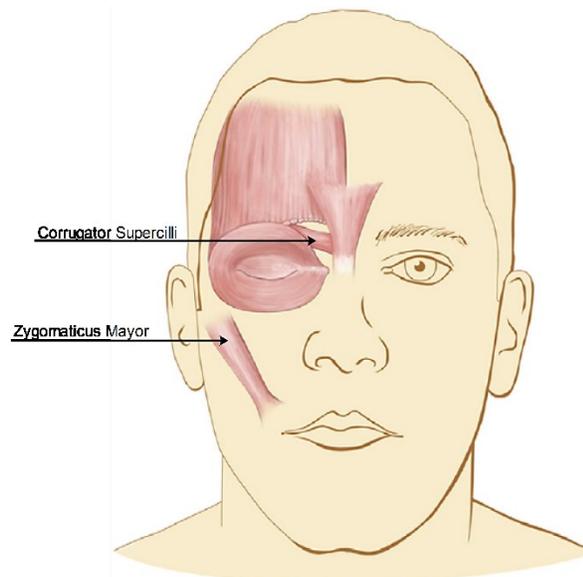


Figura 3.8 Músculos faciales, tomado de [59]

El electromiograma es comúnmente utilizado en deportistas para la medida del grado de actividad de los músculos. Pero estudios realizados han demostrado como es posible mediante ésta, inferir la emoción presente en una persona, para ello la zona del cuerpo que

debe ser analizada con ayuda de los electrodos, es la cara [60]. Para motivo del desarrollo de este proyecto se realizó la captura de la señal eléctrica de solo 2 de los músculos faciales, los cuales según la literatura se activan cuando sobre el usuario surge una emoción positiva o por el contrario una con *valence* negativa. Los músculos faciales en los cuales se enfoca la captura de la señal son el *corrugator supercilli* y el *zygomaticus mayor*, el primero es activado por lo general cuando el usuario realiza expresiones provocadas por emociones negativas como fruncir el ceño cuando se está enojado. En cambio, el segundo es asociado a emociones positivas como la felicidad, ya que su activación ocurre cuando la persona presenta el reflejo muscular de sonreír [59].

### 3.5.1 Cálculo de la *valence*

Para el análisis de las dos señales, es preciso aplicar al igual que como se hizo con la medida de la RGP, la regresión lineal de manera que permita saber cuál de los músculos escogidos para el análisis, presenta una mayor actividad. Así, el músculo con un valor mayor de pendiente, dictara la polaridad de la emoción, es decir de la *valence*. En la figura 3.9 es posible observar el gráfico de la captura de las señales EMG para cada uno de los músculos estudiados.

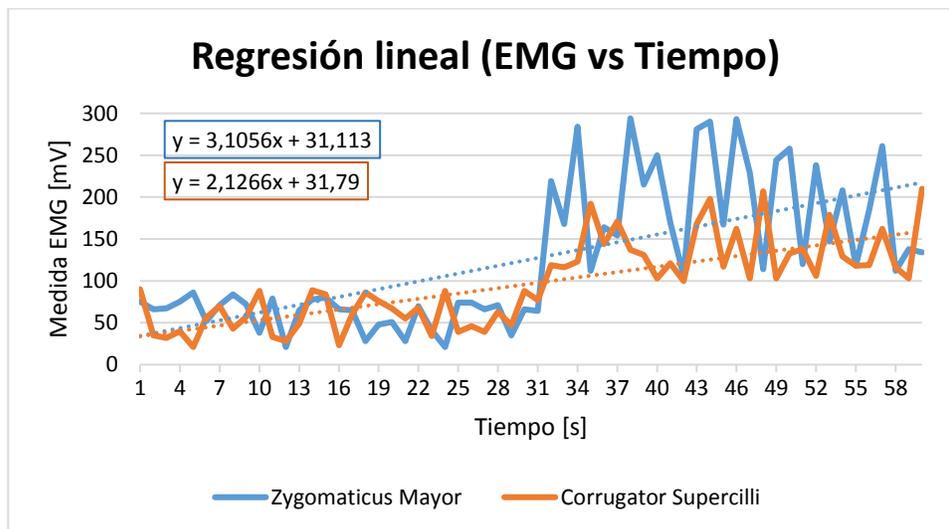


Figura 3.9 Regresión lineal para la EMG, fuente: propia

Para el cálculo de la *valence*, se realiza la medida de la señal de EMG en los músculos por 60 segundos, una vez obtenidos los valores se hace uso de la regresión lineal para obtener un aproximado de la tendencia que describe la función asociada a las medidas. En la figura 3.9 se puede apreciar como las medidas tomadas del músculo *zygomaticus mayor*, el cual es asociado a una *valence* positiva, presenta una mayor pendiente con relación al *corrugator supercilli*, el cual dicta la prevalencia de una *valence* negativa; significando como dicho

músculo presenta una mayor actividad. Por lo tanto, se concluye que la emoción asociada al usuario se encuentre en la mitad derecha del modelo de 5 emociones diseñado. Para el establecimiento del valor de entrada de *valence* en el usuario, se obtiene la media de los valores y es aplicada la ecuación 3.6 dependiendo del músculo que se active aún más.

$$Valence_{Corrugator} = \left( \frac{media}{2 * 300} \right) \quad (a)$$

$$Valence_{Zygomaticus} = 0.5 + \left( \frac{media}{2 * 300} \right) \quad (b)$$

Ecuación 3.6 Formulas cálculo de valence

Teniendo en cuenta las ecuaciones 3.6a) y 3.6b), los valores de *valence* para el músculo *corrugator* oscilarían en un rango de [0, 0.5] y al músculo *zygomaticus* entre [0.5, 1]; esto teniendo en cuenta que, al módulo clasificador del sistema de recomendaciones, son enviados los valores de *valence* y *arousal* sin normalizar, en un rango entre [0,1].

## 3.6 Equipos para medidas fisiológicas

En la actualidad existen un gran número de dispositivos que permiten la captura de las variables fisiológicas, estos se han venido utilizando en su mayor parte por deportistas y grupos científicos en los últimos años. A estos equipos de medición se les conoce comúnmente como *wearables*<sup>14</sup>, los cuales son dispositivos electrónicos incorporados en el espacio personal, estos se caracterizan porque permiten la multitarea, tiene la capacidad de comunicarse con otros *wearables* y conectarse a internet. Esto les permite formar parte de internet de las cosas en donde cualquier equipo puede ser ubicado en la red. Algunos de los dispositivos utilizados para la medición de las variables fisiológicas como la VFC, RGP y EMG son mostrados en este numeral.

### 3.6.1 Sensor de pulso cardíaco para arduino

El sensor de pulso cardíaco (pulse sensor<sup>15</sup>) para frecuencia cardíaca *plug-and-play* diseñado para Arduino. Puede ser utilizado por estudiantes, artistas, deportistas, fabricantes y desarrolladores de juegos y móviles que quieran incorporar fácilmente los datos de frecuencia cardíaca en vivo en sus proyectos (ver figura 3.9).

<sup>14</sup> Dispositivo electrónico incorporado en el espacio personal, el cual permite obtener y procesar información asociada al usuario, como la toma de señales biomédicas y su procesamiento en la nube. <http://wearablespain.com/Wearable.html>.

<sup>15</sup> Pulse sensor arduino usado para la medida de la VFC, página web fabricante: <http://pulsesensor.com/>.

Figura 3.9 (a)



Figura 3.9 (b)

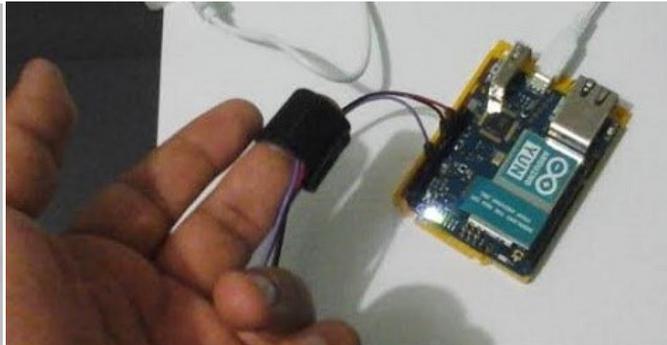


Figura 3.9 Dispositivo sensor de pulso cardíaco-arduino, fuente: propia

En la figura 3.9a) se observa el sensor y sus componentes necesarios para la medición, el cual se puede utilizar en los dedos o lóbulo de la oreja. En la figura 3.9b) es mostrado el sensor conectado al dedo del usuario, extremidad en la cual se está haciendo la medición de la frecuencia cardíaca. El sensor está conectado a la tarjeta Arduino, en donde es generado el código para el procesamiento de la señal de (FC).

### 3.6.2 Cinturon Zephyr HxM BT

Zephyr<sup>16</sup> es una banda para el pecho, el cual cuenta con sensor de frecuencia cardíaca (ver figura 3.10). Este además de medir el ritmo cardíaco de la persona por medio de electrodos presente en el cinturón, toma muestras de los intervalos RR, velocidad a la que va la persona y distancia recorrida. Además, el dispositivo posee una batería la cual es cargada vía USB.

Figura 3.10 (a)



Figura 3.10 (b)



Figura 3.10 Dispositivo sensor zephyr, fuente: propia

El sensor se comunica vía bluetooth con el dispositivo móvil y cuenta con aplicaciones para Android, Windows phone y PC. Esta herramienta cuenta un paquete SDK con recursos para

<sup>16</sup> Cinturón zephyr utilizado para la medida de la VFC, página web fabricante: <http://zephyranywherestore.com/>.

desarrolladores. En la figura 3.10a) es presentado el dispositivo con sus componentes y en la figura 3.10b) se muestra un ejemplo de cómo debe ir conectado correctamente el dispositivo en el usuario.

### 3.6.3 Cinturón Polar

El sensor de polar<sup>17</sup> es compatible con los dispositivos bluetooth (ver figura 3.11), se requiere una aplicación separada para ver los datos de frecuencia cardíaca, para uso en smartphones, recomiendan utilizar la APP Polar beat, la cual sincroniza los datos tomados con la cuenta *polar personal trainer* del usuario.

Figura 3.11 (a)



Figura 3.11 (b)



Figura 3.11 Dispositivo sensor polar, fuente: propia

Este sensor cuenta con una banda para el pecho con dos electrodos para la captura de las medidas y una pila como alimentación al dispositivo. Polar ofrece a los desarrolladores documentación para google fit, Apple healthkit, y para su app propietaria accesslink, para lo cual hay que registrarse y realizar una solicitud a Polar, una vez lo contacten se le pedirá firme un contrato de cuenta de desarrollador. En la figura 3.11a) es mostrado el dispositivo y componentes; y en la figura 3.11b) se puede ver su modo de uso.

### 3.6.4 Sensor Grove

El sensor grove<sup>18</sup> RGP para Arduino es un equipo, el cual permite la medición de la conductancia eléctrica de la piel a través de dos electrodos conductuales (ver figura 3.12). Los cuales se activan de acuerdo al nivel de sudoración que una persona presente en sus manos.

<sup>17</sup> Sensor polar para medida de la VFC, página web fabricante: [http://polar.com/en/products/accessories/H7\\_heart\\_rate\\_sensor](http://polar.com/en/products/accessories/H7_heart_rate_sensor).

<sup>18</sup> Grove sensor para la medida de la RGP, página web fabricante: <http://seedstudio.com/depot/Grove-GSR-sensor-p-1614.html>.

Figura 3.12 (a)



Figura 3.12 (b)



Figura 3.12 Dispositivo sensor Grove para la RGP, fuente: propia

En la figura 3.12a) se observa el dispositivo sensor RGP y sus componentes, tarjeta de conexión y cables, además de los electrodos. En la figura 3.12b) es presentado un ejemplo de conexión del sensor RGP en los dedos índice y corazón de la mano.

### 3.6.5 Sensor EMG

Este sensor conocido como MyoWare<sup>19</sup> cuenta con 3 electrodos eléctrico-musculares, los cuales permiten la toma de la EMG (ver figura 3.13), la placa con los dos electrodos es colocada preferiblemente, en medio del músculo y en dirección a éste, en cambio el de referencia, en una parte ósea o muscular no adyacente del cuerpo cerca del músculo a analizar. Además, este sensor es utilizado en aplicaciones con temáticas como: video juegos, robótica, equipos médicos, *wearables* y en prótesis u ortopedia.

Figura 3.13 (a)

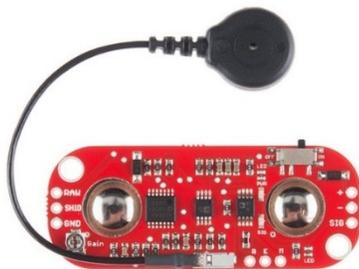


Figura 3.13 (b)



Figura 3.13 Dispositivo sensor MyoWare para la EMG, fuente: propia

<sup>19</sup> Sensor MyoWare para la medida de la EMG, página web fabricante: <http://advancertechnologies.com>.

### 3.6.6 Arduino Yún

Es una placa electrónica de hardware libre, útil en proyectos de internet de las cosas, combina el potencial de Linux con la facilidad de uso de Arduino. Cuenta con interfaz Ethernet y wifi, puerto USB, ranura para tarjeta micro-SD, 20 pines digitales entrada/salida de los cuales 7 se pueden usar como salidas PWM y 12 como entradas analógicas (ver figura 3.14). La Yún<sup>20</sup> se distingue de otras placas Arduino en que se puede comunicar con la distribución de Linux a bordo, que ofrece un ordenador en red de gran alcance con la facilidad de Arduino. Además de los comandos de Linux como cURL, puede escribir sus propios scripts de shell y Python para las interacciones fuertes, además de permite implementar servicios web.



Figura 3.14 Tarjeta hardware Arduino Yún, fuente: propia

A modo de conclusión y para el desarrollo de este proyecto, se decidió trabajar con hardware libre, por tal razón se ha hecho uso de la tarjeta Arduino Yún la cual ofrece una serie de ventajas como: permitir el uso de varios sensores, es útil para la implementación de servicios web y la facilidad para generar desarrollos de alto nivel con Arduino.

## 3.7 Diseño sistema hardware-software

El diseño del sistema hardware-software para el proyecto está compuesto de los bloques funcionales que se pueden observar en la figura 3.15. Primero son obtenidas las medidas fisiológicas de la VFC, RGP y EMG del usuario por medio del módulo de captura, en el cual se encuentran, el sensor de pulso cardíaco, sensor Grove y sensor MyoWare; además, de la tarjeta Arduino Yún. Una vez obtenidas las medidas se procede a realizar el cálculo del

---

<sup>20</sup> Placa electrónica de hardware libre Arduino Yún, página web fabricante: <https://arduino.cc/en/Main/ArduinoBoardYun>.

índice de estrés y las medidas estadísticas en el tiempo para la VFC, las cuales permiten hallar el nivel de *arousal* de entrada del usuario en el módulo de análisis de la VFC, aquí es asociado cada nivel de *arousal* a los estados de ánimo vistos en la tabla 3.1 y 2.1 respectivamente. Además, es establecido el *arousal* para los contenidos, y con el cual se deberá solicitar el módulo de lógica. Lo propio es hecho en el módulo de análisis del RGP donde se observa si los valores de conductividad obtenidos muestran la tendencia del usuario al estrés o a la relajación para ello se hace uso de la regresión lineal y por último, el módulo de análisis de la EMG realiza el cálculo de la *valence* de entrada del usuario valor que deberá presentar el contenido a consultar por el siguiente bloque.

Las métricas obtenidas en los módulos de VFC, RGP y EMG son enviadas al módulo de lógica. En este bloque es recibido el contexto del usuario, primero el rango del nivel de *arousal* y *valence* en el que se encuentra la persona, estas permiten hacer la solicitud del catálogo de contenidos al sistema de recomendaciones. Una vez obtenidos, la medida del RGP permite ordenar los videos de acuerdo a su nivel de *arousal*, dependiendo si, el usuario se encuentra en un estado de estrés, o por el contrario comienza a presentar un estado de relajación, presentándose un aumento o disminución del *arousal* en el consumidor.

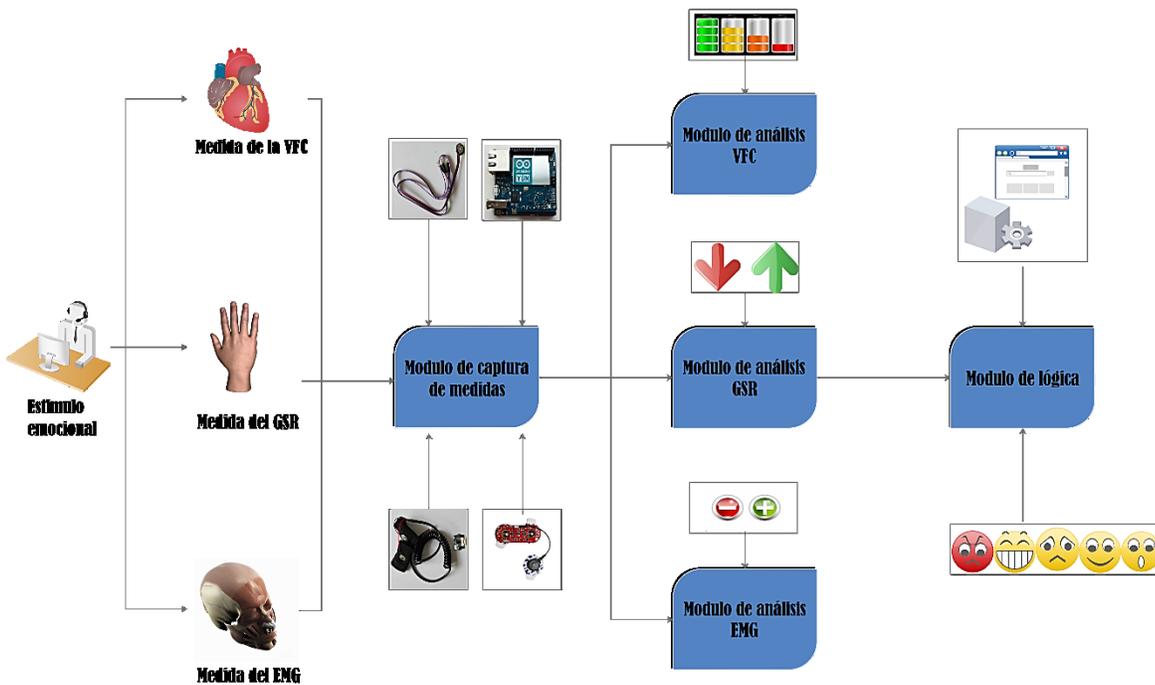


Figura 3.15 Módulos funcionales para las variables fisiológicas, fuente: propia

En la figura 3.16 es mostrada la visualización de las distintas métricas para el análisis de la VFC como son el ritmo cardíaco, los intervalos RR, el promedio del ritmo, el RMSSD, pNN50, mRR, nivel de estrés y el estado asociado. En el proceso de captura de las variables se ha hecho uso de flask para python. Este es un microframework que permite crear aplicaciones

web de forma rápida y con muy pocas líneas de código, flask incluye un servidor web de desarrollo y responde totalmente a peticiones RESTful [61].

Ritmo	81
RR	765
Prom Ritmo	80
rMSSD	12.882091284495269
pNN50	0
mRR	754
mRRi	0.25862068965517243
Nivel Estres	182.98087557080885
Desc Nivel Estres	estresado

Figura 3.16 Medidas de análisis para la VFC, fuente: propia

En la figura 3.17 es posible observar el gráfico de los intervalos RR, tomados durante un minuto en los 3 estados de ánimo dados por la ecuación del índice de estrés, donde se aprecian que en las muestras de los RR normal y RR relajado, los valores fluctúan mucho más en el tiempo, mientras que los RR estresados se caracterizan porque su variación es mínima.

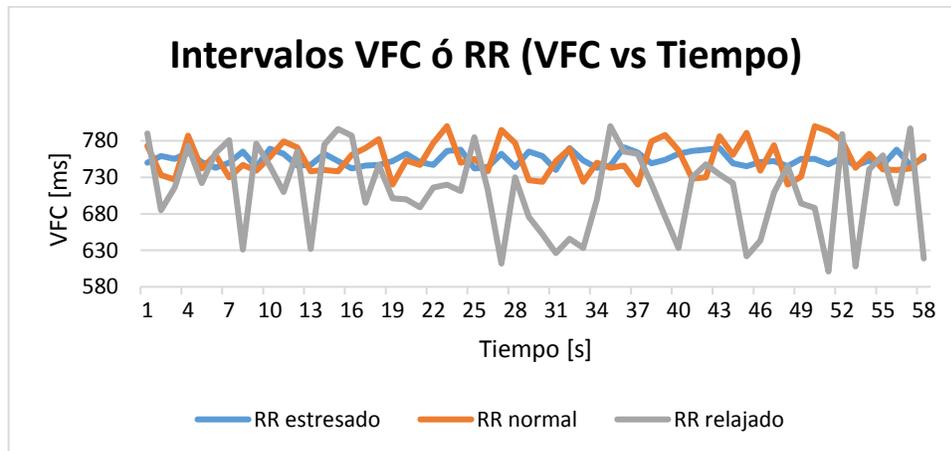


Figura 3.17 Gráfico estados de ánimo asociados a un índice de estrés (SI), fuente: propia

En la figura 3.18 se observa el ejemplo de captura de medidas del dispositivo RGP o GSR, en la cual se obtiene 60 valores cada minuto. Estos son analizados para determinar si las medidas capturadas tienen tendencia a ser crecientes, o por el contrario su aproximación lineal en el intervalo analizado muestra que está decreciendo. La pendiente en la figura al ser positiva, significa que la tendencia más probable de los valores capturados es creciente, lo cual permite intuir si la persona está aumentando su nivel de estrés, y por ende el catalogo recomendado al usuario se debe ordenar por su *arousal* de mayor a menor.

```

* Running on http://127.0.0.1:5000/ (Press CTRL+C to quit)
*****
***** DATOS GSR SENSOR *****
DATOS GSR: 300,318,234,129,290,267,309,376,234,189,340,296,402,378,298,355,389,
312,346,296,304,345,404,306,354,402,397,311,362,189,340,296,402,378,298,355,389,
312,346,296,304,345,404,306,354,402,397,311,362,445,299,392,322,337,340,402,378,
355,389,346
pendiente-> 1.45551542095 -- corte-> 289.506779661
*****

```

Figura 3.18 Medidas capturadas del dispositivo sensor RGP, fuente: propia

En la figura 3.19 es mostrado un ejemplo de captura de la señal EMG, en la cual para establecer el valor de la *valence* presente en el usuario, es necesario determinar cuál de los dos músculos, el *corrugator supercilli*, o por el contrario el *zygomaticus mayor*, presentan una mayor activación o valor en la pendiente, para la función que describe los valores capturados, para este caso se observa como las medidas tomadas por 60 segundos, evidencian una mayor pendiente para los valores capturados en el músculo *corrugator*, presentando una valencia de entrada de 0.256 para la emoción negativa, es decir, el estado de ánimo que presenta el usuario se encuentra ubicado dentro del modelo 5 emociones diseñado en el numeral 2.6.1 en los cuadrantes 2 y 3.

```

* Running on http://127.0.0.1:5000/ (Press CTRL+C to quit)
*****
***** DATOS EMG SENSORRES *****
DATOS SENSOR POSITIVO EMG (zygomaticus mayor): 109,96,280,299,184,210,263,197,9
9,180,91,156,213,86,220,293,109,96,280,299,184,210,263,197,99,180,91,156,213,86,
220,293,123,278,240,184,64,90,81,126,96,280,299,184,210,263,197,99,180,91,156,21
3,86,220,293,123,278,240,184,298
pendiente-> 0.233676021117 -- corte-> 178.339548023

DATOS SENSOR NEGATIVO EMG (corrugator supercilli): 116,225,282,92,38,184,203,24
0,56,120,78,109,227,276,112,83,91,47,130,248,209,116,225,282,92,38,184,203,240,5
6,120,78,109,227,276,112,83,91,47,130,248,209,117,85,46,72,116,225,282,184,203,2
40,56,120,78,109,227,276,248,209
pendiente-> 0.33234231731 -- corte-> 143.613559322

MUSCULO ACTIVO-> corrugator supercilli ,VALENCIA-> 0.25625 ,EMOCION-> negativa
*****

```

Figura 3.19 Medidas capturadas del dispositivo sensor EMG, fuente: propia

### 3.8 Método computacional de inferencia

Teniendo en cuenta lo visto en los numerales 3.3, 3.4 y 3.5, los cuales, proveen la información teórica y matemática para el manejo y análisis de las variables fisiológicas, y que permiten plantar las bases para la construcción del módulo hardware-software presentado en la sección 3.7. En la figura 3.20 es mostrado el diagrama de flujo que modela el método para la inferencia de emociones. Inicialmente son capturadas las variables fisiológicas del usuario a través de los dispositivos *wearables*, luego son llevados a cabo dos procesos con

las medidas obtenidas de cada sensor: Uno de estos consiste en calcular el índice de estrés mental con los datos de la VFC a través del algoritmo propuesto por el científico Soviético Bayevsky, donde se consideran medidas como la moda, amplitud de la moda y la varianza de los intervalos RR, siendo estos el periodo cardíaco entre cada una de las palpitaciones, posteriormente es establecido el valor del *arousal* de acuerdo al cambio que presente SI obtenido mediante el método de regresión lineal con los datos de la RGP. El segundo proceso y paralelo a ello, es calculado el nivel de positividad de la emoción que permite establecer la *valence*, de acuerdo a la estimulación de los músculos faciales (*corrugator supercilli* y el *zygomaticus mayor*) obtenida de la medida EMG. Una vez determinados los valores de *arousal* y *valence*, se procede a inferir la emoción de usuario de acuerdo al modelo de 5 emociones diseñado en la sección 2.6.1.

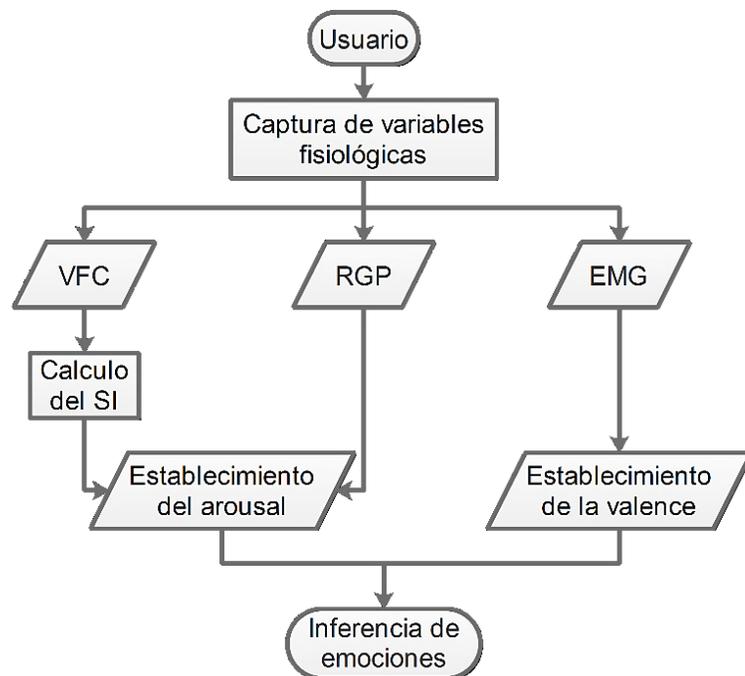


Figura 3.20 Diagrama de flujo del método de inferencia de emociones, fuente:propia

En la figura 3.21 es presentado el método computacional que permitió la inferencia de emociones, y el cual se encarga de asociar las emociones con los contenidos multimedia afectivos.

```

140 @app.route("/calcula_emocion")
141 def calcula_emocion():
142     try:
143         datos_hr=request.args['datos_hr']
144         lista_hr=map(int,datos_hr.split(", "))
145         datos_rr=request.args['datos_rr']
146         lista_rr=map(int,datos_rr.split(", "))
147         datos_emg1=request.args['datos_emg1']
148         lista_emg1=map(int,datos_emg1.split(", "))
149         datos_emg2=request.args['datos_emg2']
150         lista_emg2=map(int,datos_emg2.split(", "))
151         val_pos=obj.get_valor_estimulo(lista_emg1)
152         val_neg=obj.get_valor_estimulo(lista_emg2)
153         if val_pos != val_neg:
154             if val_pos > val_neg:
155                 med=obj.get_media(lista_emg1)
156                 valence=0.5+(med*(1.0))/(2*300)
157             else:
158                 med=obj.get_media(lista_emg2)
159                 valence=(med*(1.0))/(2*300)
160         else:
161             med=obj.get_media(lista_emg1)
162             valence=0.5+(med*(1.0))/(2*300)
163
164         nivel_estres=obj.get_stress_level(lista_rr)
165         desc_nivel_estres=obj.get_stress_level_desc(nivel_estres)
166         arousal=nivel_estres*(1.0)/300
167
168         datos_estado=obj.get_estado_animo(arousal,valence)
169         estadoanimo=datos_estado[1]
170
171         print "*****"
172         print "***** DATOS FINALES *****"
173         print "Nivel de estres es:",nivel_estres
174         print "Desc estres:",desc_nivel_estres
175         print "Arousal:",arousal
176         print "Valence:",valence
177         print "Estado de Animo:",estadoanimo
178         print "*****"

```

Figura 3.21 Método computacional de inferencia, fuente: propia

Así, a modo conclusión, el método computacional permite inferir la emoción del usuario mientras este interactúa con el sistema, durante una etapa de tiempo. Para el diseño del sistema hardware-software se buscaron herramientas libres que ofrecieran una muy buena productividad, como es el uso de la plataforma de Arduino Yún, permitiendo capturar las señales de los sensores, pulso cardíaco, grove y MyoWare, los cuales proporcionan de forma adecuada los datos fisiológicos del usuario, para el cálculo del índice de estrés, el *arousal* y la *valence*. Variables que, al asociarse al modelo de 5 emociones diseñado, posibilitan la identificación de los catálogos de contenido, fundamentales en el sistema de recomendaciones para la sugerencia de videos al usuario. Por otra parte, cabe resaltar la labor que realiza el sensor de RGP, sirviendo como apoyo a las medidas de la VFC y la EMG, encargándose de ordenar los contenidos por su nivel de *arousal*, de acuerdo a si el usuario entra en estado de relajación o bajo *arousal* y estrés o alto *arousal*, permitiendo de esta manera proporcionar al usuario un catálogo de contenidos que se adapte a su estado de ánimo, a medida que interactúa con el servicio de VoD.

## Capítulo 4

# Sistema de Recomendaciones

### 4.1 Introducción

En este capítulo el lector será participe acerca de la temática de los sistemas de recomendaciones (S.R.), los cuales han venido implementándose en muchos de los servicios presentes en la red como: compras en línea, servicios de VoD, buscadores web, hasta servicios de publicidad, entre otros. Como primera parte es realizado un estudio teórico de este teniendo en cuenta sus enfoques clásicos donde son mostrados sus tipos, arquitectura y los problemas con que cuentan. Una vez introducido al lector es presentado el S.R. basado en contexto generado, empezando por el diseño de esté y su clasificador, terminando con la unificación al prototipo del servicio de VoD basado en emociones. En el presente y posteriores capítulos se va a referir a los sistemas de recomendaciones con la abreviatura S.R.

### 4.2 Concepto de S.R.

El aumento del tráfico en las redes y la generación de contenidos que surgen cada vez en mayor cantidad, ha llevado al desarrollo de sistemas los cuales permitan el ágil acceso a estos, siendo una de las soluciones, la implementación de S.R. para los distintos servicios ofrecidos en la web. Estos se encargan de identificar las preferencias de los usuarios y con base en ellas, realizar sugerencias o proporcionar *items* personalizados en la selección, a partir de múltiples opciones (ver figura 4.1) [13].

Los ítems por lo general son desplegados en forma de listas las cuales se encuentran ordenadas de acuerdo a un ranking. Estos juegan un papel importante en sitios reconocidos en la web como son: YouTube, Netflix, Yahoo, Amazon, IMDb, entre otros, los cuales al implementarlo mejoran la experiencia en la interacción del usuario con el servicio. Existen en los S.R. distintos tipos de clasificaciones, estos son divididos principalmente en colaborativos y basados en contenido, aunque también existen divisiones como los basados en conocimiento y los híbridos los cuales mezclan el tipo colaborativo y basados en contenido [8].

A pesar de los beneficios proporcionados por los S.R. existen un conjunto de problemáticas presentes en ellos y las cuales no permiten explotar todo su potencial como son: la escasez de datos para efectuar recomendaciones, inconvenientes para la sugerencia de nuevos

contenidos y el problema a abordar en este trabajo y es el de arranque en frío, el cual surge cuando el sistema está en estados preliminares, es decir, cuando el usuario no ha interactuado con el sistema, por lo cual no existe contenido relevante para ser recomendado al usuario. Estos problemas son muy comunes en el enfoque clásico de los S.R. En la figura 4.1 es mostrada la arquitectura de un S.R., la cual describe el funcionamiento básico de este, en donde la información tomada de los módulos de gestión de los ítems y usuarios, son tomadas por los S.R. para enriquecer o realimentar el perfil del usuario en miras a la recomendación de contenido apropiado a sus gustos.

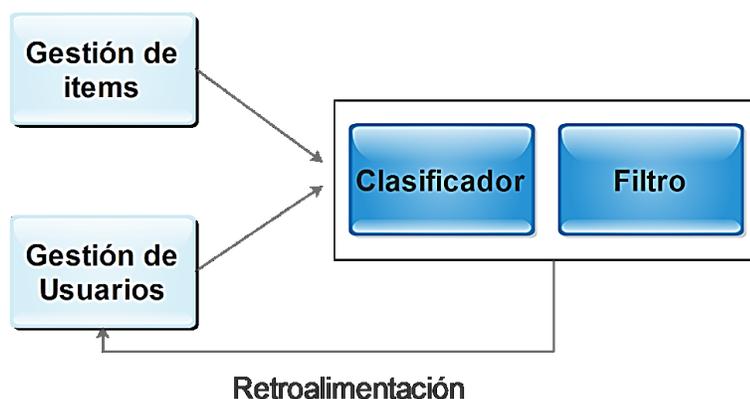


Figura 4.1 Arquitectura básica del S.R., fuente: propia

## 4.3 Enfoque clásico de los S.R.

A continuación, son descritos los enfoques clásicos de los S.R. como son: el enfoque basado en contenido y los colaborativos, métodos muy utilizados y los cuales sirvieron de base para el origen de nuevos enfoques.

### 4.3.1 Enfoque basado en contenido

Los sistemas con este tipo de enfoque, analizan una serie de descripciones de los elementos o contenidos que el usuario ya ha valorado con anterioridad, y de acuerdo a esto construyen un perfil de sus intereses basado en las características del contenido, ver figura 4.2. Este perfil representa de forma estructurada las preferencias de los usuarios, entre mejor se describan los gustos, más eficiente son las sugerencias a proporcionar por parte del sistema. Los S.R. basados en contenido al no tener en cuenta las calificaciones dadas por los demás usuarios para la recomendación, presentan un problema para sugerir nuevos ítems al consumidor. Además, cuando aún no se han valorado suficientes contenidos, este tipo de sistemas presentan el problema de arranque en frío.

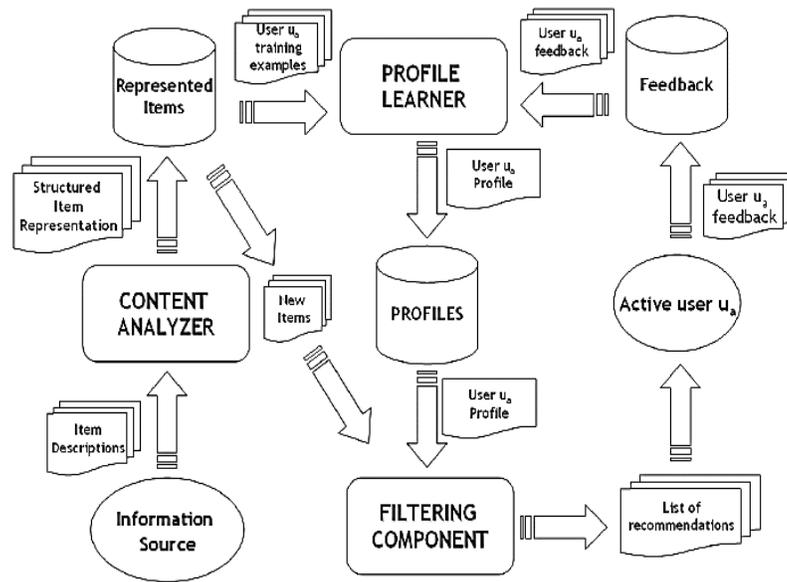


Figura 4.2 Arquitectura de los S.R. basados en contenido, tomado de [13]

Estos sistemas realizan el proceso de recomendación empleando tres pasos, los cuales están a cargo de un componente determinado y pueden ser observados en la figura 4.2. Estos componentes son: analizador de contenidos, perfil del usuario y componente de filtrado.

El analizador de contenidos es el encargado de caracterizar el contenido de los ítems o sugerencias. La información de cada ítem, es analizada por técnicas de extracción de características, estas son utilizadas por el componente de perfil del usuario, el cual se encarga de representar las preferencias del consumidor, con base en las interacciones positivas o negativas resultado de la interacción con el sistema, de esta manera es posible conocer las preferencias del usuario con relación al contenido que se le proporciona. El componente de filtrado es el encargado de realizar la recomendación de ítems teniendo como base el perfil del usuario y para ello proporciona una lista de sugerencias al consumidor.

En la figura 4.3 es presentado el esquema funcional empleado por los S.R. basado en contenidos.

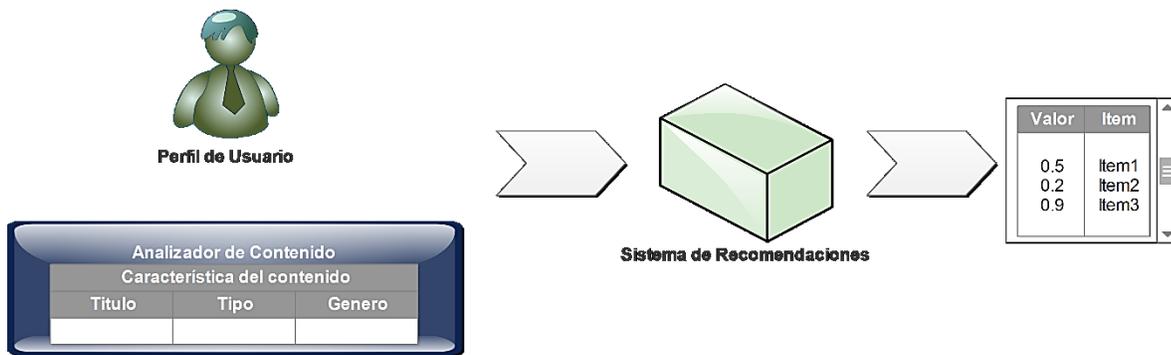


Figura 4.3 Diagrama de secuencia de un S.R. basado en contenido, fuente: propia

Existen múltiples métodos de clasificación y predicción en los S.R., los cuales consideran entornos de contenido multimedia. Pero uno de ellos y el cual es el más utilizado en los S.R. basados en contenido es las aproximaciones de tipo bayesiano, estas hacen uso del teorema de bayes con el objetivo de predecir los contenidos multimedia que pueden ser relevantes al usuario mediante el uso de ponderados probabilísticos.

#### 4.3.1.1 Clasificador Bayesiano

Es un marco probabilístico para resolver problemas de clasificación, basándose en la definición de probabilidad condicional y el teorema de bayes. Los clasificadores bayesianos consideran cada atributo y la etiqueta de clase como variables aleatorias (continuas o discretas). Teniendo en cuenta un registro con  $N$  atributos ( $A_1, A_2, \dots, A_n$ ), el objetivo es predecir la clase  $C_k$ , encontrando el valor de  $C_k$  que maximiza la probabilidad a posteriori de la clase, dados los datos  $P(C_k/A_1, A_2, \dots, A_n)$  [62].

El teorema de bayes dice, sean  $A$  y  $B$  dos sucesos aleatorios cuyas probabilidades son denotadas por  $p(A)$  y  $p(B)$ , siendo  $p(B) > 0$  y suponiendo dichas probabilidades a priori de los sucesos  $A$  y  $B$  son conocidas, así como la probabilidad condicionada del suceso  $B$  dado el suceso  $A$ , es decir  $p(B/A)$ . De acuerdo a lo anterior, es posible establecer de esta manera la probabilidad a posteriori del suceso  $A$  conocido el suceso  $B$ , es decir  $p(A/B)$ , puede calcularse a partir de la siguiente fórmula.

$$p(A|B) = \frac{p(A, B)}{p(B)} = \frac{p(A)p(B|A)}{p(B)} = \frac{p(A)p(B|A)p(B)p(B)}{\sum A' p(A')p(B|A')}$$

Ecuación 4.1 Fórmula de probabilidad condicionada de  $A$  dado  $B$

El clasificador de Naive Bayes busca encontrar la hipótesis más probable. La ecuación 4.2 modela la fórmula de Naive Bayes.

$$V_{nb} = \arg \max_{v_j \in V} P(v_j) \prod P(a_i | v_j)$$

Ecuación 4.2 Formula de Naive Bayes

En la ecuación 4.2,  $V_{nb}$  es cada una de las categorías  $V$  dentro de las cuales es posible clasificar el ejemplo, esta se puede entender como la probabilidad de conocidas las  $n$  características descritas en el ejemplo, estas pertenezcan a la categoría ( $v_j$ ). La probabilidad de  $P(a_i | v_j)$  está definida de forma general como:

$$P(a_i | v_j) = \frac{nc}{n}$$

Ecuación 4.3 Probabilidad condicionada, Naive Bayes

Donde ( $nc$ ) es el número de veces que ocurre la característica ( $a_i$ ) en la categoría ( $v_j$ ), en cambio ( $n$ ) representa el número de casos totales de la categoría ( $v_j$ ). En caso de ( $nc$ ) sea igual a cero es usada la estimación de Laplace, definida en la ecuación 4.4 y en donde ( $k$ ) es el número de valores diferentes a tomar por la característica ( $a_i$ ).

$$P(a_i | v_j) = \frac{nc + 1}{n + k}$$

Ecuación 4.4 Formula para la estimación de Laplace

Un ejemplo del uso del teorema de bayes es plasmado en la tabla 4.1, para este caso el clasificador de Naive Bayes puede ser usado para predecir la posible categoría de un caso  $x$ , a partir de un conjunto de casos ocurridos, en donde es considerado el cálculo de una recomendación para una tienda virtual de películas, donde los usuarios han valorado los contenidos multimedia con calificaciones de 1 a 3.

Tabla 4.1 Ejemplo del teorema de Naive Bayes, fuente: propia

MUESTRA	GÉNERO	AÑO	CALIFICACIÓN
1	Acción	2015	1
2	Drama	2014	2
3	Comedia	2013	2
4	Acción	2016	1
5	Comedia	2013	3
6	Drama	2015	1
7	Acción	2015	2

Se tienen 3 categorías  $V$  con los siguientes elementos los cuales corresponden a la Calificación = {1, 2, 3}. Las películas cuentan con 2 características  $a = \{\text{Genero, Año}\}$ , el ejemplo consiste en hallar la calificación de una película, con las siguientes características:

$$a = \{\text{comedia, 2014}\}$$

Para obtener la predicción de la posible calificación que podría tener la película, es necesario establecer el valor de cada una de las siguientes expresiones o probabilidad condicionales, de las cuales se selecciona la de probabilidad más alta y será la calificación de la película.

- $P(1) * P(\text{Comedia}|1) * P(2014|1)$
- $P(2) * P(\text{Comedia}|2) * P(2014|2)$
- $P(3) * P(\text{Comedia}|3) * P(2014|3)$

Para ilustrar como son obtenidas cada una de las probabilidades, se hará paso a paso para la calificación cuyo valor es uno.

- $P(1) = 3/7$  (la probabilidad de la calificación 1 del experimento, existen 3 calificaciones del total de 7.).
- $P(\text{Comedia}|1) = (nc+1)/(n+k) = (0+1)/(2+3) = (1/5)$  (dado que no existen casos con género sea comedia y la valoración sea 1 se hace uso de la ecuación 4.4)
- $P(2014|1) = (nc+1)/(n+k) = (0+1)/(1+4) = 1/5$  ( $K=4$  porque hay 4 años diferentes en el experimento y  $n=1$  debido a esto solo hay una característica con valor 2014)
- $P(1) * P(\text{Comedia}|1) * P(2014|1) = (3/7) * (1/5) * (1/5) = 3/175$
- $P(2) * P(\text{Comedia}|2) * P(2014|2) = (3/7) * (1/2) * 1 = 3/14$
- $P(3) * P(\text{Comedia}|3) * P(2014|3) = (1/7) * (1/2) * (1/5) = 1/70$

Al obtener todos los cálculos es posible observar como la probabilidad más alta la presenta la expresión  $P(2) * P(\text{Comedia}|2) * P(2014|2)$  con  $3/14$ , esto quiere decir como es probable dada una calificación de una película con genero comedia y año 2014 sea de 2. El método descrito anteriormente es utilizado en el presente trabajo para el diseño e implementación del recomendador clásico.

#### 4.3.2 S.R. colaborativos

El filtrado colaborativo está ampliamente implementado en los S.R., este realiza las recomendaciones teniendo como base a otros usuarios con gustos similares, la similitud en los gustos es obtenida de acuerdo al historial de calificaciones del conjunto de usuarios encontrados. Los S.R. colaborativos buscan solucionar el problema de la recomendación de nuevos contenidos, presente en el anterior enfoque, pero aun no es una solución final a este problema, si se tiene escasa información por parte de los demás usuarios, además se sigue presentando el inconveniente del arranque en frío ya que el sistema en un inicio no cuenta con información importante para efectuar una sugerencia, además de no conocer con precisión los gustos del usuario. En la figura 4.4 se observa el gráfico resumen de su funcionamiento.

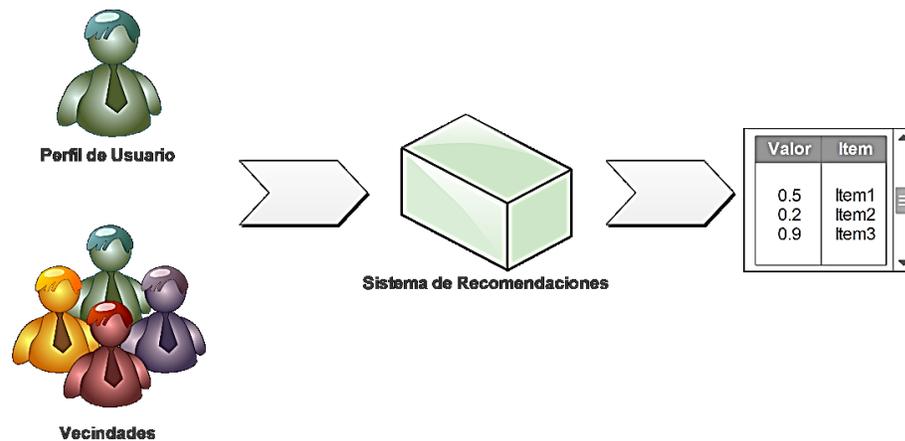


Figura 4.4 Diagrama de secuencia de un S.R. basado en filtros colaborativos, fuente: propia

La mayoría de sistemas de filtrado colaborativo, emplean la técnica basada en vecindades, estas consisten en agrupar un número de usuarios con un determinado grado de similitud, la predicción al usuario activo, es realizado con el cálculo de la media ponderada de las calificaciones de los usuarios seleccionados.

Previendo los anteriores problemas mencionados en los enfoques clásicos, como alternativa de solución a la escasez de datos y el arranque en frío, son usados los S.R. basados en contexto, los cuales brindan una alternativa para hacer frente a dichos problemas haciendo uso de variables contexto de usuario. En la sección 4.4 el lector podrá observar esta temática.

## 4.4 S.R. basados en contexto

Antes de explicar los S.R. basados en contexto, es necesario entender el concepto de contexto, este según la disciplina tiene significados variados, pero de forma general se define como: “El conjunto de elementos que tienen influencia alguna sobre el objeto” [13]. En la literatura los sistemas conscientes del contexto, se definieron inicialmente como la información relacionada con la ubicación del usuario, los objetos y personas relevantes en la interacción del usuario y la aplicación. Cada vez se añaden muchas más variable del contexto como son: el tiempo, el clima y las variables fisiológicas, en miras a enriquecer más este tipo de sistemas.

En los S.R. basados en contexto se tiene en cuenta parámetros conocidos y desconocidos por los sistemas, además se buscan variables que puedan tener un impacto en la selección y clasificación de los resultados de las recomendaciones, cualquier tipo de información sobre las condiciones donde se encuentra un usuario, consideradas relevantes para la interacción con el sistema, permitiendo realizar sugerencia personalizadas de acuerdo a su contexto físico, personal, social y de red, ver figura 4.5.

Las actuales aproximaciones, en cuanto al uso de información del contexto con técnicas de recomendación tradicionales, se enmarcan en el ámbito del consumo de contenidos multimedia musicales en escenarios fijos o de movilidad. En ambos casos, se obtienen con ayuda de sensores, un conjunto de variables del contexto tales como: temperatura, ruido ambiente, ubicación, luminosidad, hora, situación geográfica, entre otras. A través de estas variables, es determinado el estado de ánimo o la actividad diaria realizada por el usuario en un determinado periodo del día, usando para ello algoritmos de inferencia y clasificación, destacándose los métodos de lógica difusa. Según el estado de ánimo o la actividad diaria inferida se recomienda un contenido determinado, el cual ha sido previamente clasificado. Dada la necesidad de variables del contexto desde diferentes fuentes, los entornos de movilidad se adecuan de mejor forma al despliegue e implementación de los S.R. híbridos, basados en contexto [63] [64].

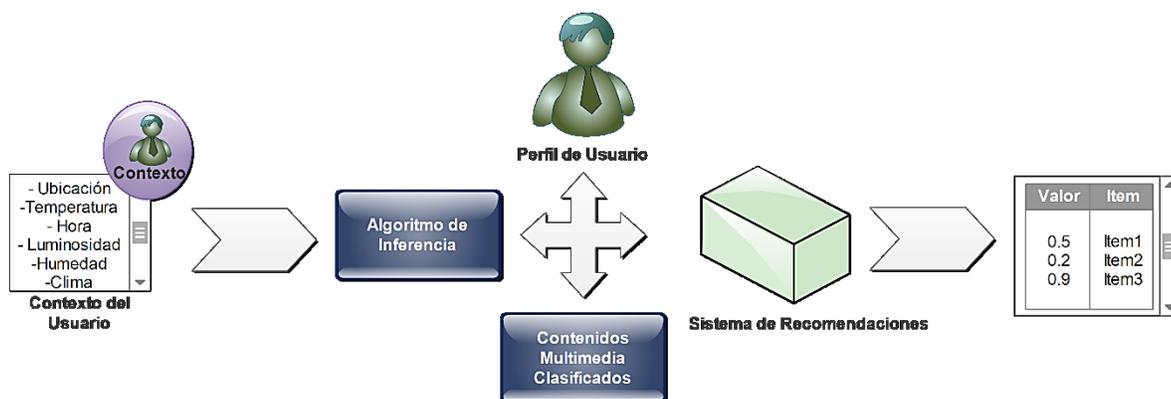


Figura 4.5 Diagrama de secuencia de un S.R. basado en contexto, fuente: propia

Con base en la definición dada, en el presente trabajo se han escogido como variables del contexto de usuario las medidas fisiológicas como son: la VFC, RGP y EMG vistas en el capítulo 3, las cuales permiten la generación del algoritmo de inferencia de emociones y el empleo de un clasificador de contenidos de acuerdo al modelo de 5 emociones propuesto en el capítulo 2, esto se puede ver en el numeral 4.5 a continuación.

## 4.5 Diseño del S.R. basado en contexto

Como propuesta de un sistema de recomendaciones basado en emociones, se plantea en primer lugar la arquitectura generada, en la cual son consideradas como variables de entrada al S.R. las medidas fisiológicas de VFC, RGP, y EMG, las cuales proveen la información necesaria para la inferencia de emociones como se observa en el capítulo 3. Dicha arquitectura puede ser observada en la figura 4.6.

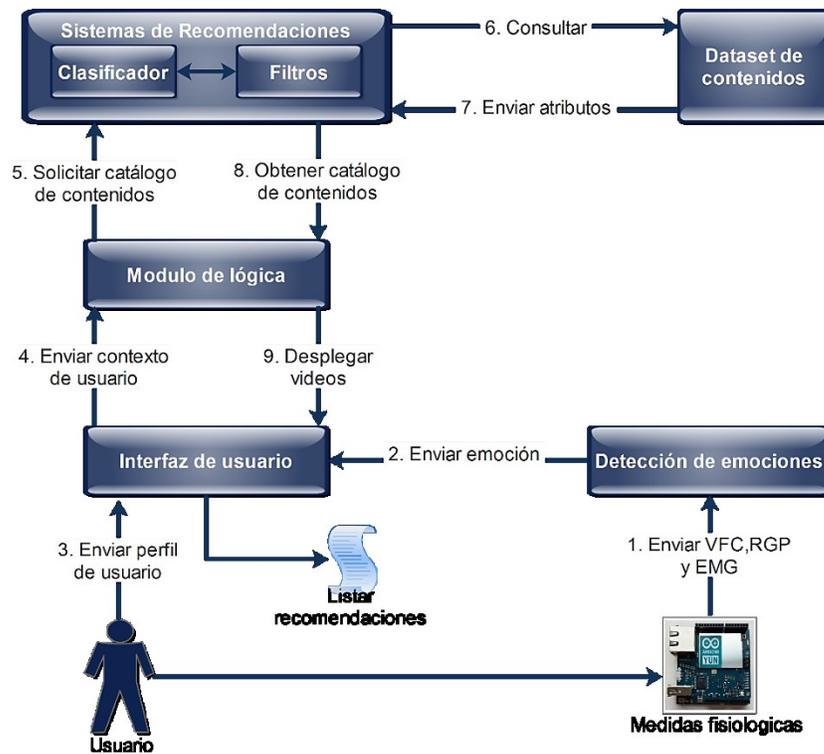


Figura 4.6 Arquitectura del S.R. basado en contexto, fuente: propia

A continuación, se describen el conjunto de pasos que involucra la generación de la lista de recomendaciones al usuario:

En “1” por medio de la tarjeta Arduino Yún se procede a la captura periódica de las variables VFC, RGP y EMG, las cuales son obtenidas a través de los sensores fisiológicos. Estas son analizadas por el bloque de detección de emociones el cual está compuesto por tres módulos de análisis vistos en la sección 3.7. Dicho bloque se encarga de calcular el índice de estrés mental (SI), la *valence* y el *arousal* que presenta el usuario mientras interactúa con el sistema.

En “2” una vez se haya inferido la emoción del usuario a partir del *arousal* y la *valence*, y en “3” el usuario se haya validado, se procede en “4” a enviar el contexto de usuario al módulo de lógica, este se encarga en “5” de solicitar el catálogo de contenidos de acuerdo al perfil inicial presentado por el usuario. El S.R. es el encargado de clasificar y filtrar los contenidos relevantes al usuario. Este en “6” realiza la consulta al *dataset* para obtener el contenido con las características enmarcadas con la emoción presente en el usuario.

En “7” se envían la lista de contenidos recomendados al S.R. en donde el clasificador de tipo booleano se encarga de predecir el orden de los contenidos por emoción haciendo uso del *arousal* y la *valence*, además de tener en cuenta la posible valoración que el usuario haya dado al video. El filtro por su parte con ayuda del SI y la medida tomada por el RGP, es el

encargado de reordenar la lista de recomendaciones por nivel de *arousal*, consolidando la lista sugerida al usuario de forma dinámica durante la experiencia con el servicio. Un resumen explicativo, acerca del diseño del S.R. desarrollado se puede ver en la figura 4.7.

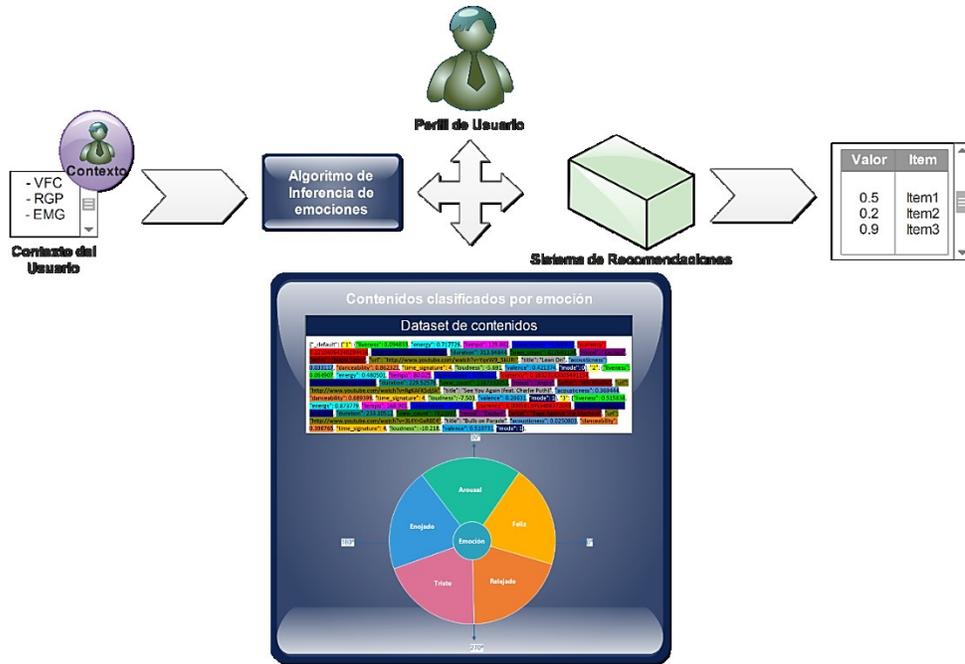


Figura 4.7 Diseño del S.R. basado en contexto, fuente: propia

### 4.5.1 Diseño del clasificador bayesiano

El clasificador diseñado en el presente trabajo forma parte del S.R. clásico. Este es del tipo booleano como se explicó en la sección 4.3.1.1 y está basado en el algoritmo de Naive Bayes. El clasificador tiene como objetivo ordenar el contenido relevante al estado emocional del usuario y con base en esto inferir los posibles gustos musicales del consumidor mientras interactúa con el sistema. En la tabla 4.2 es presentado un ejemplo de un clasificador bayesiano propuesto en este trabajo en donde se observa 5 columnas, la cuales contiene información como título del video, nivel de *arousal*, tiempo, *valence* y calificación.

Tabla 4.2 Ejemplo de clasificador bayesiano con valores booleanos, fuente: propia

VIDEO	A	V	T	C
<i>Bulls on Parade</i>	1	1	1	0
<i>Bombtrack</i>	1	1	1	1
<i>Freedom</i>	0	1	0	1
<i>Settle For Nothing</i>	1	0	0	0
<i>Ellens Gesang III (¡AVE MARIA!)</i>	0	0	1	?

Donde las letras significan A=*arousal*, T=tempo, V=*valence* y C=calificación.

Para obtener las características del contenido multimedia, se consultan los parámetros musicales al *dataset* de video, conformado en el capítulo 2 del presente documento. Dado que los rangos de valores de las variables utilizadas: *arousal* y *valence*, oscilan entre 0 y 1; es necesario discretizar sus valores en dos números booleanos “0” o “1”, los cuales se van a utilizar en el clasificador bayesiano. Para ello son utilizadas las ecuaciones 4.5(a) y (b) las cuales permiten discretizar los valores mayores a 0,8 como un “1” booleano y menores o igual a este valor como un “0” booleano.

$$arousal_{Discretizado} = \begin{cases} arousal > 0,8 = 1 \\ arousal \leq 0,8 = 0 \end{cases} \quad (a)$$

$$valence_{Discretizado} = \begin{cases} valence > 0,8 = 1 \\ valence \leq 0,8 = 0 \end{cases} \quad (b)$$

*Ecuación 4.5 Formulas para discretizar arousal y valence*

En resumen, según las ecuaciones 4.5 los valores de *arousal* y *valence* que excedan el 0,8 de su rango, se van a considerar como un “1” booleano o un valor positivo, y los valores menores al 0,8 son considerados como un “0” booleano o valor negativo. En el caso de la propiedad musical tempo es necesario inicialmente normalizar su valor para que oscile en un rango entre 0 y 1, pues esta propiedad en la música presenta un rango entre 20 y 240 ppm (pulsaciones por minuto) y el cual es el rango común donde se puede apreciar una pieza musical. Luego es posible discretizar y obtener un valor booleano asociado al valor inicial del tempo. En la ecuación 4.6(a) se presenta la fórmula para normalizar el tempo y en la ecuación 4.6(b) es mostrada la fórmula para discretizar dicho valor como un “0” o “1” booleano después de haber normalizado.

$$tempo_{Normalizado} = \frac{tempo - 20}{240 - 20} \quad (a)$$

$$tempo_{Discretizado} = \begin{cases} tempo_{Normalizado} > 0,8 = 1 \\ tempo_{Normalizado} \leq 0,8 = 0 \end{cases} \quad (b)$$

*Ecuación 4.6 Formulas para normalizar y discretizar el tempo*

En el caso de la calificación, también es necesario discretizar ya que los valores oscilan entre 1 y 5 para este atributo, para ello se considera como un “1” booleano las calificaciones mayores o igual a 3 y con un “0” booleano lo menores a este valor. En la ecuación 4.7 se presenta la ecuación para discretizar en un valor booleano la calificación.

$$calificación_{Discretizado} = \begin{cases} calificación \geq 3 = 1 \\ calificación < 3 = 0 \end{cases}$$

*Ecuación 4.7 Formula para discretizar calificación del contenido*

Los valores de *arousal*, *valence*, tiempo y calificación discretizados conforman los atributos de entrada del clasificador booleano de Naive Bayes, el cual fue implementado en Java usando la API de la herramienta de análisis de datos weka<sup>21</sup>. Un ejemplo para la obtención de los valores booleanos se muestra continuación en la tabla 4.3 y tabla 4.4, donde se tiene para una pista los siguientes valores de *arousal*, *valence*, tiempo y calificación como se aprecia a continuación.

Tabla 4.3 Ejemplo de discretización con un contenido original (sin discretizar), fuente: propia

NOMBRE	AROUSAL	VALENCE	TEMPO	CALIFICACIÓN
<i>Freedom</i>	0,491285	0,858701	72,064	3

- El *arousal* discretizado es  $(0.491285 \leq 0.8) = 0$
- En la *valence* se plantea  $(0.858701 > 0.8) = 1$
- Para el tiempo se tiene  $(72.064 - 20) / 220 = 0,236654545$ , luego es discretizado su valor y  $0,236654545 \leq 0.8 = 0$
- La calificación discretizada es  $(3 \geq 3) = 1$

Lo anterior puede ser visto a continuación:

Tabla 4.4 Ejemplo de discretización con un contenido original (discretizados), fuente: propia

NOMBRE	AROUSAL	VALENCE	TEMPO	CALIFICACIÓN
<i>Freedom</i>	0	1	0	1

Luego del cálculo de la lista de valores booleanos, el clasificador predice la posible valoración que el usuario daría al contenido “Ellens Gesang III (¡AVE MARIA!)” (columna C de la Tabla 4.2) teniendo como base calificaciones anteriormente realizadas, generando un listado de videos ordenados según la hipótesis de clasificación más probable.

En la figura 4.8, se presenta como resumen el diagrama del clasificador bayesiano, donde el S.R. clásico hace parte del S.R. basado en contexto, visualizándose cómo interactúan los dos sistemas, utilizando el primero como método de entrada las características del contenido, en cambio el segundo o el S.R. basado en contexto, utiliza las medidas fisiológicas de usuario para hacer uso del método de inferencias de emociones. Permitiendo con los dos enfoques, efectuar recomendaciones que se adapten mucho más a los gustos del usuario.

<sup>21</sup> Plataforma software para minería de datos. Página web oficial de weka: <http://cs.waikato.ac.nz/~ml/weka>.

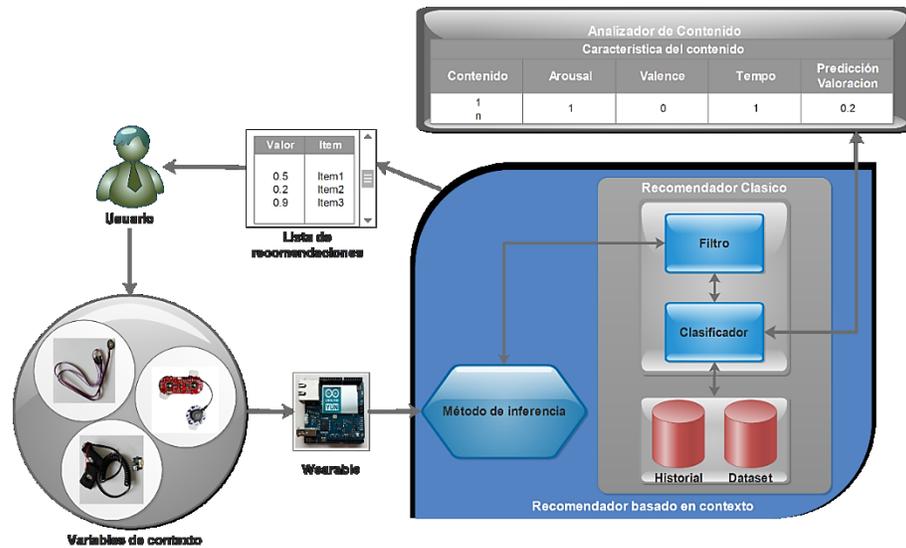


Figura 4.8 Diagrama final del clasificador bayesiano, fuente: propia

### 4.5.2 Servicio de VoD

La arquitectura del servicio de VoD propuesto en el presente trabajo comprende cómo se ha venido enfatizando a lo largo del documento los siguientes bloques funcionales: módulo hardware de Arduino, el servidor de contexto, servidor de lógica, servidor de procesamiento, el servidor de contenidos y la base de datos (ver figura 4.9).



Figura 4.9 Arquitectura del servicio de VoD, fuente: propia

El módulo Arduino Yún proporciona un servicio web RESTful entre los sensores y el servidor de contexto, este se encarga de recibir las medidas capturadas de los sensores de VFC, RGP y EMG, y enviarlas al servidor de contexto desarrollado con Flask de Python, donde es realizado el cálculo del índice de estrés (SI), *arousal* y *valence* para el establecimiento de la emoción. Esta información es consultada por el servidor de lógica el cual recibe dicha

información a través del formato JSON desde el servidor de contexto, en este módulo se efectúa la validación del usuario y es realizada la solicitud del catálogo de contenidos al servidor de procesamiento. La base de datos MySQL de sistema, a la cual se realizan las consultas contiene las tablas de perfil de usuario y lista de contenidos, en donde son registradas las valoraciones de los contenidos dadas por cada usuario. Por otra parte, en el servidor de procesamiento se genera la lista de recomendaciones haciendo uso de las predicciones realizadas por weka al usuario, de acuerdo al perfil de este y teniendo en cuenta la emoción de entrada. Una vez generada la lista de recomendación, es enviada empleando el formato JSON al servidor de lógica, el cual solicita los videos vía HTTP al servidor de contenidos para desplegarlos en la interfaz de usuario del servicio de VoD.

El servicio de video bajo demanda del presente proyecto fue generado como medio de evaluación del sistema de recomendaciones desarrollado, además los S.R. vienen incluidos en las prestaciones de los servicios de VoD. En el presente numeral se pretende mostrar al lector, el diseño de la interfaz de usuario del servicio de VoD. Como primera interfaz se tiene la validación del usuario y la segunda permitirá la visualización de los videos. En la figura 4.10 es posible observar la primera de estas.



Figura 4.10 Interfaz validación de usuario del servicio de VoD, fuente: propia

En “1” el usuario como acción inicial se valida en el sistema, para ello como primera acción son obtenidas las medidas fisiológicas a través del sistema hardware-software implementado en la sección 3.7 (ver figura 4.11). En “2”, al presionar el botón obtener valores se comienza la captura de la VFC y la EMG para establecer el nivel de *arousal* y *valence*, los cuales permiten determinar la emoción de entrada del usuario. En “3” el usuario visualiza gráficamente la medida de la frecuencia cardíaca en tiempo real. Una vez obtenidos los valores, el usuario puede iniciar sesión, si no se encuentra registrado tendrá la opción de

hacerlo. Al realizar dicha acción de validación, como segundo paso se le muestra la interfaz presentada en la figura 4.12.



Figura 4.11 Sistema de captura de datos, fuente: propia



Figura 4.12 Interfaz principal de usuario del servicio de VoD, fuente: propia

En “1” se muestra el campo donde se reproduce el video recomendado al usuario por el S.R., además del menú de control del video donde puede realizar diferentes acciones (pausar video, detener el video, subir y bajar volumen, cambiar de video, ajustar a toda la pantalla el video, y sistema de valoración del mismo), esta última acción de valorar es muy importante para el sistema, pues va a servir de retroalimentación en la recomendación de nuevos contenidos. En “2” el usuario ve el monitoreo continuo de las variables fisiológicas de (FC, VFC, RGP y EMG), además es mostrado el nivel de estrés y la emoción de usuario en ese instante, también al igual que con la primera interfaz, el gráfico de HR vs tiempo es posible visualizarlo. En “3” es mostrado al consumidor un listado promedio de 40 contenidos

de video recomendados, en donde la emoción detectada por el sistema es pieza clave para el despliegue de los contenidos relevantes al usuario y la medida RGP se encarga de reordenarlos de acuerdo al estímulo o aumento del *arousal* en la persona.

Es importante mencionar como el S.R. va a estar actualizando cada 60 segundos el listado de recomendaciones de acuerdo al cambio emocional presente en el usuario por un determinado estado de tiempo, y cada 90 segundos se reordena el listado de acuerdo al estímulo que le proporcionen la visualización de los videos. Donde este es determinado a partir de la medida galvánica de la piel (RGP), la cual está asociada a un cambio en la percepción del *arousal* en el usuario. En la Figura 4.13 es mostrada la arquitectura del servicio de VoD propuesto, la cual comprende los siguientes bloques funcionales: el servidor web, el servidor de lógica, servidor de contexto, servidor de procesamiento, el servidor de contenidos y por último el servidor de base de datos.

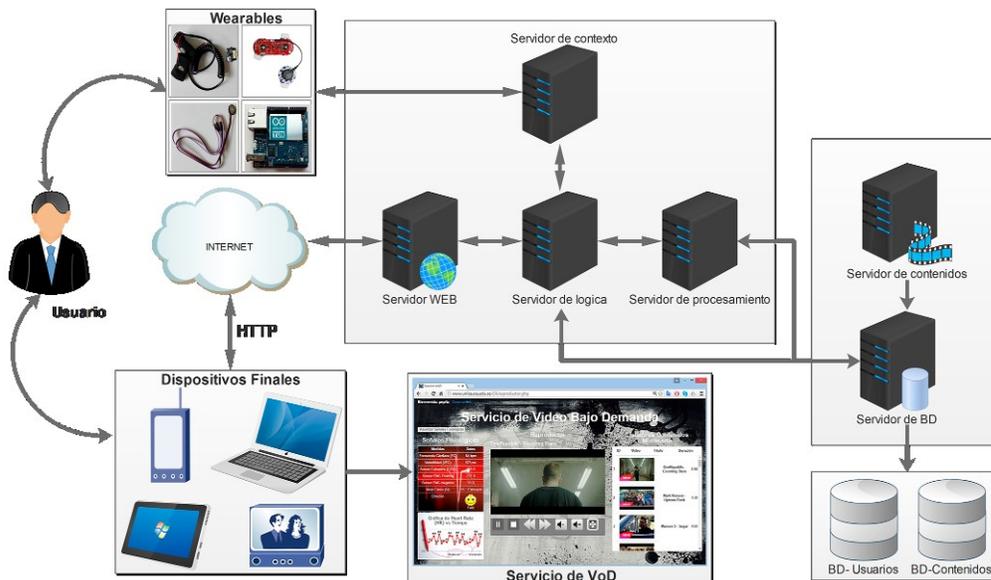


Figura 4.13 Arquitectura del servicio de VoD, fuente: propia

Con el fin de dimensionar, visualizar y organizar el sistema desarrollado. Inicialmente el usuario a través de los dispositivos *wearables* inicia la captura de las medidas fisiológicas, y las cuales permitieron la inferencia de la emoción en el servidor contexto, este envía la emoción de entrada al servidor de lógica, el cual se encarga de validar y solicitar el listado de recomendaciones al servidor procesamiento. El servidor procesamiento a través del clasificador bayesiano y el servidor de base de datos, el cual contiene la información del dataset y los usuarios del servicio, clasifica y ordena las recomendaciones de acuerdo a la emoción de entrada y las preferencias de usuario, y las retorna al servidor de lógica. Este último solicita los videos al servidor de contenidos y los proporciona al usuario vía HTTP a través del servidor web. Finalmente, el usuario hace uso del servicio de VoD a través de los dispositivos finales (PC, tabletas, Smartphones, entre otros).

## Capítulo 5

# Evaluación y Pruebas

## 5.1 Introducción

En este capítulo es presentado como primer apartado las pruebas al S.R. clásico, en las cuales se analizan los porcentajes de predicción de las recomendaciones que el S.R. provee a usuarios y cual sirvió como punto de partida para la vinculación del contexto al nuevo S.R. Después se muestra la evaluación y pruebas al S.R. basado en contexto propuesto, el cual considera la emoción de entrada de usuario; y finalmente las pruebas de carga y estrés algunos de los componentes del servicio de VoD. Lo anterior, con el fin de validar los diferentes componentes del S.R. basado en contexto como posible alternativa al problema de arranque en frío presente en los actuales S.R. clásicos.

## 5.2 Pruebas S.R. clásico

Las pruebas de evaluación del S.R. clásico, se basaron en el análisis y descripción de los porcentajes de predicción presentados por el recomendador bayesiano implementado en el servidor de procesamiento, a través de la API de Weka para Java, el servidor web Spark y la base de datos MySQL. Para ello son realizadas las pruebas al S.R. clásico con usuarios registrados hipotéticamente en el servicio de VoD, los cuales ya han valorado y aún no contenidos. En esta sección, se presentan en primera instancia el resumen de predicciones para las recomendaciones del S.R. clásico proporcionada por la API de Weka para Java, y a continuación la matriz de confusión que modela el desempeño del algoritmo de recomendación.

### 5.2.1 Resumen de predicciones

En la figura 5.1, se presenta un resumen de las predicciones provistas por el clasificador Naive Bayes al S.R. clásico, a través de la herramienta de minería de datos Weka. El clasificador bayesiano hace uso del gestor base de datos MySQL para consultar la base de datos producto del *dataset* de contenidos presentado en el capítulo 2, la cual contiene la información de los usuarios y de los 200 contenidos asociados a las 5 emociones mencionadas en la sección 2.6.1. Los resultados obtenidos del clasificador bayesiano ayudan a filtrar y clasificar de una manera más adecuada las recomendaciones del S.R. clásico provee a los usuarios, a través del servicio de VoD.

```

*****
*** RESUMEN PREDICCIONES ***
Correctly Classified Instances      118          67.8161 %
Incorrectly Classified Instances    56          32.1839 %
Kappa statistic                     0
Mean absolute error                 0.4366
Root mean squared error             0.4673
Relative absolute error             99.8608 %
Root relative squared error         100.0187 %
Total Number of Instances          174
Ignored Class Unknown Instances    26
Número de predicciones: 200
*****

```

*Figura 5.1 Resumen de predicciones del clasificador bayesiano, fuente: propia*

De acuerdo a la figura 5.1, el clasificador realizó correctamente 118 clasificaciones de contenidos con un porcentaje de predicción de 67.81%, 56 clasificaciones incorrectas con un porcentaje de 32.19%, para tener un total de 174 contenidos o instancias consideradas para la clasificación, y las cuales ya han sido valoradas por los usuarios. Además de 26 instancias no valoradas aun por los usuarios, para tener un total de 200 instancias a predecir.

Adicionalmente se observa la estadística kappa (K) con valor de 0, la cual es una medida cuantitativa [0,1] de concordancia, siendo cero el peor de los casos. El error medio absoluto (MAE) es una medida de precisión de datos, lo cual indica como el clasificador presentó un 43,66% de incertidumbre en las recomendaciones, de las cuales pudieron haber sido erróneas o ignoradas. La raíz del error cuadrático medio (RMSE) es un indicador de error medio para predicciones numéricas y la cual indica el grado de desviación de las predicciones, en el caso del clasificador las predicciones en las recomendaciones tuvieron un 46,73% de error, lo cual pudo haber ocurrido por el alto grado de incertidumbre en las recomendaciones. El error relativo absoluto (RAE) es un indicador relativo de precisión simple, lo cual indica como el clasificador tuvo un adecuado indicador de 99,86% en las recomendaciones, donde este indicador mide la diferencia [0,100%] entre el valor absoluto y el valor verdadero de cada recomendación, mientras mayor sea este valor mayor grado de similitud existe en las predicciones de las recomendaciones. La raíz del error cuadrático relativo (RRSE) es un indicador promedio de los valores de predicción reales, para el caso del clasificador bayesiano es un 100,01% acertado en la predicción de cada una de las recomendaciones provistas por el S.R. a usuarios.

Después de analizar los resultados proporcionados por la herramienta de Weka, cabe resaltar como las medidas MAE y RMSE son las de mayor relevancia en el análisis del S.R. clásico, las cuales indican el grado de precisión y desviación de los datos, en este caso el grado de precisión en las recomendaciones provistas por el S.R. a usuarios. Así, luego de analizar los datos e indicadores de predicción, el clasificador bayesiano es un adecuado

recomendador para el S.R. clásico, además de ser un componente a tener en cuenta para adaptaciones y nuevos S.R.

### 5.2.2 Matriz de confusión

La matriz de confusión es una herramienta útil para predecir el desempeño de un clasificador, además de proveer de información acerca de las clasificaciones actuales y pronosticadas realizadas por un sistema de clasificación. En la figura 5.2, es presentada la matriz de confusión que modela el desempeño del clasificador bayesiano utilizado por el S.R. clásico.

```
*****
*** MATRIZ DE CONFUSIÓN ***
0.0|56.0|
0.0|118.0|
*****
```

Figura 5.2 Matriz de confusión del clasificador bayesiano, fuente: propia

Para mayor comprensión de los datos plasmados en la matriz de confusión del clasificador bayesiano descrito en la figura 5.2, es presentado en la tabla 5.1 un ejemplo sintetizado con los datos obtenidos para este clasificador. Para ello se identifican con las letras A, B, C y D, cada uno de los datos estimados en la figura 5.2.

Tabla 5.1 Ejemplo matriz de confusión, fuente: propia

		PREDICCIÓN	
		Negativa	Positiva
INSTANCIA	Negativa	A = 0	B = 56
	Positiva	C = 0	D = 118

El análisis de la tabla 5.1 se puede entender de la siguiente forma:

- A es el número de predicciones correctas, para una instancia negativa, en este ejemplo 0.
- B es el número de predicciones incorrectas, para una instancia positiva, en este ejemplo 56.
- C es el número de predicciones incorrectas, para una instancia negativa, en este ejemplo 0.
- D es el número de predicciones correctas, para una instancia positiva, en este ejemplo 118.

Después de analizar y presentar el ejemplo con la matriz de confusión, se puede concluir como el clasificador bayesiano presenta un porcentaje de 59% de certeza, de acuerdo a las 118 predicciones correctas en las recomendaciones del S.R. clásico provee a los usuarios.

Y un porcentaje de 28% de incertidumbre en las recomendaciones de acuerdo al grado de predicción. Finalmente, el clasificador presenta un adecuado número de predicciones positivas frente a negativas, por lo tanto, puede ser un buen filtro de clasificación en las recomendaciones provistas por el S.R. clásico a usuarios, de acuerdo a las valoraciones de contenidos.

## 5.3 Pruebas S.R. contexto

Para evaluar el S.R. basado en contexto se llevaron a cabo pruebas con métodos de comparación de similitud con respecto a la emoción de entrada entre las recomendaciones generadas por el S.R. clásico y el S.R. basado en contexto. Cabe mencionar como la comparación entre los S.R., es llevado a cabo por medio de la emoción de entrada de usuario, la cual se puede determinar a partir de los parámetros de *arousal* y *valence*, por lo tanto, estos fueron los parámetros considerados en la comparación de ambos S.R. En primera instancia son presentados varios métodos de comparación lineal que miden el grado de similitud entre las recomendaciones, esto con el fin de evaluar ambos S.R., después se presentan las pruebas realizadas y resultados obtenidos de dichos métodos.

### 5.3.1 Métodos de comparación lineal

Uno de los retos en los S.R. basados en contexto es la forma de evaluación del mismo, para ello autores han desarrollado métodos o métricas las cuales ayudan a evaluar la precisión de los S.R. Estos métodos matemáticos de comparación ayudan a validar las recomendaciones que el sistema provee con respecto a las esperadas por el usuario del mismo. Para ello a continuación son mencionados algunos de los métodos utilizados, como son: distancia Euclidiana, distancia Manhattan, similitud del Coseno, coeficiente de correlación de Pearson y coeficiente OLS (*Ordinary least squares*) [65] [66], los cuales son métodos matemáticos de comparación para ver qué tan similar son las recomendaciones propuestas por el sistema al usuario.

#### 5.3.1.1 Distancia Euclidiana

Es la métrica de similitud más básica, es la encargada de medir la distancia entre dos puntos en el espacio, lo cual corresponde a la longitud de una línea recta trazada entre los dos puntos [65]. La ecuación 5.1, corresponde a la métrica en el plano de dos dimensiones, y se define como la sumatoria de las diferencias o distancias entre dos puntos.

$$D_{uv} = \sqrt{\sum_{i=1}^n |a_{ui} - a_{vi}|^2}$$

Ecuación 5.1 Distancia Euclídiana

En resumen, mientras más tienda la métrica a 0, mayor va a ser la similitud entre los puntos, cosa contraria mientras más tienda a 1 la métrica, mayor es la diferencia entre los puntos.

### 5.3.1.2 Distancia Manhattan

Esta métrica es la encargada de medir la suma de las diferencias absolutas en cada uno de sus componentes para 2 vectores en el espacio [65]. Esta medida es aún más precisa en comparación a la distancia euclidiana para vectores de 2 o más dimensiones. A continuación, se presenta la ecuación 5.2 y la cual corresponde a la ecuación de la métrica, la cual es definida como la sumatoria de las diferencias absolutas de 2 vectores.

$$D_{uv} = \sum_{i=1}^n |a_{ui} - a_{vi}|$$

Ecuación 5.2 Distancia Manhattan

A modo de conclusión esta métrica presenta la misma lógica que la distancia euclidiana (ver sección 5.3.1.1), mientras más tienda el valor a 0, mayor es la similitud entre las partes.

### 5.3.1.3 Similitud del Coseno

Es la medida de similitud del producto escalar de dos vectores, la cual se encarga de medir el ángulo entre los vectores y evaluar la dispersión de los mismos. Aunque no es considerada una métrica, debido a que no cumple la desigualdad triangular, es muy útil en los S.R. para medir la similitud de dos vectores [65]. La ecuación 5.3, representa la similitud del coseno de los vectores u y v. Esta medida es definida como el ángulo coseno entre 2 vectores.

$$\text{Cos}(u, v) = \frac{a_u \cdot a_v}{\|a_u\| \|a_v\|} = \frac{\sum_{i=1}^n a_{ui} \cdot a_{vi}}{\sqrt{\sum_{i=0}^n a_{ui}^2} \sqrt{\sum_{i=0}^n a_{vi}^2}}$$

Ecuación 5.3 Similitud del Coseno

Cabe mencionar que, aunque la medida de similitud oscila en la escala de [-1,1], se puede utilizar para parametrizar su escala de [0,1] la siguiente ecuación 5.4:

$$1 - \frac{\cos^{-1}(\cos(u, v))}{\pi}$$

*Ecuación 5.4 Formula parametrización, similitud del coseno*

En conclusión, esta medida indica si dos vectores son similares si el valor de la similitud del coseno tiende más a 1, cuya interpretación se puede mencionar de la siguiente manera, los vectores son simétricos mientras mayor sea su valor de 0 a 1.

#### 5.3.1.4 Coeficiente de correlación de Pearson

Este método se encarga de medir el grado de covariación entre distintas variables relacionadas linealmente, a diferencia de la covarianza este método es independiente de la escala de medidas de sus variables [65]. Este coeficiente mide la similitud en una escala de  $[-1, 1]$ , donde 1 es similar y -1 disimiles. La ecuación 5.5, representa el coeficiente de correlación de Pearson de las variables  $u$  y  $v$ . Este método es definido como el cociente entre la covarianza y las desviaciones estándar de cada una de las variables.

$$\text{CorrP}(u, v) = \frac{\sum_{i=1}^n (a_{ui} - \bar{a}_u) \cdot (a_{vi} - \bar{a}_v)}{\sqrt{\sum_{i=1}^n (a_{ui} - \bar{a}_u)^2} \sqrt{\sum_{i=1}^n (a_{vi} - \bar{a}_v)^2}}$$

*Ecuación 5.5 Coeficiente de Correlación de Pearson*

Si se desea establecer su escala entre  $[0, 1]$ , también se puede hacer uso de la ecuación 5.4. La interpretación del coeficiente es similar a la de la similitud del coseno, ver sección 5.3.1.3; mientras mayor sea el valor del método más similares son las variables.

#### 5.3.1.5 Coeficiente mínimos cuadrados ordinarios (Ordinary Least Squares, OLS)

Es un método no paramétrico de medición de variables o modelado lineal, el cual se encarga de indicar si dos variables o vectores son asociados entre sí. Este método se basa en el ajuste de una línea recta a una muestra de datos, minimizando la suma de los cuadrados de las desviaciones [66]. A continuación, es presentada la ecuación 5.6 la cual modela el coeficiente OLS. Este método se define como el cociente entre el producto de las medias y el cuadrado de una de las variables o vector.

$$\text{OLSCoef}(u, v) = \frac{\sum_{i=0}^n a_{ui} \cdot a_{vi}}{\sum_{i=0}^n a_{ui}^2}$$

*Ecuación 5.6 Coeficiente OLS*

Con el fin de evaluar el S.R. basado en contexto y el cual ha sido propuesto en el presente trabajo de grado, se optó por realizar pruebas utilizando los métodos de comparación mencionados en la sección 5.3.1, con base en las predicciones de contenidos multimedia y las cuales provee el S.R. basado en contexto en comparación al S.R. clásico.

### 5.3.2 Evaluación del S.R. basado en contexto

La evaluación del S.R. basado en contexto es llevado a cabo mediante la siguiente prueba, un usuario hipotético X ingresa con una emoción de entrada que tiene asociada un valor de *arousal* y *valence* y se hace la comparación de estos dos valores de entrada con los valores de *arousal* y *valence* de cada uno de los contenidos recomendados por cada S.R. (clásico y basado en contexto) a través de las métricas de comparación y obteniendo como resultados la media aritmética, desviación estándar y análisis comparativo de las métricas de comparación. Con el fin de encontrar el S.R. con menor grado de dispersión o recomendaciones más adecuadas, ver figura 5.3.

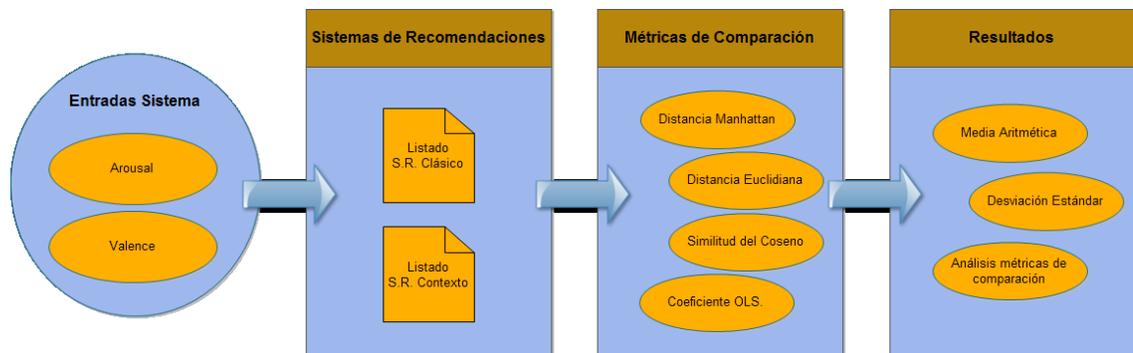


Figura 5.3 Diagrama de evaluación S.R., fuente: propia

Dentro de las métricas de comparación se pueden encontrar: la D.Euclidiana, la D.Manhattan, la similitud del coseno, el coeficiente de Pearson y coeficiente OLS o de mínimos cuadrados. A continuación, son presentados los resultados de las pruebas de comparación realizadas con las recomendaciones de cada S.R., teniendo en cuenta las 5 posibles emociones de entrada (feliz, excitado, enojado, triste y relajado) propuestas en la sección 2.6.1.

#### 5.3.2.1 Resultados de media aritmética

La media aritmética es una medida de tendencia central promedio, la cual indica el valor promedio de un conjunto de datos [67]. Esta medida es utilizada para obtener las medias aritméticas de los resultados analizados a través de las pruebas realizadas en ambos S.R. con las métricas de comparación, mencionadas en la sección 5.3.1. Para ello se

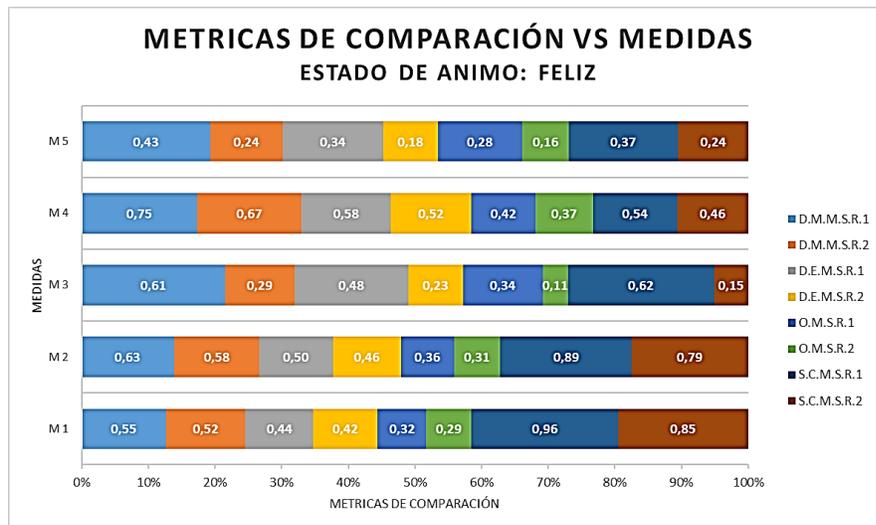
consideraron algunas abreviaturas conceptuales en cada uno de las representaciones de los datos, las cuales son presentadas en la tabla 5.2.

*Tabla 5.2 Abreviaturas de media aritmética para métricas de comparación, fuente: propia*

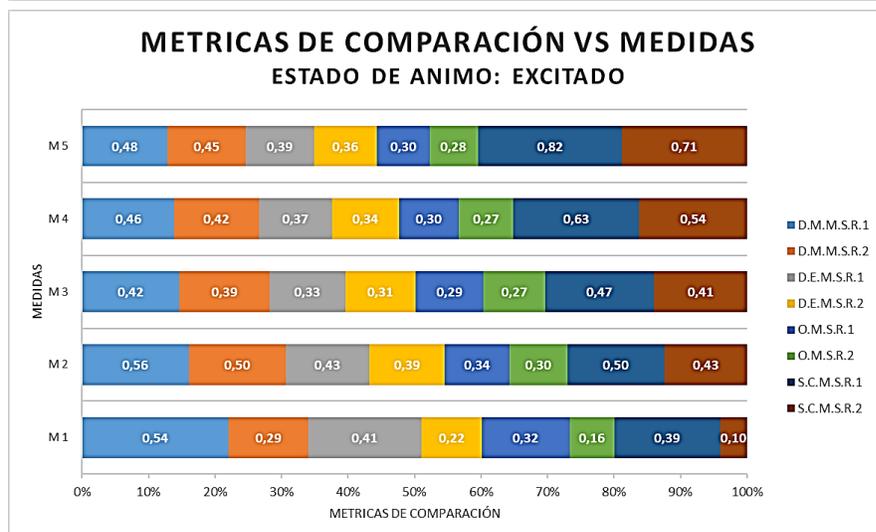
<b>MEDIDA</b>	<b>ABREVIATURA</b>
<i>Media de la distancia Manhattan en S.R. Clásico</i>	<i>D.M.M.S.R.1</i>
<i>Media de la distancia Manhattan en S.R. Contexto</i>	<i>D.M.M.S.R.2</i>
<i>Media de la distancia Euclidiana en S.R. Clásico</i>	<i>D.E.M.S.R.1</i>
<i>Media de la distancia Euclidiana en S.R. Contexto</i>	<i>D.E.M.S.R.2</i>
<i>Media del coeficiente OLS. en S.R. Clásico</i>	<i>O.M.S.R.1</i>
<i>Media del coeficiente OLS. en S.R. Contexto</i>	<i>O.M.S.R.2</i>
<i>Media de la similitud del Coseno en S.R. Clásico</i>	<i>S.C.M.S.R.1</i>
<i>Media de la similitud del Coseno en S.R. Contexto</i>	<i>S.C.M.S.R.2</i>

La evaluación de los S.R. fue llevada a cabo con usuarios hipotéticamente registrados en el servicio de VoD, los cuales habían valorado y aún no contenidos. Para ello se realizaron cinco pruebas secuenciales (M1, M2, M3, M4 y M5) por cada estado de ánimo de entrada de usuario descrito en la sección 2.6.1, de forma que abarcará todo el plano cartesiano del modelo.

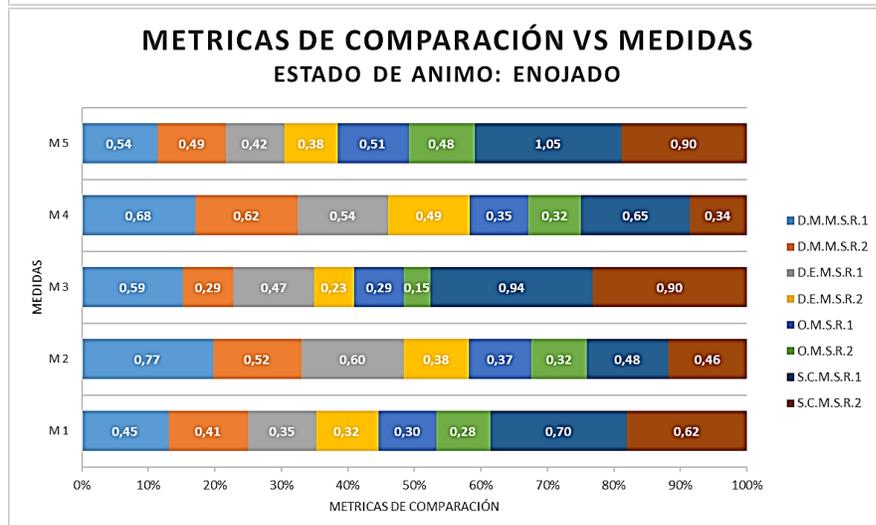
En la figura 5.4 son presentadas las pruebas de la media aritmética para cada una de las métricas de comparación, realizadas con cada estado de ánimo a los dos recomendadores: clásico (S.R.1) y contexto (S.R.2). En las gráficas de la figura 5.4, son presentadas las métricas de dos en dos, mencionando los resultados para cada S.R. Donde las 2 primeras son las métricas de la media aritmética para la distancia Manhattan (S.R.1 en color azul claro y S.R.2 en color naranja), las siguientes 2 de la distancia Euclidiana (S.R.1 en color gris y S.R.2 en color amarillo), seguidamente las 2 del coeficiente OLS (S.R.1 en color azul y S.R.2 en color verde) y finalmente las 2 métricas de la similitud del Coseno (S.R.1 en color azul oscuro y S.R.2 en color café). Además, es realizado un ajuste con los resultados de la métrica similitud del Coseno, de tal manera que permitiera mayor comprensión en los datos, para ello se hizo la parametrización de los datos a través de la ecuación 5.4 y este producto es multiplicado por un factor de 10 con cada resultado de la métrica. Cabe mencionar adicionalmente que, aunque se hizo un ajuste con los datos de similitud del Coseno, esta métrica no brinda información relevante.



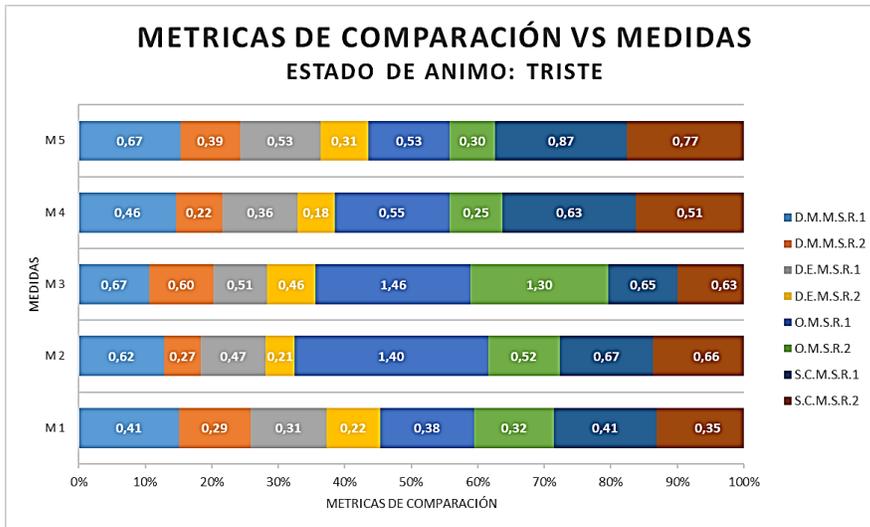
(a)



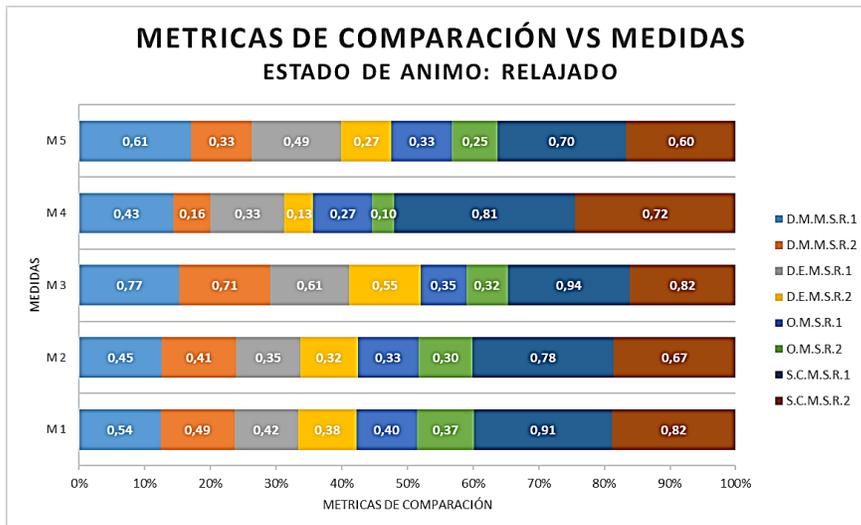
(b)



(c)



(d)



(e)

Figura 5.4 Métricas de comparación vs medidas (media aritmética), fuente: propia

En la figura 5.4a) se muestra la media de las métricas de comparación vs medidas (5 medidas secuenciales capturadas) para el estado de ánimo “feliz”, entre el S.R. clásico y el S.R. basado en contexto. En esta gráfica es observado como en las medidas “M3” y “M5”, se encuentra diferencias de 0,32 y 0,19 entre D.M.M.S.R.1 y D.M.M.S.R.2; 0,25 y 0,16 entre D.E.M.S.R.1 y D.E.M.S.R.2; 0,23 y 0,12 entre O.M.S.R.1 y O.M.S.R.2; 0,47 y 0,13 entre S.C.M.S.R.1 y S.C.M.S.R.2; lo cual permite evidenciar como las recomendaciones del S.R.2 son más adecuadas en cuanto al estado de ánimo de entrada de usuario. Las demás métricas son similares en las otras medidas, pero con menores rangos de diferencia entre 0,03 y 0,08 para D.M.M.; 0,02 y 0,06 para D.E.M.; 0,03 y 0,05 para O.M.; 0,09 y 0,11 para S.C.M.

En la figura 5.4b) son presentados los resultados para el estado de ánimo de entrada “excitado”. En esta gráfica se muestra como en la medida “M1”, se evidencian diferencias

de 0,25 entre D.M.M.S.R.1 y D.M.M.S.R.2; 0,19 entre D.E.M.S.R.1 y D.E.M.S.R.2; 0,16 entre O.M.S.R.1 y O.M.S.R.2; 0,29 entre S.C.M.S.R.1 y S.C.M.S.R.2; observándose levemente como el S.R.2 presenta recomendaciones más adecuadas que el S.R.1, a partir del estado de ánimo de entrada de usuario. Además, se puede observar como los resultados de las métricas de comparación son similares a la emoción anterior.

En la figura 5.4c) son mostrados los resultados para el estado de ánimo de entrada “enojado”. Los datos presentados en esta gráfica son algo diferentes con respecto a resultados anteriores, pues para algunas medidas las métricas presentan mejores resultados en comparación a otras. Por ejemplo, los resultados de las medidas “M2” y “M3” presentan gran diferencia en sus métricas de comparación, y “M1”, “M4” y “M5” menor grado de similitud. Los resultados de la medida “M3” presenta una diferencia de 0,30 entre D.M.M.S.R.1 y D.M.M.S.R.2, además una diferencia de 0,24 entre D.E.M.S.R.1 y D.E.M.S.R.2, y 0,14 entre O.M.S.R.1 y O.M.S.R.2 favoreciendo a S.R.2; diferente a los datos en “M4” donde la diferencia entre D.M.M.S.R.1 y D.M.M.S.R.2 es 0,06, entre D.E.M.S.R.1 y D.E.M.S.R.2 es 0,05 y 0,03 entre O.M.S.R.1 y O.M.S.R.2, donde son datos mucho menores; lo cual permite evidenciar como el S.R.2 presenta mejores recomendaciones que el S.R.1, de acuerdo al estado de ánimo de entrada de usuario. Lo anterior, encuentra explicación en el hecho de querer forzar al usuario a un estado de ánimo enojado por un periodo de tiempo, a través de diversos factores para producir estrés como son: el ruido, oscuridad, entre otros.

En la figura 5.4d) son presentados los resultados para el estado de ánimo de entrada “triste”. En esta gráfica se observan los mejores resultados con respecto a resultados anteriores, donde las diferencias en las métricas de comparación rondan los rangos de 0,35 entre D.M.M.S.R.1 y D.M.M.S.R.2; 0,26 entre D.E.M.S.R.1 y D.E.M.S.R.2; 0,88 entre O.M.S.R.1 y O.M.S.R.2; y 0,01 entre S.C.M.S.R.1 y S.C.M.S.R.2, evidenciando como las recomendaciones del S.R.2 son más adecuadas que el S.R.1 de acuerdo al estado de ánimo de entrada de usuario.

En la figura 5.4e) son mostrados los resultados para el estado de ánimo de entrada “relajado”, donde se ilustran los resultados de cada una de las métricas vs medidas, y se observa en cada medida como tienden al mismo comportamiento en sus resultados en comparación a resultados anteriores, presentando al S.R.2 con recomendaciones más adecuadas de acuerdo al estado de ánimo de entrada de usuario.

Así, como conclusión de esta sección, se observa como los datos analizados en ambos S.R.: clásico (S.R.1) y basado en contexto (S.R.2) a través de las pruebas de comparación realizadas, evidencian como las recomendaciones de S.R.2 son más precisas en comparación al S.R.1, con respecto a emoción de entrada de usuario. Las pruebas realizadas con los estados de ánimo: feliz, relajado y triste, presentan mejores resultados de similitud en las recomendaciones, de acuerdo al estado de ánimo de entrada de usuario.

Las pruebas con el estado de ánimo excitado, también presenta buenos resultados, pero en menor grado de similitud. El estado de ánimo enojado, es el único que presenta algunas diferencias en sus resultados, pero con resultados positivos de similitud.

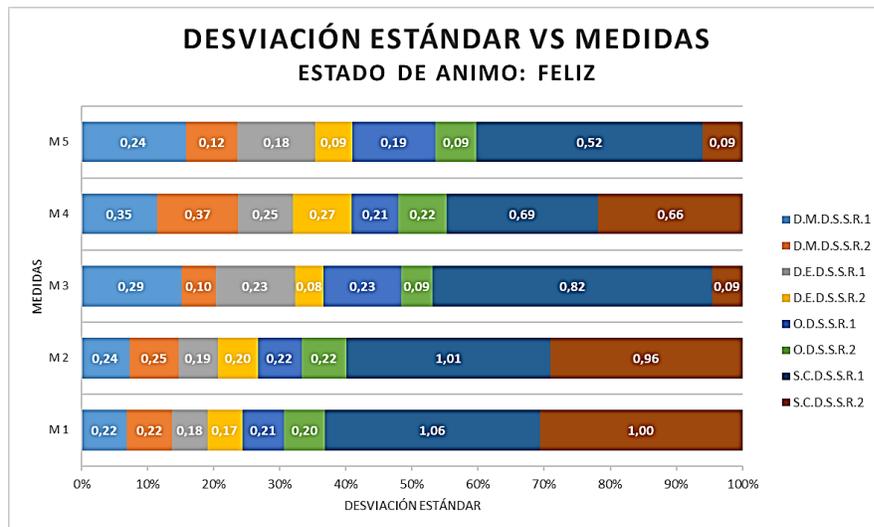
### 5.3.2.2 Resultados de desviación estándar

La desviación estándar es un índice numérico, el cual indica la dispersión de un conjunto de datos, entre menor sea este valor menor es grado de dispersión y mayor similitud presentan los resultados [67]. Esta medida es utilizada para obtener la desviación estándar de los resultados analizados a través de las pruebas realizadas en ambos recomendadores con las métricas de comparación, mencionadas en la sección 5.3.1. Además, se realizaron algunas abreviaturas conceptuales para ayudar a un mejor manejo y análisis de los resultados en las gráficas, ver tabla 5.3.

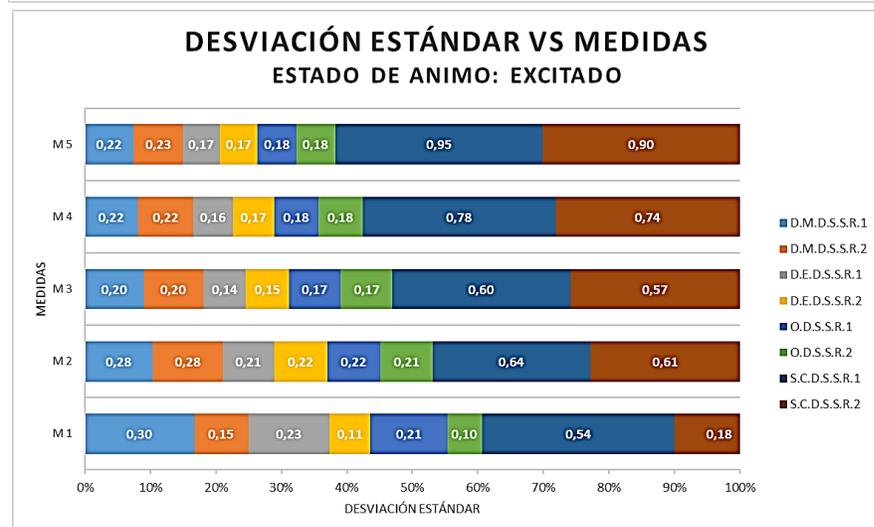
Tabla 5.3 Abreviaturas de desviación estándar para métricas de comparación, fuente: propia

MEDIDA	ABREVIATURA
<i>Desviación estándar de la distancia Manhattan en S.R Clásico</i>	<i>D.M.D.S.S.R.1</i>
<i>Desviación estándar de la distancia Manhattan en S.R Contexto</i>	<i>D.M.D.S.S.R.2</i>
<i>Desviación estándar de la distancia Euclidiana en S.R Clásico</i>	<i>D.E.D.S.S.R.1</i>
<i>Desviación estándar de la distancia Euclidiana en S.R Contexto</i>	<i>D.E.D.S.S.R.2</i>
<i>Desviación estándar del coeficiente OLS. en S.R Clásico</i>	<i>O.D.S.S.R.1</i>
<i>Desviación estándar del coeficiente OLS. en S.R Contexto</i>	<i>O.D.S.S.R.2</i>
<i>Desviación estándar de la similitud del Coseno en S.R Clásico</i>	<i>S.C.D.S.S.R.1</i>
<i>Desviación estándar de la similitud del Coseno en S.R Contexto</i>	<i>S.C.D.S.S.R.2</i>

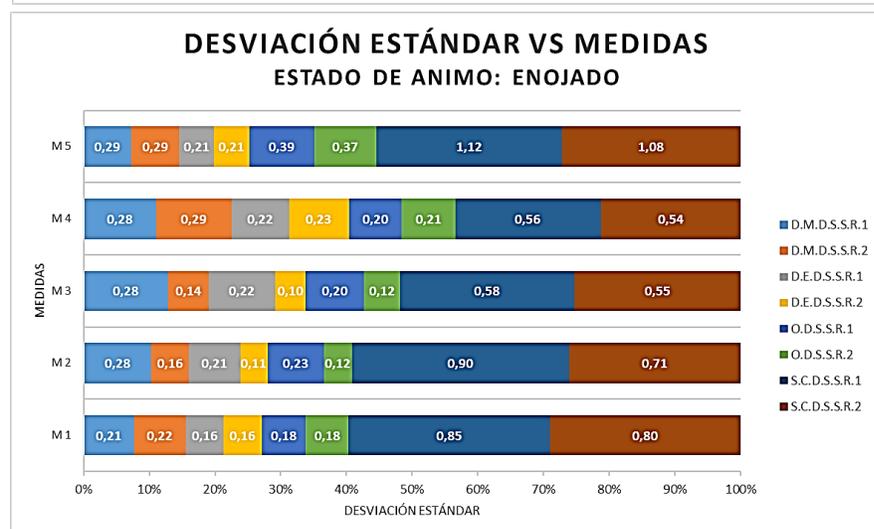
El análisis de desviación estándar con cada uno de los resultados, se llevó a cabo por medio de cinco pruebas secuenciales (M1, M2, M3, M4, M5) para los cinco estados de ánimo presentados en la sección 2.6.1. En la figura 5.5, son presentados los resultados de desviación estándar realizados a través de las pruebas a cada S.R., teniendo en cuenta el estado de ánimo de entrada de usuario. En las gráficas de la figura 5.5, son presentadas las métricas de dos en dos, mencionando los resultados para cada S.R. Donde las 2 primeras son las métricas de desviación estándar para la distancia Manhattan (S.R.1 en color azul claro y S.R.2 en color naranja), las siguientes 2 de la distancia Euclidiana (S.R.1 en color gris y S.R.2 en color amarillo), seguidamente las 2 del coeficiente OLS (S.R.1 en color azul y S.R.2 en color verde) y finalmente las 2 métricas de la similitud del Coseno (S.R.1 en color azul oscuro y S.R.2 en color café).



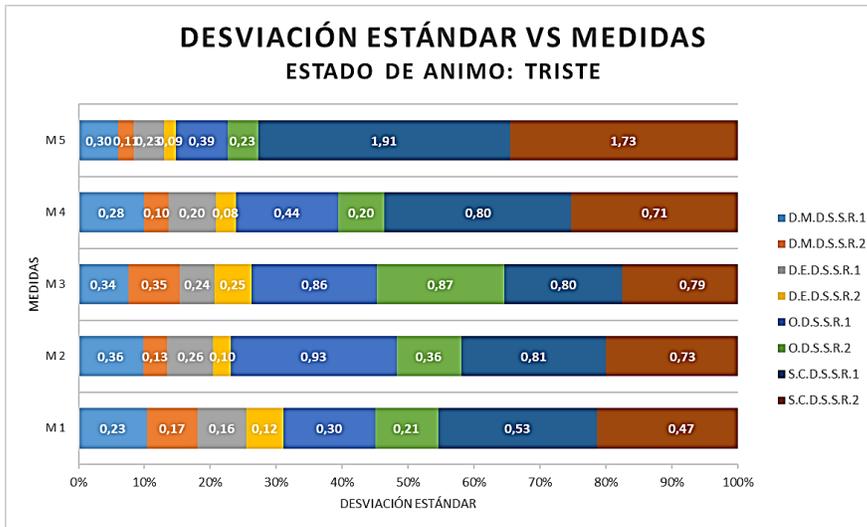
(a)



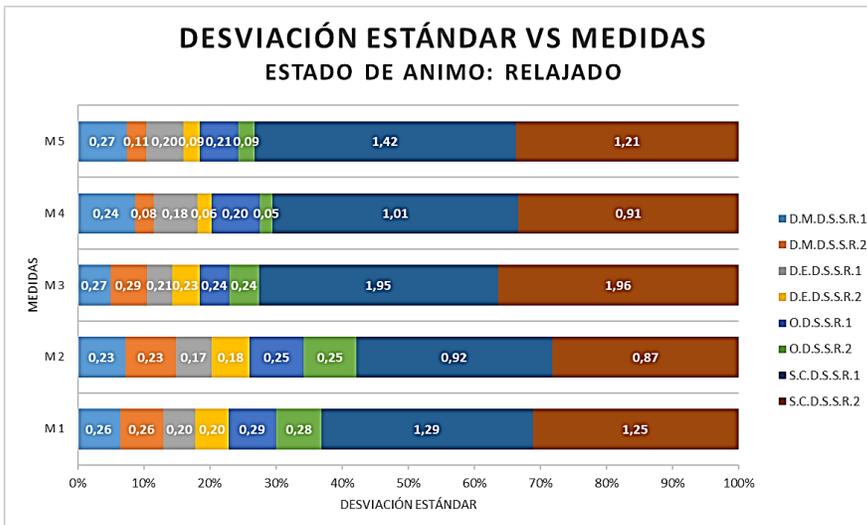
(b)



(c)



(d)



(e)

Figura 5.5 Desviación estándar vs medidas, fuente: propia

En la figura 5.5a) son mostrados los resultados de desviación estándar para el estado de ánimo de entrada “feliz”. En esta gráfica se observa como en las medidas “M3” y “M5” el S.R.2 es más adecuado y presenta menor grado de dispersión en los resultados en comparación al S.R.1, de acuerdo al estado de ánimo de entrada de usuario; con rangos de diferencia entre los 0,14 y 0,18 para “M3”, y 0,09 y 0,12 para “M5” en las métricas de comparación. Por su parte, en el caso de “M2” y “M4” presentan al S.R.2 con resultados desfavorables frente al S.R.1, donde las diferencias en las métricas de comparación están entre los rangos de 0,01 y 0,02 a favor S.R.1. En la medida “M1” los resultados son algo equivalentes, con rangos de diferencia entre 0,01 y 0,05 en las métricas de comparación, presentando levemente como las recomendaciones del S.R.2 son más adecuadas a las del S.R.1.

En la figura 5.5b) son presentados los resultados para el estado de ánimo de entrada “excitado”. En esta gráfica se puede observar como en la medida “M1” los resultados presentan al S.R.2 más adecuado en las recomendaciones que el S.R.1; pero en las demás medidas los valores son algo similares favoreciendo levemente los resultados de las métricas al S.R.2, teniendo en cuenta el estado de ánimo de entrada de usuario al sistema.

En la figura 5.5c) se muestran los resultados para el estado de ánimo de entrada “enojado”. Los resultados de las medidas “M1” y “M5” son similares en sus resultados, con unas pequeñas diferencias en sus resultados entre los rangos de 0,01 y 0,05. En las medidas “M2” y “M4” el S.R.2 presenta resultados más adecuados en las recomendaciones en comparación al S.R.1, de acuerdo al estado de ánimo de entrada de usuario.

En la figura 5.5d) son presentados los resultados para el estado de ánimo de entrada “triste”. En esta gráfica se observa como el S.R.2 es más adecuado y con menor grado de dispersión en los resultados que el S.R.1, con rangos de diferencia entre 0,06 y 0,23 para D.M.D.S; 0,04 y 0,16 para D.E.D.S; 0,09 y 0,57 para O.D.S; y 0,01 y 0,18 para S.C.D.S, de acuerdo al estado de ánimo de entrada.

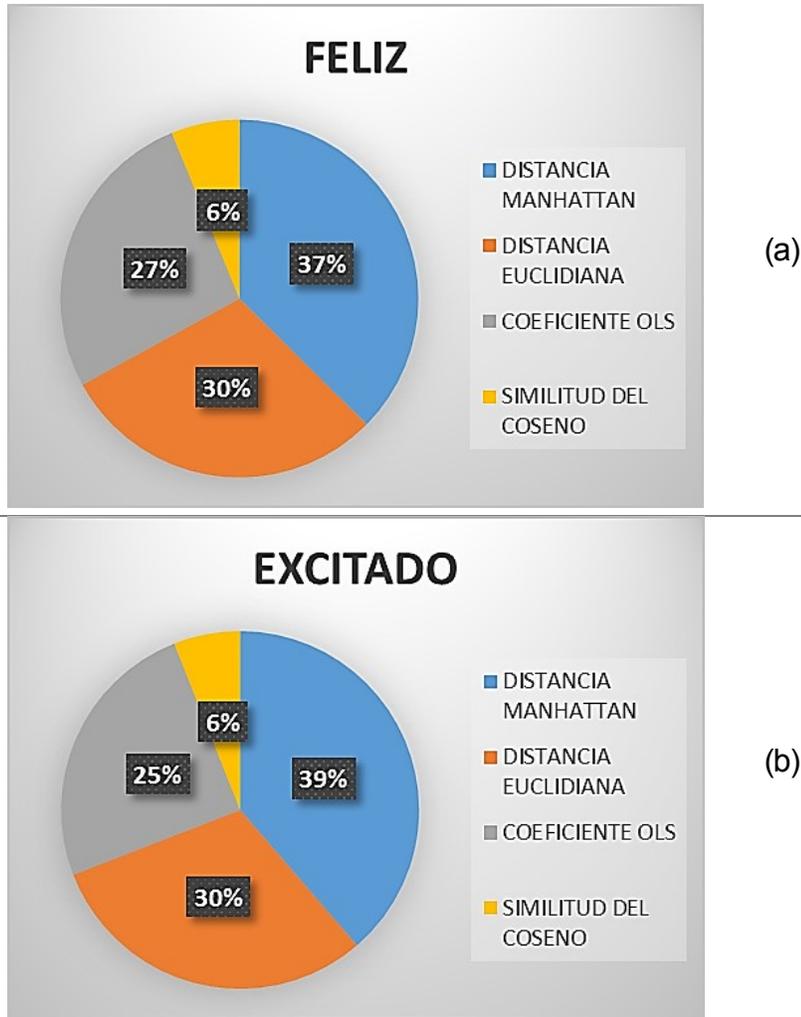
En la figura 5.5e) se muestra los resultados para el estado de ánimo de entrada “relajado”. Los resultados presentados en esta gráfica son algo similar a los anteriores resultados con rangos de diferencia entre los 0,01 y 0,16 en sus métricas de comparación, presentando levemente al S.R.2 con recomendaciones más adecuadas y con menor grado de dispersión en comparación al S.R.1, de acuerdo al estado de ánimo de entrada de usuario.

Después de un análisis con las desviaciones estándar para cada una de las métricas de comparación, se puede observar como el S.R.2 presenta recomendaciones de contenidos más precisas y con un menor grado de dispersión en comparación al S.R.1. Así, el recomendador propuesto puede ser una alternativa de solución al problema de arranque en frío y escasez de datos presente en los S.R. clásicos.

### *5.3.2.3 Análisis métricas de comparación*

El análisis de las métricas de comparación se llevó a cabo con la diferencia entre los resultados obtenidos en las pruebas realizadas al S.R. clásico y S.R. basado en contexto, esto con el fin de evaluar y distinguir mayor diferencia en los resultados e información relevante con cada una de las métricas de comparación, de acuerdo al estado de ánimo de entrada de usuario. En la figura 5.6, es mostrada la representación de los resultados de comparación, con cada una de las siguientes métricas: distancia Manhattan, distancia Euclidiana, coeficiente OLS y similitud del Coseno; estas métricas fueron utilizadas en el análisis y pruebas de las secciones anteriores. En los gráficos de la figura 5.6, es utilizado el color azul para representación de la distancia Manhattan, naranja para la distancia

Euclidiana, gris para el coeficiente OLS y amarillo para la similitud del Coseno. Los datos presentados en el análisis de las métricas de comparación, son los porcentajes de diferencia entre el recomendador clásico y recomendador basado en contexto.



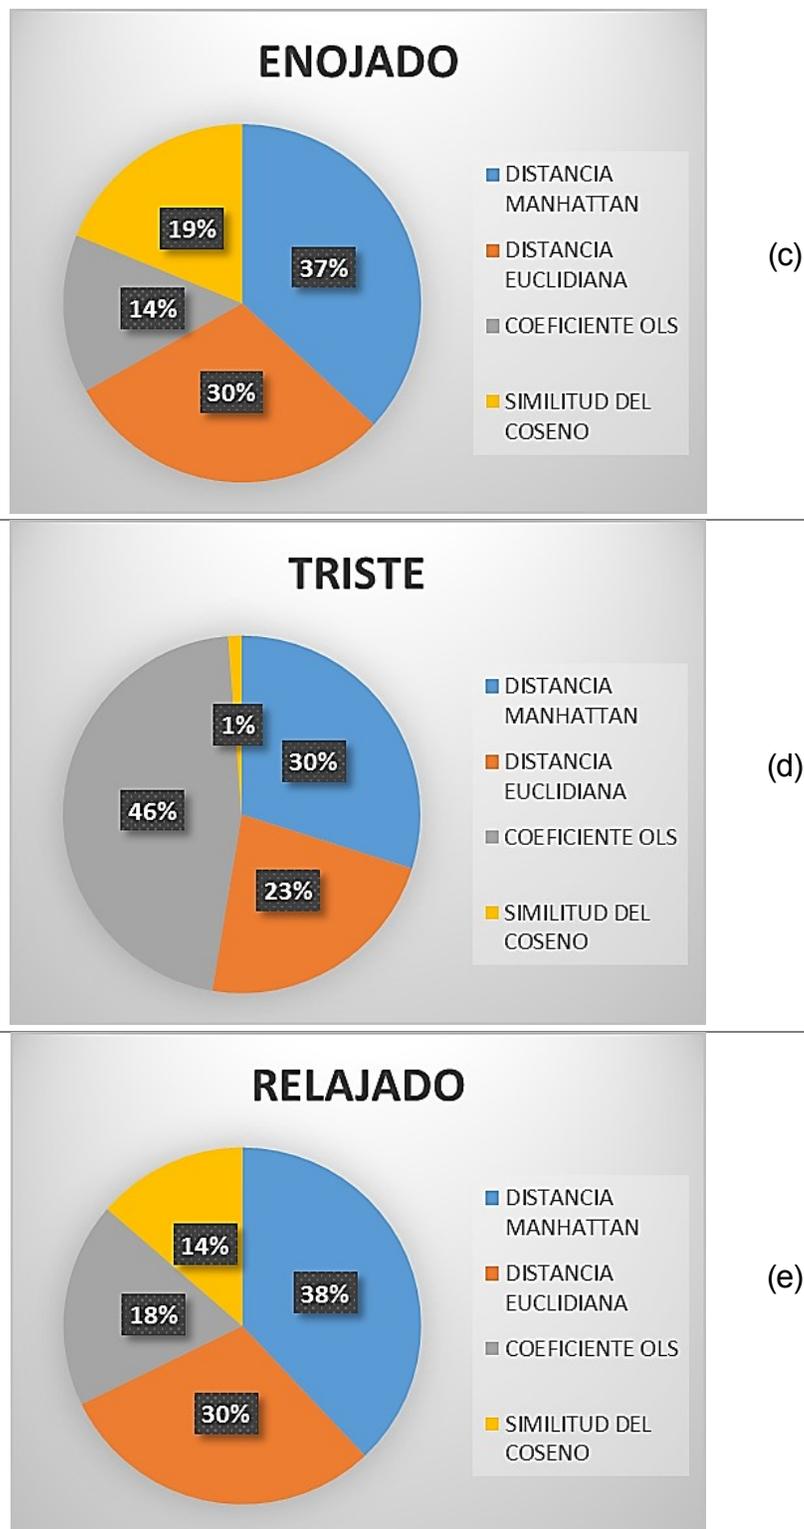


Figura 5.6 Análisis métricas de comparación, fuente: propia

En la figura 5.6a) es mostrado el porcentaje de similitud para cada una de las métricas de comparación sobre el estado de ánimo “feliz”. En esta gráfica la distancia Manhattan presenta el mayor valor de similitud, con un 37% frente a un 30% de la distancia Euclidiana, 27% del coeficiente OLS y 6% de la similitud del Coseno. En la figura 5.6b) son presentados los porcentajes para el estado “excitado”, con un 39% la distancia Manhattan frente a las demás (resultados similares a los anteriores). En la figura 5.6c) son mostrados los porcentajes para el estado “enojado”, con un 37% la distancia Manhattan frente a las demás las cuales mantienen menor grado de similitud. En la figura 5.6d) son observados los porcentajes para el estado de ánimo “triste”, donde el coeficiente OLS es la métrica con mayor porcentaje 46%, frente a un 30% de la distancia Manhattan, lo anterior encuentra explicación en el hecho de que la métrica del coeficiente OLS es un método no paramétrico, y fue el estado triste donde mayores valores presentó la métrica. En la figura 5.6e) son presentados los porcentajes asociados al estado de ánimo “relajado”, observándose como la distancia Manhattan conserva mayor porcentaje de similitud en comparación a las demás (resultados similares a los 3 primeros estados).

Después de analizar cada una de las gráficas anteriores, es posible concluir como la métrica de distancia Manhattan es el método de comparación lineal con mayor porcentaje de similitud en cada uno de los estados de ánimo de entrada analizados en el presente trabajo de grado. Así, esta métrica permite mayor comprensión, diferencia y análisis entre distintos S.R., y puede ser considerada como una buena métrica de evaluación frente a los demás métodos de comparación utilizados.

## 5.4 Pruebas de carga y estrés

Para evaluar el servidor de procesamiento, servidor de contexto y el sistema hardware-software “Arduino Yún”, se ha hecho uso de la herramienta apache benchmarking<sup>22</sup> la cual permite evaluar su rendimiento al proporcionarle un número determinado de conexiones o peticiones y observar el tiempo de respuesta del aplicativo. Las características de los equipos utilizados y a los cuales se les realizaron las pruebas son: computador (procesador i7 de 2.4-3.4 GHz, 16 GB Ram, 1 TB disco duro), Arduino Yún (procesador Atheros AR9331, Ram 64 MB, velocidad del reloj 16 MHz).

### 5.4.1 Servidor de Procesamiento

En la figura 5.7 se encuentra la representación de la prueba de carga realizada al servidor de procesamiento, el cual es el encargado de generar la lista de recomendaciones al usuario

---

<sup>22</sup> Herramienta para el análisis del rendimiento de servidores, apache benchmarking página web: <https://httpd.apache.org/docs/2.4/programs/ab.html>.

de acuerdo a su perfil. En ella son realizadas 200 conexiones secuenciales y 200 simultáneas, con valores de concurrencia en múltiplos de 10 hasta completar el número de conexiones.

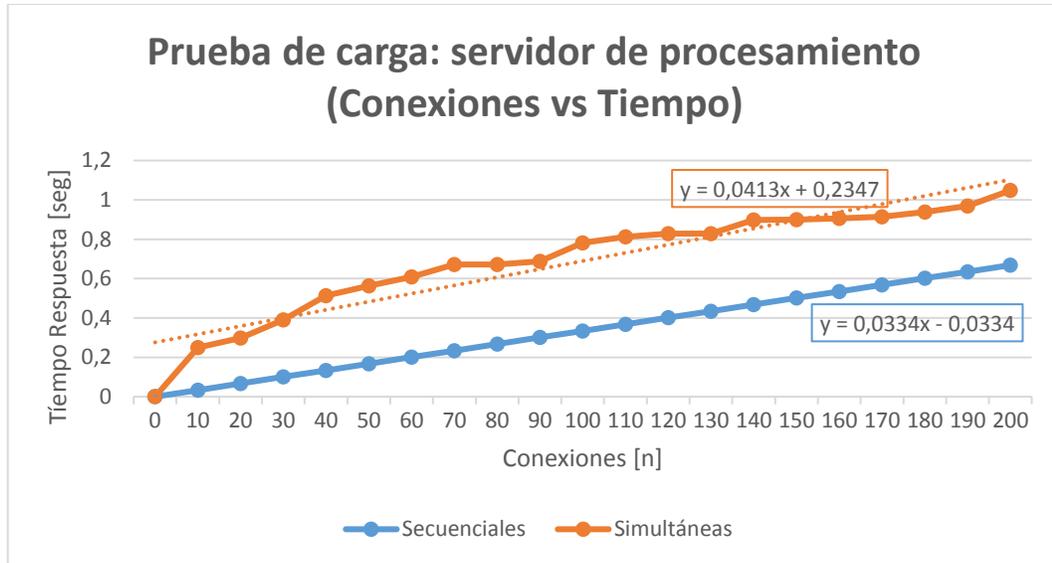


Figura 5.7 Pruebas de carga, servidor de procesamiento, fuente: propia

En la figura 5.7 se observa la gráfica donde son mostradas las conexiones secuenciales y simultáneas vs tiempo de respuesta, donde la conexiones simultáneas presentan los picos más altos de tiempo en comparación con la realizadas de forma secuencial, con un tiempo máximo de 1.04 segundos para 200 solicitudes simultaneas, mientras tanto para el mismo valor en secuenciales se tiene un tiempo de 0.66 segundos, verificándose con las líneas de tendencia y pudiendo prever como a un mayor número de conexiones simultáneas el servidor aumenta el tiempo de respuesta, debido a que la capacidad de procesamiento tiende a crecer por el número de conexiones a resolver.

Para establecer el valor máximo de conexiones a soportar por parte del servidor de procesamiento son realizadas las pruebas de estrés, las cuales se registran en la figura 5.8, para dicha medida fueron realizadas múltiplos de 1000 conexiones simultaneas y con el mismo número en la concurrencia, viéndose reflejado el tope máximo en 16000 solicitudes simultáneas, para un tiempo máximo de respuesta de 180.1 segundos en resolver las conexiones. Entretanto para las solicitudes secuenciales se alcanzó un tope de 20000 con un tiempo de 121.8 segundos.

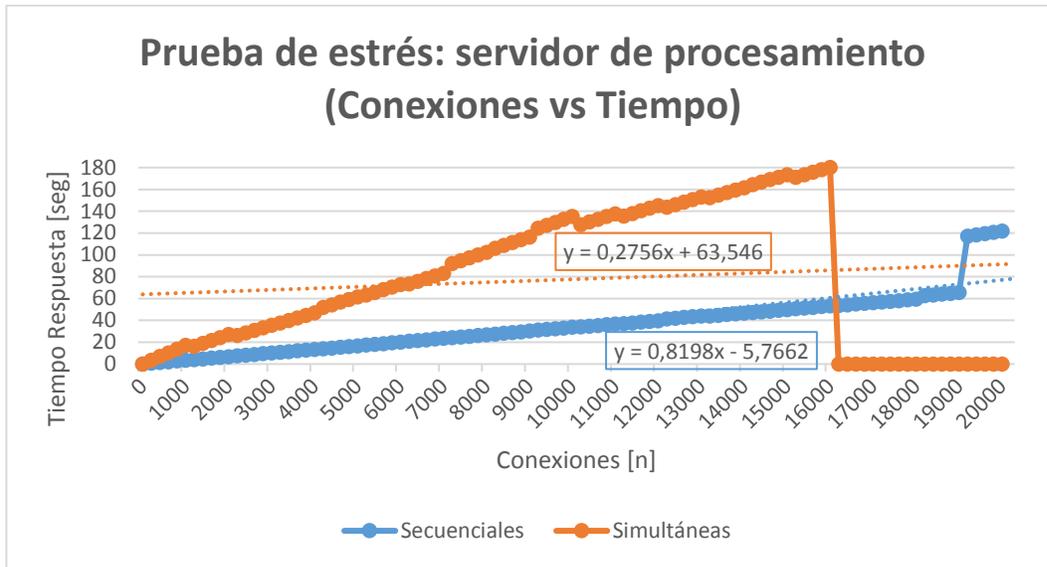


Figura 5.8 Pruebas de estrés, servidor de procesamiento, fuente: propia

### 5.4.2 Servidor de contexto

El módulo servidor de contexto es el encargado del procesamiento de los datos relacionados con las variables fisiológicas, utilizados por el S.R. basado en contexto para determinar el estado de ánimo de entrada de usuario. Con el fin de evaluar la capacidad de respuesta ante múltiples conexiones al sistema, se realizaron pruebas de carga y estrés al servidor de contexto. En la figura 5.9 es presentada la representación de los datos y la interpretación de las pruebas de carga al servidor de contexto, en las cuales fueron realizadas 200 conexiones de manera secuencial y simultánea.

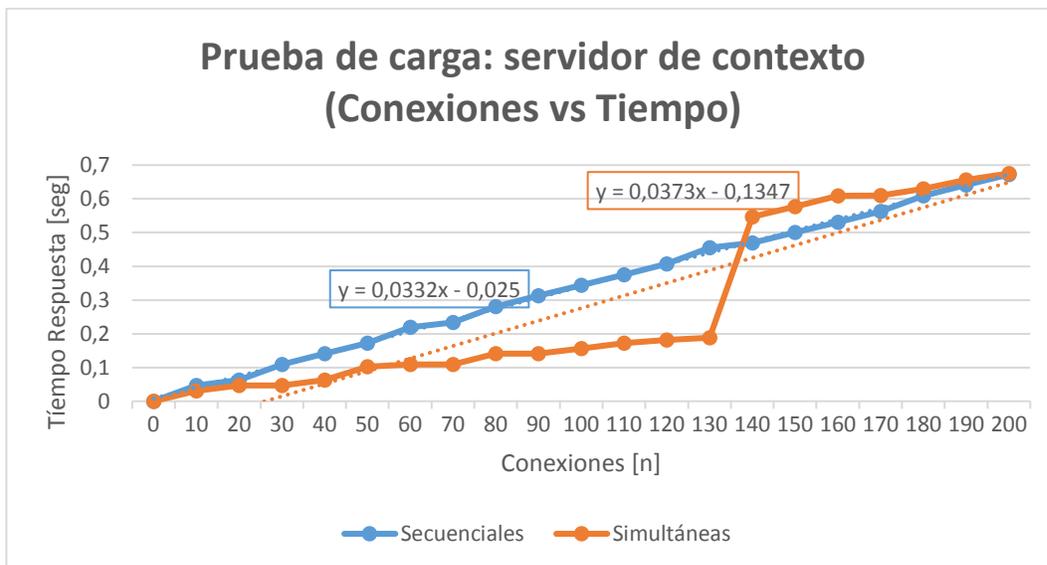


Figura 5.9 Pruebas de carga, servidor de contexto, fuente: propia

En la figura 5.9, es mostrado el tiempo empleado en segundos para 200 conexiones secuenciales en color azul y simultaneas en color rojo. Según la representación de los datos el tiempo empleado por el servidor de contexto con 200 conexiones secuenciales, oscila entre 0,050 y 0,675 segundos, presentando un crecimiento gradual a medida que aumenta la carga por medio de las conexiones. El tiempo empleado por el servidor de contexto con 200 conexiones simultáneas, oscila entre 0,030 y 0,675 segundos, presentando un buen rendimiento en las primeras 130 conexiones iniciales, y luego un aumento significativo en el tiempo de respuesta debido a la carga de las conexiones.

Las pruebas de estrés al servidor de contexto se llevaron a cabo con 20000 conexiones secuenciales y simultáneas, hasta lograr que el sistema colapsará. En la figura 5.10 se presenta la representación de los datos con respecto a las pruebas de estrés al servidor de contexto.

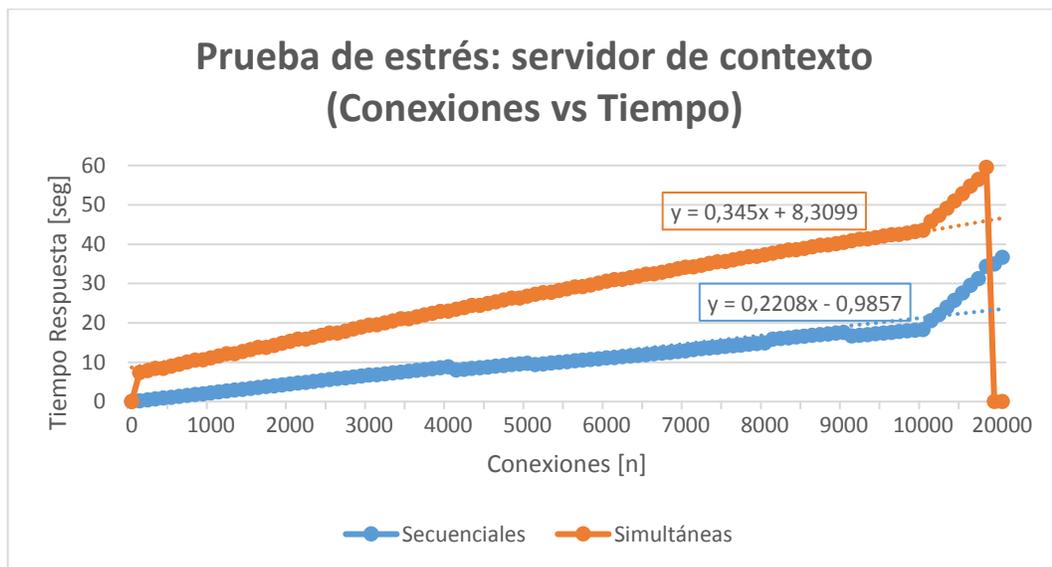


Figura 5.10 Pruebas de estrés, servidor de contexto, fuente: propia

En la figura 5.10 son presentadas las pruebas de estrés realizadas al servidor de contexto, para ello es mostrado el tiempo empleado en segundos para 20000 conexiones secuenciales en color azul, y simultáneas en color rojo. Según la representación de los datos el tiempo empleado por el servidor de contexto para responder a 20000 conexiones secuenciales, oscila entre 0 y 36 segundos, presentando un mayor consumo de recursos entre las 10000 y 20000 conexiones secuenciales, aun así no colapsa el sistema. El tiempo empleado por el servidor de contexto para responder a 20000 conexiones simultáneas o concurrentes, oscila entre 7 y 62 segundos, luego de las 18000 conexiones el sistema colapsa debido al excesivo número de conexiones y el estrés de capacidad presente en el servidor.

A modo de conclusión, el servidor de contexto presenta buena capacidad de procesamiento de acuerdo a las pruebas de carga y estrés realizadas, soportando una capacidad de más de 20000 conexiones secuenciales y un poco menor si son simultáneas. Además, el tiempo estimado de respuesta a las primeras 200 conexiones no excede un segundo. Finalmente, el servidor de contexto encargado del procesamiento de datos fisiológicos de usuarios, presenta un buen rendimiento y tiene la capacidad de responder a un consumo adecuado del S.R. basado en contexto, a través del servicio de VoD.

### 5.4.3 Sistema hardware-software (Arduino Yún)

Para el sistema hardware-software las pruebas de carga sufrieron un leve cambio, puesto que en este caso se efectuaron las conexiones sin concurrencia, debido a la baja capacidad de procesamiento con la cual cuenta este dispositivo. A la tarjeta Arduino se le realizaron con ayuda de herramienta apache benchmark conexiones en múltiplos de 10, hasta un total de 200, evidenciándose plenamente una gran variación en los tiempos de respuesta presentándose los picos de tiempo más altos en la prueba con 10 y 180 conexiones, en un tiempo de 1.407 segundos para ambos casos, para efectuar la respuesta (ver figura 5.11).

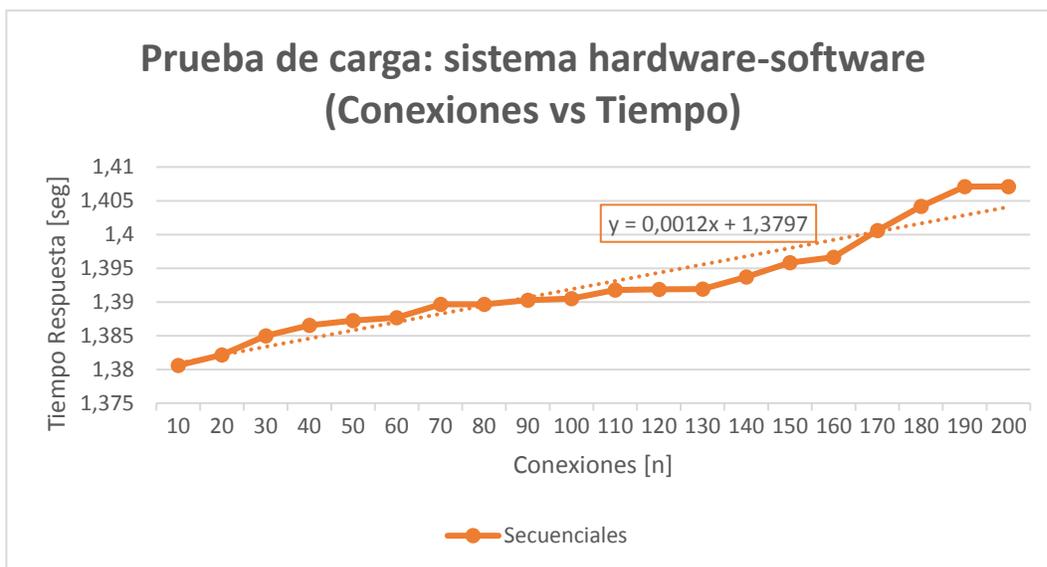


Figura 5.11 Pruebas de carga, sistema hardware-software, fuente: propia

Con el fin de probar los límites del dispositivo Arduino en cuanto a rendimiento en el procesamiento de las solicitudes, se llevaron a cabo pruebas de estrés, en donde fueron realizadas 200 conexiones con distintos valores de concurrencia (10,20,30,40,50,60), en donde cuyo límite es de 60 solicitudes simultáneas, con un tiempo de respuesta efectuado a los 99.4 segundos (ver figura 5.12). En donde la línea de tendencia evidencia una subida

en los tiempos de procesamiento de las solicitudes, esforzando al máximo de su capacidad a dicho módulo.

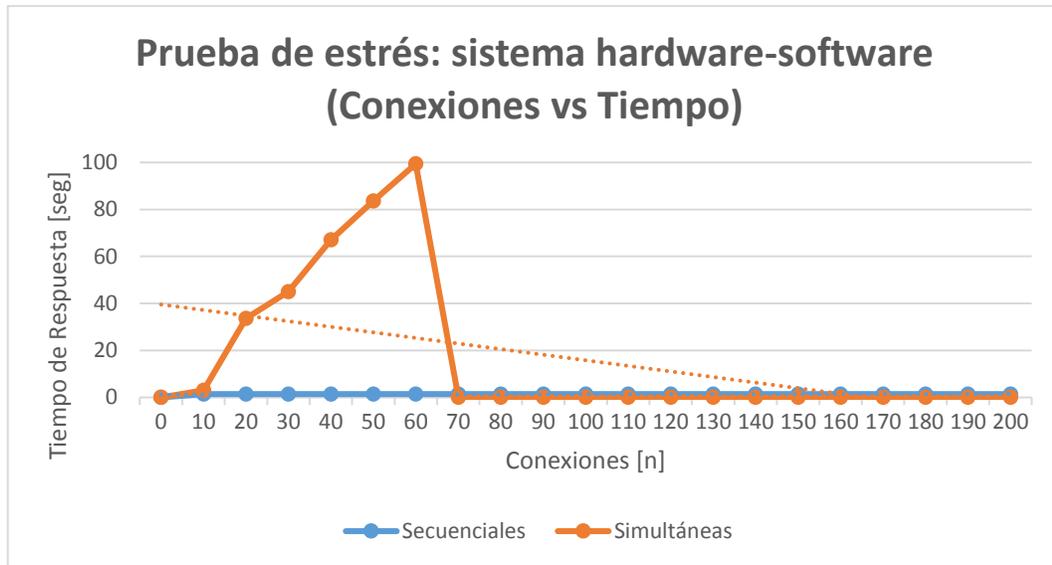


Figura 5.12 Pruebas de estrés, sistema hardware-software, fuente: propia

Como conclusiones finales, sobre las pruebas de carga y estrés realizadas, es de gran importancia a la hora de mirar donde alojar las aplicaciones, de contar con equipos con una muy buena capacidad de procesamiento. Para motivos de este proyecto, la maquina utilizada como servidor de procesamiento tiene muy buenas especificaciones al contar con una memoria ram de 16 G y un procesador con un rango de procesamiento entre los 2.4 y 3.4 GHz, lo cual se evidenció al realizar las pruebas de estrés, además dichas pruebas permiten indicar como Spark puede ser una buena opción para su uso como servidor de procesamiento en tiempo real, cuyo tiempo promedio para efectuar respuesta a las conexiones simultáneas es de 0.7 segundos. De las pruebas de estrés realizadas al servidor de contexto, es posible concluir como el uso de flask es una opción viable para desempeñar dicha función. En cuanto al módulo de Arduino, aunque presenta una capacidad mucho más baja de procesamiento con 400Mhz, su rendimiento es alto, ya que su límite es de 200 conexiones con 60 simultáneas y para motivos de este proyecto cada módulo Arduino será personal, es decir las conexiones solo las hará un usuario en específico.



## Capítulo 6

### Conclusiones, trabajos futuros y otros

En este capítulo son presentadas las conclusiones del trabajo de grado, teniendo en cuenta los objetivos propuestos. Además de lo anterior, se plantean trabajos futuros para quienes deseen abordar y continuar con investigaciones en el ámbito de los S.R. e Internet de las cosas. Adicionalmente son mostradas las publicaciones en eventos y revistas, producto del desarrollo y ejecución de este trabajo.

#### 6.1 Conclusiones

- Las características musicales como el *arousal* y la *valence* posibilitan la clasificación de contenidos multimedia en el espacio cartesiano de las emociones. Lo anterior permite agilizar el acceso a los contenidos multimedia del servicio de VoD, en el sentido que se personalizan las preferencias del usuario a partir de una emoción de entrada. Cabe aclarar, estas características son obtenidas de forma más efectiva cuando el análisis se hace en el orden de los segundos a todas las pistas musicales.
- El *dataset* de contenidos multimedia de video propuesto, constituye un aporte importante para el diseño e implementación de servicios de video basados en emociones, integrando las ventajas del *dataset* musical de Echonest y la información de video provista por la API de youtube. Así mismo, el modelo de clasificación de emociones presentado en la sección 2.6.1 puede ser considerado para el desarrollo de servicios de contenidos multimedia basados en emociones, tales como: sistemas de recomendaciones, buscadores servicios publicitarios, entre otros.
- La herramienta Java para la clasificación de contenidos musicales desarrollada y presentada en la sección 2.6.2, permitió verificar la correcta clasificación en el proceso de conformación del *dataset* de contenidos musicales de video. Así mismo, esta herramienta hizo posible evaluar la pertinencia del modelo de clasificación de contenidos propuesto en la sección 2.6.1.
- El uso de las API's provistas por Echonest para los lenguajes Python y Java, permitió evidenciar como estas son una buena alternativa en la implementación de servicios, los cuales consideren la relación de contenidos multimedia con modelos emocionales. Lo anterior, tiene fundamento en las librerías las cuales permiten acceder a un conjunto

relevante de características musicales, sin restricciones a nivel de la cantidad de consultas realizadas.

- Variables del contexto de usuario tales como las medidas fisiológicas (VFC, EMG y RGP), a diferencia de las variables tradicionales utilizadas en los S.R., éstas permiten enriquecer los métodos de entrada, y brindar información personal del usuario más adecuada de acuerdo al comportamiento emocional en un determinado estado de tiempo; esto permite aportar a la solución de arranque en frío presente en los S.R.
- La variable VFC se convierte en parte fundamental del sistema construido, ya que esta hace posible el cálculo del índice de estrés y a su vez establecer el nivel de *arousal* de entrada del usuario, el cual puede asociarse al modelo de 5 emociones diseñado en la sección 2.6.1.
- La variable EMG es de gran importancia para el sistema construido, pues es la medida que posibilita el cálculo de la *valence* considerada en el modelo de 5 emociones presentado en la sección 2.6.1. Esta variable junto con la VFC permite establecer la emoción de usuario presente mientras interactúa con el servicio.
- La variable RGP al estar asociada directamente con el nivel de *arousal* de una persona, es usada por el S.R. como filtro, en el sentido de permitir reordenar la lista de recomendaciones obtenida a partir de la VFC y EMG, teniendo en cuenta si el usuario presenta un aumento o disminución en su nivel de *arousal*.
- La plataforma Arduino Yún permitió capturar de manera adecuada, las señales de los sensores: pulso cardíaco, Grove y MyoWare, los cuales proporcionan los datos fisiológicos del usuario para el cálculo del índice de estrés, y la obtención de los parámetros: *arousal* y *valence*.
- En este trabajo se presentó la implementación de un nuevo clasificador basado en el algoritmo de Naive Bayes, el cual tiene en cuenta los parámetros musicales como medio para la predicción de contenidos multimedia. Así, a partir de los resultados obtenidos se puede concluir lo siguiente, este clasificador es conveniente para el uso en la implementación de los S.R., los cuales tengan en cuenta variables del contexto y las valoraciones hechas por los usuarios sobre los ítems o contenidos, lo cual ayudo a predecir la evaluación de nuevos contenidos para los usuarios.
- La herramienta Weka permite la ejecución de algoritmos de minería de datos, en este trabajo, esta herramienta se utilizó para la implementación del clasificador bayesiano,

encargado de la clasificación y predicción de contenidos multimedia a través del algoritmo de Naive Bayes. Así mismo, esta herramienta facilitó la implementación del clasificador, por medio de la API de Weka para el lenguaje Java.

- En este trabajo se propuso un servidor de procesamiento basado en la herramienta Weka, el cual permitió un análisis y procesamiento ágil de los datos, en cada una de las recomendaciones. Además, este servidor utilizó JSON como formato de comunicación con el servidor de lógica, lo cual facilita y mejora el tiempo en procesar la información.
- El servicio de VoD basado en emociones desarrollado, hace uso de herramientas hardware y software libre, permitiendo la escalabilidad, asequibilidad y plantea las bases para futuros proyectos de investigación en miras a brindar mejoras al sistema, lo cual posibiliten llevarlo a un mercado real.
- Los S.R. propuestos, así como los algoritmos usados para su diseño e implementación, pueden ser adaptados y aplicados en otros escenarios como son: Televisión Digital Terrestre y Televisión Móvil. Lo anterior, tiene fundamento en los estándares con los cuales se trabajan en estos escenarios, además, estos presentan ciertos problemas en el acceso a los contenidos multimedia (salto de canal, gran cantidad de contenidos).
- De acuerdo a los resultados presentados en la sección 5.2 con respecto a las pruebas del S.R. Clásico y el clasificador bayesiano, éstos presentan valores adecuados de precisión promedio de 99,86% en las recomendaciones que el S.R. provee al usuario, de acuerdo a las valoraciones de contenidos multimedia realizadas por los mismos usuarios. Lo anterior, permite concluir como el clasificador bayesiano implementado en la sección 4.5.1, es un adecuado recomendador y el cual puede utilizarse en presentes y actuales S.R. clásicos e híbridos.
- De acuerdo a los resultados de las secciones 5.3.2.1 y 5.3.2.2 con respecto a las pruebas de evaluación del S.R. basado en contexto en comparación al S.R. clásico, se puede observar como las recomendaciones del S.R. basado en contexto, son más precisas de acuerdo a la emoción de entrada del usuario. Lo anterior permite validar al S.R. basado en contexto, propuesto en el presente trabajo de grado, como una alternativa de solución al problema de arranque en frío y escasez de datos para recomendar, presente en los S.R. clásicos.
- El S.R. basado en contexto desarrollado y presentado en la sección 4.5, permitió evidenciar que las recomendaciones son más adecuadas y precisas de acuerdo a la emoción de entrada de usuario en comparación al S.R. clásico, además estas posibilitan

un acceso ágil al contenido multimedia cuando se considera las variables del contexto de usuario como parámetros de entrada.

- Las pruebas de carga realizadas al servidor de procesamiento evidencian un tiempo promedio de 0.7 segundos en efectuar una carga de 200 conexiones con distintos valores de concurrencia, mostrando un buen rendimiento, lo cual permite concluir que, si se desea en un futuro prestar un servicio eficiente, es necesario hacer uso de equipos robustos dotados con mejores especificaciones, y esto se podría llevar a un mercado mucho más amplio y exigente.
- En las pruebas de carga realizadas al módulo Arduino Yún, aunque no está capacitado para soportar grandes cantidades de tráfico y procesamiento, este módulo será de uso personal y por ende solo será utilizado por un usuario a la vez. De igual manera, este presenta un buen rendimiento al poder soportar una carga de 200 conexiones sin concurrencia con un tiempo promedio de respuesta de 1.3 segundos. Así, es posible concluir para estudios posteriores, se deben generar y emplear módulos que permitan la captura de variables de un núcleo específico de personas al mismo tiempo.
- En la sección 3.7 se diseñó y construyó el sistema hardware-software encargado de la captura de variables fisiológicas, y el cual permitió proveer de más parámetros de entrada, al S.R. basado en contexto. En la sección 3.8 es presentada la adaptación del método de inferencia emocional, teniendo como base el contexto de usuario, el cual facilitó las recomendaciones de contenidos multimedia por parte del S.R teniendo como referencia las características del contenido. En la sección 4.5.2 es mostrado el servicio de VoD encargado de proveer de contenidos de video al S.R., el cual proporcionó y facilitó un consumo adecuado de los videos.
- En conclusión, para hacer énfasis en el cumplimiento de los objetivos específicos (O.E.) los cuales se llevaron a cabo a lo largo del trabajo de grado. Se organiza de la siguiente manera, teniendo en cuenta cada capítulo que integra el presente documento: En el capítulo 2, es generado el *dataset* de contenidos multimedia afectivos, del cual hace uso el servidor de procesamiento, con el cual se cumple el O.E.1. En el capítulo 3 es realizado la adaptación del método de inferencia, el cual permitió el reconocimiento del estado emocional del usuario, dando por cumplido el objetivo O.E.2. En el capítulo 4 es presentado el S.R. basado en contexto el cual se encarga de clasificar y recomendar contenidos de video al usuario, cumpliéndose el O.E.3, finalmente en el capítulo 5 es evaluado el S.R. propuesto frente a mecanismos de recomendación clásicos, presentando favorablemente valores de evaluación adecuados y un funcionamiento óptimo a través del servicio de VoD desarrollado.

## 6.2 Trabajos futuros

- Se considera realimentar el contexto de usuario vinculando más variables tanto fisiológicas como son: la respiración, temperatura, etc. Y medidas biométricas tales como la voz, detección de rostro, entre otras; en miras a que permita enriquecer su perfil y de esta manera el S.R. sugiera contenido relevante a cada consumidor con una mayor eficiencia.
- Es planteada la posibilidad de vincular los resultados del S.R. con las características físicas del dispositivo y el tipo de red desde la cual van a ser consumidos los servicios, de tal manera se tengan contenidos y servicios adaptativos vinculando el estándar DASH para el streaming sobre http y con esto modular la tasa binaria del video en función del estado de la red.
- Se propone como mecanismo para el análisis de las características del contenido en cuanto a las variables del *arousal* y la *valence*, extender el modelo emocional de los contenidos multimedia, considerando el análisis sobre las letras de las canciones.
- Como el contenido de video tiene una gran variedad de tipos, es propicio considerar como trabajo futuro el empleo y análisis emocional de todos estos contenidos, permitiendo diversidad de temáticas a ofrecer en el servicio de VoD al usuario.
- Se propone en un trabajo futuro, la integración del S.R. con otros parámetros de entrada como lo es la información que circula por las redes sociales; además, poder conformar un dataset más dinámico con contenidos multimedia más regionales.
- Se considera el uso de dispositivos tales como: el sensor encefalográfico convencional, el cual es mucho más preciso y sofisticado en la toma de las medidas; además, podría a ayudar a limitar los costos y desarrollos del proyecto.
- Como trabajo futuro se considera la migración de los servidores de lógica y procesamiento a servidores en la nube, lo cual podría mejorar los tiempos de respuesta y capacidad del sistema.
- Finalmente, sería conveniente como trabajo futuro, orientar el S.R. a mejoras de la salud y hábitos en las personas, así evitar problemas o enfermedades comunes como: el estrés, migraña, entre otros.

## 6.3 Publicaciones

### 6.3.1 Publicaciones en Congresos

- Artículo, Short Paper. Solarte, L.A., Sánchez, M., Chanchí, G.E., Durán, D.F., and Arciniegas J.L. “*Propuesta de un sistema de recomendaciones basado en contexto para contenidos multimedia*”. 11 Congreso Colombiano de Computación (11CCC). Septiembre 27 al 30 de 2016. Popayán, Colombia. Estado: Aceptado.

### 6.3.2 Publicaciones en Revistas

- Solarte, L.A., Sánchez, M., Chanchí, G.E., Durán, D.F., and Arciniegas J.L. “*Dataset de contenidos musicales de video, basado en emociones*”. Revista de Ingenierías USBMED: “Ingeniería, Ciencia, Tecnología e Innovación”. Vol. 7, Núm. 2 (2016). Universidad de San Buenaventura. Medellín, Colombia. Indexada tipo C. Estado: Publicado.
- Solarte, L.A., Sánchez, M., Chanchí, G.E., Durán, D.F., and Arciniegas J.L. “*Sistema Hardware-Software para reconocimiento de emociones a partir de señales fisiológicas*”. Revista Ingeniería Biomédica. Vol. 10, Núm. 20 (2016). Escuela de Ingeniería de Antioquia -EIA- Universidad CES. Medellín, Colombia. Indexada tipo B. Estado: En revisión.
- Solarte, L.A., Sánchez, M., Chanchí, G.E., Durán, D.F., and Arciniegas J.L. “*Servicio de video bajo demanda basado en emociones*”. Revista Sistemas & Telemática. Vol. 14, Núm. 38 (2016). Universidad ICESI. Cali, Colombia. Indexada tipo C. Estado: En revisión.

## 6.4 Registros Software

- “*Sistema de recomendaciones para el servicio de VoD, basado en la inferencia de emociones a partir de variables del contexto de usuario*”. Dirección Nacional de Derecho de Autor (DNDA). Libro 13, Tomo 54, Partida 128. 6 de Julio de 2016. Bogotá, Colombia. Número de radicación: 1-2016-48635.
- “*Dataset de contenidos musicales de video, basado en emociones*”. Dirección Nacional de Derecho de Autor (DNDA). Libro 13, Tomo 54, Partida 129. 6 de Julio de 2016. Bogotá, Colombia. Número de radicación: 1-2016-48909.

## Bibliografía

- [1] J. Altgeld y D. Z. John, «The IPTV/VoD Challenge: Upcoming Business Models,» de *Achieving the Triple Play: Technologies and Business Models for Success*, Intl. Engineering Consortiu, 2006, p. 3.
- [2] O. D. Torres, «Evolución y tendencia de la tecnología de streaming en internet,» *FACE - UNNE*, p. 8, 2009.
- [3] L. J. Klein Z, «Vimeo,» [En línea]. Available: <https://vimeo.com/18487974>. [Último acceso: 23 02 2016].
- [4] C. Greco y I. Nemoianu, «Multimedia Streaming,» de *Academic Press Library in signal Processing*, Paris, ELSEVIER, 2014, p. 327–381.
- [5] W. Simpson y H. Greenfield, *IPTV and internet video*, Oxford: Elsevier, 2009.
- [6] Cisco VNI, «Cisco Visual Networking Index: Forecast and Methodology,» Cisco, 27 Mayo 2015. [En línea]. Available: [http://www.cisco.com/c/en/us/solutions/collateral/service-provider/ip-ngn-ip-next-generation-network/white\\_paper\\_c11-481360.html](http://www.cisco.com/c/en/us/solutions/collateral/service-provider/ip-ngn-ip-next-generation-network/white_paper_c11-481360.html). [Último acceso: 02 Julio 2015].
- [7] A. Lobo, R. García, X. G. Pañeda, D. Melendi y S. Cabrero, «Modeling Video on Demand services taking into account statistical dependences in user behavior,» *Simulation Modelling Practice and Theory*, vol. 31, nº 1569-190X, pp. 96-115, 2013.
- [8] D. Jannach, M. Zanker, A. Felfernig y G. Friedrich, *Recommender Systems: An Introduction*, Cambridge, 2010.
- [9] L. Chen, Y. Zhou y D. M. Chiu, «A study of user behavior in online VoD services,» *Computer Communications*, vol. 46, nº 0140-3664, pp. 66-75, 15 June 2014.
- [10] K. Pripuzic, I. Zarko, V. Podobnik, I. Lovrek, M. Cavka, I. Petkovic, P. Stulic y M. Gojceta, «Building an IPTV VoD Recommender System: An Experience Report,» *Telecommunications (ConTEL)*, 2013 12th International Conference on, pp. 155-162, 2013.
- [11] M. Dabrowski, J. Gromada y H. Moustafa, «Context-Awareness for IPTV Services Personalization,» *Innovative Mobile and Internet Services in Ubiquitous Computing (IMIS)*, 2012 Sixth International Conference on, pp. 37-44, 2012.
- [12] E. Perik, B. Ruyter, P. Markopoulos y B. Eggen, «The sensitivities of user profile information in music recommender systems,» de *In Proceedings of Private, Security, Trust*, 2004, pp. 137-141.
- [13] F. Ricci, L. Rokach, B. Shapira y P. Kantor, *Recommender System Handbook*, Springer, 2010.

- [14] Z. Yujie y W. Licai, «Some challenges for context-aware recommender systems,» de *Computer Science and Education (ICCSE), 2010 5th International Conference on*, Hefei, China, 2010.
- [15] D. Asanov, «Algorithms and Methods in Recommender Systems,» Berlin Institute of Technology, Berlin, Germany, 2011.
- [16] B. Barragáns Martínez, E. Costa Montenegro y J. Juncal Martínez, «Developing a recommender system in a consumer electronic device,» *Expert Systems with Applications*, Vols. %1 de %242, Issue 9, nº 0957-4174, pp. 4216-4228, 2015.
- [17] D. Gallego Vico, G. Huecas y J. Salvachúa Rodríguez, «Generating context-aware recommendations using banking data in a mobile recommender system,» de *The Sixth International Conference on Digital Society*, Valencia, Spain, 2012.
- [18] K. Chapphannarungsri y S. Maneeroj, «Combining Multiple Criteria and Multidimension for Movie Recommender System,» de *Proceedings of the International MultiConference of Engineers and Computer Scientists 2009 Vol I, March 18 - 20*, Hong Kong, 2009.
- [19] A. Kosir, J. Tasic, A. Odic y M. Tkalic, «Relevant context in a movie recommender system : users' opinion vs. statistical detection,» de *WOODSTOCK '97 El Paso*, Texas, USA, 2012.
- [20] A. Thawani, S. Gopalan y V. Sridhar, «Context Aware Personalized Ad Insertion in an Interactive TV Environment,» de *4th Workshop on Personalization*, 2004.
- [21] M. N. Moreno y e. al., «Web mining based framework for solving usual problems in recommender systems. A case study for movies' recommendation,» *Neurocomputing*, 2015.
- [22] M. Baldauf, S. Dustdar y F. Rosenberg, «A survey on context-aware systems,» *International Journal Ad Hoc and Ubiquitous Computing*, Vols. %1 de %22, Issue 4, pp. 263-277, 2007.
- [23] G. Adomavicius y A. Tuzhilin, «Context-Aware Recommender Systems,» de *Proceedings of the 2008 ACM conference on Recommender systems*, New York, USA, 2008.
- [24] X. Wang, D. Rosenblum y Y. Wang, «Context-aware mobile music recommendation for daily activities,» de *MM '12 Proceedings of the 20th ACM international conference on Multimedia* , New York, NY, USA, 99-108.
- [25] J.-H. Su, H.-H. Yeh, P. Yu y V. Tseng, «Music Recommendation Using Content and Context Information Mining,» *Intelligent Systems, IEEE*, vol. 25, nº 1, pp. 16-26, 2010.
- [26] S. Song, H. Moustafa y H. Afifi, «IPTV Services Personalization Using Context-Awareness,» *Informatica*, pp. 13-20, 2011.
- [27] H. S. Park, J. O. Yoo y S. Bae, «A Context-Aware Music Recommendation System Using Fuzzy Bayesian Networks with Utility Theory,» *Fuzzy Systems and Knowledge Discovery*, vol. 4223, pp. 970-979, 2006.
- [28] I. Fjørtoft, B. Kristoffersen y J. Sageie, «Children in schoolyards: Tracking movement patterns and physical activity in schoolyards using global positioning system and heart rate monitoring,» *Landscape and Urban Planning*, Vols. %1 de %293, Issues 3-4, nº 0169-2046, pp. 210-217, 2009.

- [29] M. Viqueira Villarejo, B. García Zapirain y A. Méndez Zorrilla, «A Stress Sensor Based on Galvanic Skin Response (GSR) Controlled by ZigBee,» *Sensors*, vol. 12, n° 1424-8220, pp. 6075-6101, 2012.
- [30] J. H. D. M. Westerink, E. L. Van den Broek, M. H. Schut, J. van Herk y K. Tuinenbreijer, «Computing Emotion Awareness Through Galvanic Skin Response and Facial Electromyography,» de *Probing Experience*, vol. 8, Holanda, Springer, 2008, pp. 149-162.
- [31] K. Patil, M. Singh, G. Singh, Anjali y N. Sharma, «Mental stress evaluation using heart rate variability analysis: A Review,» *International Journal Of Public Mental Health And Neurosciences*, vol. 2, n° 2394-4668, 2015.
- [32] S. Rho, B. j. Han y E. Hwang, «SVR-based music mood classification and context-based music recommendation,» de *Proceedings of the 17th ACM International Conference on Multimedia*, Beijing, China, 2009.
- [33] T. Sharma y B. Kapoor, «Intelligent data analysis algorithms on biofeedback signals for estimating emotions,» de *International Conference on Reliability, Optimization and Information Technology*, Baddi, India, 2014.
- [34] C. Serrano, «Modelo integral para el profesional en ingeniería,» Universidad del Cauca, Popayán, 2005.
- [35] J. A. Rivera Guerra, «redalyc,» 2011. [En línea]. Available: <http://www.redalyc.org/articulo.oa?id=94419100008>. [Último acceso: 3 Marzo 2016].
- [36] Y. Yang y H. Chen, *Music Emotion Recognition*, Taiwan: CRC Press, 2011.
- [37] M. Jones y R. Fay, *Music Perception*, Ohio: Springer, 2010.
- [38] T. Jehan y B. Whitman, «The Echonest,» MIT Media Lab, Junio 2005. [En línea]. Available: <http://the.echonest.com/>. [Último acceso: 13 Enero 2016].
- [39] H. Chen y Y. Yang, *Music Emotion Recognition*, Taiwan: CRC Press, 2011.
- [40] P. Kleinginna y A. Kleinginna, «A Categorized List of Emotion Definitions, with Suggestions for a Consensual Definition,» de *Motivation and Emotion*, Georgia, Plenum Publishing Corporation, 1981, pp. 345-379.
- [41] J. Russell, «A Circumplex Model of Affect,» de *Personality and Social Psychology*, Vancouver , APA journals , 1980, pp. 1161-1178.
- [42] K. Hevner, «Experimental Studies of the Elements of Expression in Music,» de *The American Journal of Psychology*, Illinois, Jstor, 1936, pp. 246-268.
- [43] R. Plutchik, «The Nature of Emotions,» de *American Scientist*, Florida, American Scientist, 2001, pp. 344-350.
- [44] V. Castaignet y V. Frederic, «musicoverly,» 2006. [En línea]. Available: <http://musicoverly.com/api/doc/documentation.php>. [Último acceso: 2 Marzo 2016].

- [45] T. Jehan y B. Whitman, «The Echo nest,» MIT Media Lab, Junio 2005. [En línea]. Available: <http://the.echonest.com/>. [Último acceso: 13 Enero 2016].
- [46] T. Kan y S. Scherf, «Gracenote,» Tribune Media Company, 1998. [En línea]. Available: <https://developer.gracenote.com/web-api>. [Último acceso: 2 Marzo 2016].
- [47] J. Posner y J. Russell, «The circumplex model of affect: An integrative approach to affective neuroscience, cognitive development, and psychopathology,» de *Dev Psychopathol*, New York, NIH, 2005, p. 715–734.
- [48] O. Meyers, A Mood-Based Music Classification and Exploration System, Massachusetts: Massachusetts Institute of Technology, 2004.
- [49] X. Navarro, «Fisiología del sistema nervioso autónomo,» *Revista de neurología*, vol. XXXV, nº 6, pp. 553-562, 2002.
- [50] S. D. Kreibig, «Autonomic nervous system activity in emotion: A review,» de *Biological Psychology*, Geneva, ELSEVIER, 2010, p. 394–421.
- [51] J. E. Hall, Tratado de fisiología médica, Barcelona : ELSEVIER, 2011.
- [52] G. Roldas, «Archivos de Medicina del Deporte,» de *Variabilidad de la Frecuencia Cardíaca*, Barcelona, AMD, 2008, pp. 41-127.
- [53] S. Boonnithi y Phongsuphap, «Comparison of Heart Rate Variability Measures for Mental Stress Detection,» de *Computing in cardiology*, Bangkok, IEEE, 2011, pp. 85-88.
- [54] R. M. Bayevsky, G. G. Ivanov, L. V. Chireykin y e. al, «HRV analysis under the usage of different electrocardiography systems (Methodical recommendations),» de *Committee of New Medical Techniques of Ministry of Health of Russia*, Moscow, 2002.
- [55] C. Kappeler-Setz, Multimodal Emotion and Stress Recognition, Zurich: ETH ZURICH, 2012.
- [56] F.-T. Sun y C. Kuo, «Activity-Aware Mental Stress Detection Using Physiological Sensors,» de *Mobile Computing, Applications, and Services*, Santa Clara, Springer, 2012, pp. 211-230.
- [57] J. Bakker, M. Pechenizkiy y N. Sidorova, «What's your current stress level? Detection of stress patterns from GSR sensor data,» de *IEEE International Conference on Data Mining Workshops*, Eindhoven, 2011.
- [58] S. Day, Important Factors in Surface EMG Measurement, Calgary: Bortec Biomedical Ltd, 2002.
- [59] A. Van Boxtel, «Facial EMG as a Tool for Inferring Affective States,» de *Proceedings of Measuring Behavior*, Tilburg, 2010, pp. 104-108.
- [60] U. Dimberg, «Facial Electromyography and Emotional Reactions,» de *Psychophysiology*, Upsala, The Society for Psychophysiological Research, Inc, 1990, pp. 481-494.
- [61] A. Ronacher, «Flask Web Development, one drop at a time,» 14 Junio 2013. [En línea]. Available: <http://flask.pocoo.org/>. [Último acceso: 1 Abril 2016].

- [62] «Learning naive Bayes classifiers from positive and unlabelled examples with uncertainty,» de *International Journal of Systems Science*, Yangling, Taylor & Francis , 2012, pp. 1805-1825.
- [63] H.-S. Park, J.-O. Yoo y Sung-Bae, «A Context-Aware Music Recommendation System Using Fuzzy Bayesian Networks with Utility Theory,» *Fuzzy Systems and Knowledge Discovery*, vol. 4223, pp. 970-979, 2006.
- [64] S. Rho, B.-j. Han y E. Hwang, «SVR-based music mood classification and context-based music recommendation,» de *Proceedings of the 17th ACM International Conference on Multimedia*, Beijing, China, 2009.
- [65] N. H. a. R. M. R. M. R. Siddiquee, «A fuzzy based recommendation system with collaborative filtering,» de *8th International Conference on Software, Knowledge, Information Management and Applications (SKIMA)*, Dhaka, 2014.
- [66] L. Moutinho y G. D. Hutcheson, «Ordinary Least-Squares Regression,» de *The SAGE Dictionary of Quantitative Management Research*, SAGE Publications, 2011, pp. 224-228.
- [67] U. Kohler y F. Kreuter, «Describing data using statistics,» de *Data Analysis Using Stata, Third Edition*, Texas, Stata Press, 2012, pp. 173-186.