

Recomendaciones musicales en base a la selección de características relevantes de alto nivel

Alessandra Delgado Mattos, Graciela Meza Lovón

daniela.delgado.mattos@ucsp.edu.pe, g.meza.lovon@gmail.com

Universidad Católica San Pablo

Resumen: En los últimos años la cantidad de aplicaciones orientadas a la industria musical ha incrementado considerablemente. Las opciones que estas nuevas aplicaciones ofrecen cada vez se van tornando más complejas y sofisticadas, puesto que las expectativas de los usuarios se van haciendo más exigentes. Hoy día ya no basta con aplicaciones musicales que sólo sirvan como simples reproductores de archivos de audio, los usuarios precisan de más opciones y funcionalidades, siendo uno de éstos, los sistemas automáticos de recomendación musical basada en los gustos y preferencias de dicho usuario. Entonces, para poder obtener una recomendación musical óptima se enfrentan tres problemas: el primero es cómo recuperar la información musical, el segundo problema es la ponderación de la información recuperada para poder clasificar los archivos musicales y, finalmente, la indexación de los archivos musicales bajo criterios de similitud para poder organizar la música. Para resolver los diferentes problemas presentados, se plantea, primero utilizar características de alto nivel mediante la recuperación de información de los metadatos y archivos MIDI, ponderar las características obtenidas, finalmente, indexar los datos obtenidos en una estructura métrica que permita realizar las consultas requeridas para obtener la recomendación musical más óptima.

Palabras clave: sistemas automáticos de recomendación musical, archivos MIDI, metadatos, recomendación musical.

Abstract: In recent years the number of applications aimed at the music industry has increased considerably. The options that these new applications will increasingly offer becoming more complex and sophisticated, as the expectations of users are becoming more demanding. Today and not enough music applications that only serve as simple audio file players, users require more features and functionality, one of these, the automatic music recommendation based on the tastes and preferences of the user. So in order to get an optimal music recommendation facing three problems: the first is how to retrieve musical information, the second problem is the weight of the retrieved information to classify music files and finally indexing music files under similarity criteria to organize music. To solve the various problems presented, we propose first to use high-level features by retrieving metadata information and MIDI files, weighing the characteristics obtained eventually index the data obtained from a metric structure that allows queries required to obtain optimum musical recommendation.

Keywords: automatic music recommendation, MIDI files, metadata, music recommendation.

1. Introducción

En la actualidad, los servicios de transmisión musical en línea poseen grandes colecciones musicales que alcanzan los miles de millones de canciones, planteando un gran desafío al realizar tareas, como buscar, recuperar y organizar el contenido de la música. De esta manera, participan cientos de expertos en percepción musical, musicología, ingeniería y ciencias de la computación dando así muchas propuestas para recuperar y organizar la música utilizando métodos basados en el contenido de las pistas.

En el caso específico de un sistema de clasificación musical, el grado de complejidad aumenta puesto que son más difusos y ambiguos los parámetros que pueden determinar el género de una determinada pista musical. De la misma manera, afectará directamente el tipo de clasificación o la cantidad de géneros musicales elegidos a utilizar en el sistema. Otro aspecto a tener en cuenta son las características de una canción que serán utilizadas al momento de compararla con otras con el fin de buscar similitudes y diferencias.

Hoy, se han realizado grandes avances gracias al MIR (Recuperación de información musical), respaldándose en algunas ciencias como musicología, psicología, estudio

académico de la música, procesamiento de señales, aprendizaje de máquina, o algunas combinaciones de éstas. Actualmente, el método más común para acceder a la música es a través de los metadatos que representan toda aquella información extra, como título de la obra, álbum, año, autor, tapa, género, etc. La mayoría de servicios existentes para descargar música utilizan solo este enfoque desempeñándose eficientemente, como se menciona en [IEEE et al., 2008].

Sin embargo, conforme la cantidad de información se va incrementando es muy difícil mantener las expresiones de los metadatos consistentes, los cuales permitan tener información útil y confiable para el manejo de la música, puesto que muchas personas crean las descripciones y la variación en el concepto de codificaciones impacta en el rendimiento de la búsqueda. Estas descripciones representan opiniones subjetivas, por lo que la supervisión de los metadatos es de suma importancia. La idea general es poder utilizar el concepto de los sistemas basados en metadatos, que son sistemas que analizan la información sobre el contenido de la música.

El problema que se va a resolver en el presente trabajo es la recomendación musical, donde, en una primera etapa, se encuentra la recuperación de información donde intervienen los metadatos y los archivos MIDI. En una

siguiente etapa, es necesario realizar la recopilación de las características, y finalmente, la indexación de las muestras obtenidas en una estructura métrica. De esta manera, poder realizar consultas en el conjunto de datos indexados.

El resto de este paper está organizado de la siguiente manera. En la Sección 2, se muestra el estado del arte del problema a resolver. La Sección 3 describe la manera de seleccionar características mediante el método mRMR. La Sección 4 describe la manera de seleccionar características mediante el método SIR. En la sección 5, se desarrolla los experimentos realizados. La sección 6 desarrolla los resultados obtenidos y, finalmente, las conclusiones se encuentran en la Sección 7.

2. Teoría del dominio y trabajos previos

Existen diferentes enfoques para la recomendación musical: En 1999, Will Glaser y Tim Westergren dieron vida al Proyecto del Genoma Musical [Glaser et al., 2006]. Un año después se asociaron con Jon Kraft para fundar Pandora Media. El principal objetivo de este proyecto fue capturar la esencia de la música en su nivel más básico, usando alrededor de 400 características para describir las canciones.

También utilizaron un complejo algoritmo matemático que se encargó de clasificar las pistas musicales. Este proyecto creó 5 distintos tipos de genomas, los cuales son: Pop/Rock, Hip-Hop/Electrónica, Jazz, Música mundial, Clásica, este enfoque toma el nombre de recomendación experta basada en la selección de la persona. Se desarrollaron también los enfoques sociales, que utilizan atributos de texto, información cultural, etiquetas sociales y otros tipos de selecciones basadas en la web [Nanopoulos et al., 2010] [Schedl et al., 2009] [Levy and Sandler, 2009].

Trabajos que analizan el contenido del audio para la caracterización de las pistas, así como establecer similitudes entre características musicales [Amatriain et al., 2003]. Filtros Colaborativos (CF), los que analizan patrones de sonido por muchos usuarios para establecer similitudes por usuario y elementos musicales. Cada uno de estos enfoques presentan ciertas desventajas, el primero consume demasiado tiempo y es difícil de escalar. Es muy poco probable que los enfoques basados en etiquetas sociales nos brinden una caracterización completa de la música. Los enfoques basados en el contenido pierden las relaciones y distinciones que realizan las personas entre las canciones [Slaney, 2011]. La capacidad de modelar lo que el usuario desea hace que el enfoque CF sea uno de los más precisos en la recomendación musical, ya que éste naturalmente aprende las tendencias de popularidad observando el comportamiento real del usuario, sin embargo presenta la desventaja de necesitar una gran cantidad de registros del comportamiento del usuario [Aizenberg et al., 2012]. El método descrito en este trabajo propone una recomendación basada en contenido, ya que recomienda canciones en base a la canción que el usuario seleccionó inicialmente, más considerando como atributos las características instrumentales que presentan los archivos MIDI, debido a que estos archivos nos brindan la misma

información que uno podría encontrar en una partitura musical, así, al tener las características seleccionadas, se realiza un proceso de selección utilizando dos algoritmos de selección de características el primero mRMR y el segundo que ha sido creado específicamente para seleccionar los instrumentos relevantes de una canción (SIR) obteniendo así una recomendación musical mucho más óptima en cuanto al parecido de una canción con otra instrumentalmente.

2.1. Características en la clasificación musical

El principio de la biología [Glaser et al., 2006] que dice que los genes son considerados como la unidad más pequeña de almacenamiento de información genética de un ser vivo, es utilizado en la computación. En el caso específico del tema que se trata en este documento, un gen pasa a representar una característica básica de una canción en particular, el conjunto de genes de una canción contendrá toda la información de la misma, haciéndola única y diferenciándola de todas las demás.

Por lo tanto, canciones que pertenecen a un mismo género tendrán información genética similar. Sin embargo, en la clasificación musical, se torna difícil determinar si una canción pertenece a un género y no a otro, puesto que muchos géneros tienen características similares, un sistema computacional que se encargue de clasificar las canciones resulta de mucha ayuda, puesto que deja de lado la subjetividad humana y se basa únicamente en los genes y su información para determinar el género de una canción, vale la pena mencionar que el éxito en la clasificación dependerá de la correcta elección de los genes.

2.2. Selección de características

El objetivo de la selección de características es reducir la dimensión de los datos, de manera que se escogen las características que sean útiles para resolver el problema de aprendizaje, descartando las demás.

Tomando en cuenta el enfoque de esta investigación en la clasificación musical, se utilizarán un conjunto de características musicales de alto nivel [McKay, 2004] para la clasificación de géneros, debido a que estas características pueden ser extraídas fácilmente de formatos simbólicos como archivos MIDI [Perrot and Gjerdigen, 1999].

2.2.1. Métodos de Selección de características

Existen muchas técnicas de selección de características, por lo que se han clasificado según dos criterios: el primer criterio pregunta cómo generar los vectores características mientras que el segundo ve la manera de evaluar los vectores de características:

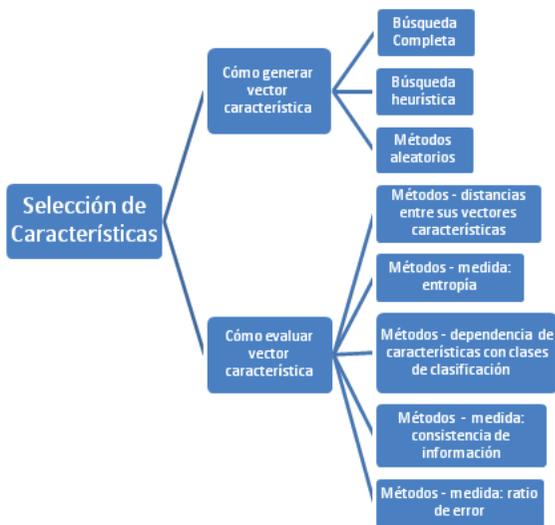


Figura 1. Métodos de Selección de Características. [Sewell, 2007] [Dash and Liu, 1997] [Petr Somol, 2004] [Brassard et al., 1997] [Dash and Liu, 1997].

3. Selección de una sola característica mediante mRMR (minimum Redundancy Maximum Relevance Feature Selection)

Dados los datos de entrada D presentados como N muestras y M características $X = x_i, i = 1, \dots, M$ y la variable de clasificación objetivo c. El problema de selección de características es encontrar del espacio de observación M-dimensional, RM, un subespacio de m características, R_m , las que caracterizan óptimamente a c. Esta condición de caracterización óptima significa a menudo un error mínimo de clasificación.

La relevancia máxima selecciona las características con mayor relevancia para la clase objetivo c. La relevancia se caracteriza usualmente en términos de correlación o información mutua, que es una medida ampliamente utilizada para definir la dependencia de variables.

F_i es relevante si $\exists v, y$ con $p(F_i = v) > 0$ tales que $p(Y = y | F_i = v) = p(Y = y)$ donde F_i e Y son variables aleatorias que representan la característica f_i , y la clase, respectivamente.

Pero este concepto presenta un inconveniente el cual es que sólo tiene en cuenta la característica de forma individual, cuando realmente varias características influyen simultáneamente en el valor de la clase. Es por esto que se propone debido a muchos trabajos realizados que revisan y estudian estas definiciones de relevancia a [John et al., 1994] [Langley, 1994] [Blum and Langley, 1997] [Kohavi and John, 1997] [Lashkia and Anthony, 2004] dos tipos de relevancia: fuerte y débil.

Se entiende que una característica es fuertemente relevante cuando ésta es imprescindible, entendiendo así que ninguna otra característica puede reemplazar su aportación por lo que su eliminación supondría pérdida de capacidad de predicción. Esta definición de relevancia fuerte deja fuera a características potencialmente

relevantes las que podrían llegar a ser imprescindibles, si no se incluyen otras que aporten la misma información, son las llamadas débilmente relevantes.

Entonces, se consideran características irrelevantes a aquellas características que no son relevantes, ni fuertemente ni débilmente, aportando una capacidad máxima de selección con el menor número de características.

Este método estudia el cómo seleccionar buenas características de acuerdo con el criterio de la dependencia estadística máxima basada en la información mutua ya que permite seleccionar un grupo compacto de características superiores a muy bajo coste. Se utilizará un framework que hace uso de la heurística de mínima redundancia, máxima relevancia (mRMR) [Peng et al., 2005] para minimizar la redundancia.

4. Selección de características mediante Sir (Selección de instrumentos representativos)

El método SIR contará con un conjunto de datos de entrada D, los cuales representan las N muestras y M características y la clase de las respectivas muestras. En este método, se busca encontrar el grado de pertenencia de una canción a su respectivo género, utilizando el concepto de grado de pertenencia de la lógica difusa [Novk, 2006], ya que el valor de pertenencia de una canción a su género se encuentra entre el intervalo 0 y 1 variando de acuerdo con la presencia de instrumentos representativos de dicha canción a su supuesto género, tratando así de cometer la menor cantidad de errores al momento de clasificar esa canción, la cual, finalmente tendrá una ponderación de pertenencia hacia cada género. Este método trabaja con las características extraídas de los archivos MIDI.

4.1. Cálculo del Género

Para realizar el cálculo del género, se utilizan las 60 canciones por género que han sido seleccionadas para extraer de ellas sus características obteniendo de este conjunto de canciones la siguiente fórmula:

$$\frac{\sum_{i=0}^{\sigma} \alpha_i}{\sigma} \quad (1)$$

donde σ representa el total de canciones y α_i representa cada uno de los instrumentos y del género respectivo, obteniendo la suma de todos los instrumentos de cada una de las canciones i dividiendo dicha suma entre el total de las canciones por cada género.

4.2. Primera ponderación

Se realiza una primera ponderación de la pertenencia de una canción con el género en base a todos los instrumentos, a través de la siguiente fórmula de grado de pertenencia:

$$\frac{\sum_{i=0}^{128} \beta_i / \alpha_i}{\eta} \quad (2)$$

donde β_i representa los i instrumentos de la canción, α_i representa los i instrumentos del género, η representa el número de instrumentos por género y 128 es el número de características que presenta cada canción. Dichas características representan a los 128 instrumentos con los que trabajan los archivos MIDI.

4.3. Significancia de los instrumentos en la canción

Posteriormente, para tener una mejor ponderación se realiza la significancia de cada instrumento I_j en la canción, esto quiere decir el porcentaje que significa un instrumento del total de instrumentos de la canción. Esto se realiza con todas las canciones. Entonces ahora podremos obtenerla significancia de los instrumentos del género de la misma manera que fue calculado para las canciones.

4.4. Filtros en Cascada

Son un conjunto de filtros individuales que, al trabajar de forma conjunta, se obtienen mejores resultados. La diferencia entre cada filtro es mínima. En cada filtro, se realiza una discriminación de los instrumentos representativos y no representativos, según el peso del filtro. Para lograr esto, cada característica es comparada con el valor del filtro, si el valor de la característica es menor al del filtro, entonces esta característica conformará parte de las características no representativas, en caso contrario se escoge la característica como característica representativa. Como se observa en la figura 2.

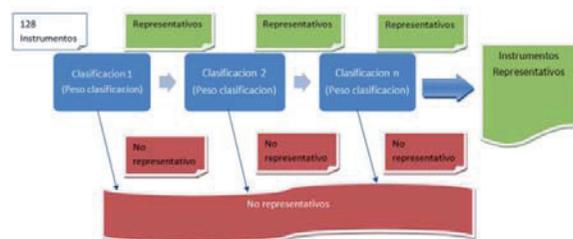


Figura 2. Filtro encascada. [McKay, 2004].

De las características representativas se vuelve a calcular la significancia de estas, en el conjunto de características. Así, sucesivamente, hasta cumplir el número de iteraciones. Finalmente, del filtro en cascada se obtiene un vector de características de los instrumentos representativos de un género.

Así se realiza una ponderación de pertenencia final de los instrumentos de la canción al género que ya pasó por el filtro en cascada utilizando la fórmula 3.

$$\sum_{i=0}^{128} \gamma_i / \delta_i / \eta \quad (3)$$

donde γ_i se refiere al instrumento significativo i de la canción, δ_i se refiere a los Instrumentos i del género clasificado y η representa el número de instrumentos pertenecientes al género clasificado.

5. Experimentos

5.1. Recuperación de la información

5.1.1. Extracción de características

1. La extracción de características de los archivos MIDI se realizó con la herramienta jSymbolic [Mckayand Fujinaga, 2006] la cual permite extraer características musicales de alto nivel de dichos archivos.
2. El archivo MIDI posee 128 características que representan los 128 timbres instrumentales y efectosdesonido.
3. Se seleccionaron las características de notas de tiempo de prevalencia, las cuales representan, para cada instrumento, la fracción del tiempo total de la grabación en el que estuvo sonando un instrumento en la canción, generando así un vector de 128 características para cada canción, las cuales se agrupan en 16 canales: piano, percusión cromática, órgano, guitarras, bajos, cuerdas, conjunto, latones, reese, pipes, synthlead, synthpad, syntheffects, etnic, percusión y efectos de sonido.

5.1.2. Base de Datos Utilizada

Se extrajeron 300 archivos MIDI de la base de datos Bodhiharma MIDI, de entre estas canciones se seleccionaron 60 canciones románticas, 60 canciones de salsa, 60 canciones rock, 60 canciones de reggaetón y 60 canciones de bachata.

Para realizar las pruebas, se extrajeron 5 muestras por cada género, quedando como parte de la base de datos un total de 275 muestras.

5.2. Ponderación de características

De las características obtenidas en la etapa anterior, se procede a realizarla significancia de los instrumentos en la canción. A partir del vector obtenido de cada canción, se calcula el género y se seleccionan los instrumentos representativos SIR utilizando el método filtros en cascada. Así se obtienen los instrumentos representativos de los 5 géneros, para, finalmente, realizar el grado de pertenencia de una canción i a los géneros.

5.3. Selección de características con el mRMR

Al obtener los vectores características de los archivos MIDI, se calcula la significancia de los instrumentos en la canción para todas las canciones, y estos vectores son enviados al seleccionador mRMR el cual escogerá, según la cantidad deseada de características con las cuales queremos trabajar, un grupo de características que represente mejora cada género con la restricción de que estas características sean mutuamente tan diferentes entre sí como sea posible, pero al mismo tiempo similares a la clase que representan obteniendo así características con mayor relevancia y menor redundancia.

Para la selección de características, se hará uso del framework mRMR C/C++ Versión [Peng et al., 2005], el cual es un software integrado para la selección de atributos de mínima redundancia-máxima relevancia.

5.4. Indexación y comparación en estructura métrica

Se indexan cada uno de los vectores característica a la estructura métrica LAESA.

Al tener las muestras indexadas en el LAESA, se procede a realizar la recomendación de la canción más similar a la ingresada por el usuario, la cual antes de hacer uso del LAESA, tanto las muestras indexadas como la muestra ingresada por el usuario pasan por un pre proceso el cual, consiste en obtener el género al que ha sido clasificado dicha muestra, colocando 5 características extras a las 128 características que representan los instrumentos de la canción. Estas nuevas características representan el grado de pertenencia de la canción a cada género, seleccionando el grado de pertenencia mayor como el género de esa canción, de esta manera se mejorará la exactitud de la recomendación.

6. Resultados

Para comprobar la validez de la propuesta del presente paper, se realizaron las pruebas de la siguiente forma:

- Recomendación musical utilizando las características iniciales obtenidas del análisis del archivo MIDI.
- Experimentos de la selección de características mediante SIR-Selección de Instrumentos Representativos.
- Experimentos de la selección de características mediante el seleccionador mRMR. Recomendación musical utilizando las características seleccionadas del seleccionador mRMR.
- Recomendación musical utilizando las características seleccionadas de la selección de instrumentos representativos.

6.1. Recomendación musical con características iniciales

En este experimento se realizó la indexación de las características iniciales a la estructura métrica LAESA, obteniendo recomendaciones musicales poco eficientes debido a que la media de recomendación tiene los valores 1% y de 8% para las canciones de género romántica y salsa respectivamente, demostrando que usando las características iniciales no produce una óptima recomendación musical.

6.2. Selección de características mediante SIR – Selección de Instrumentos Representativos

Con los resultados obtenidos en la etapa anterior se hace necesario realizar un procesamiento con las 128 características que se tienen por canción: Cálculo del género musical, Significancia de los instrumentos, Significancia de los instrumentos en el género, Filtros en cascada, obteniendo finalmente el vector de características con los instrumentos representativos del género.

En este experimento, para seleccionar los instrumentos representativos de cada género, se realizaron pruebas con diferentes iteraciones en el filtro en cascada para hallar los géneros.

De los resultados obtenidos, la mejor elección es realizar el filtro en cascada con tres iteraciones. Ya que es la que más se acerca a la cantidad de 60 canciones por género.

6.3. Selección de características mediante el seleccionador mRMR

En el experimento de selección de características con mRMR, también se selecciona las características relevantes. En este caso las pruebas se realizaron con 10, 20 y 50 características respectivamente.

De los resultados obtenidos se tiene que la mejor ponderación de la base de datos a los géneros es con 10 características relevantes. Por lo que se obtendrá para cada género un vector característica con sus 10 instrumentos más relevantes.

Cuadro 1. Media de recomendación a canciones de Romántica

Género	Salsa	Regg	Rom	Bach	Rock
CanciónRom1	0%	0%	80%	10%	10%
CanciónRom2	0%	0%	70%	10%	20%
CanciónRom3	80%	0%	20%	0%	0%
CanciónRom4	0%	10%	70%	0%	20%
CanciónRom5	0%	0%	60%	40%	0%
Media	16%	2%	60%	12%	10%

Cuadro 2. Media de recomendación a canciones de Salsa

Género	Salsa	Regg	Rom	Bach	Rock
CanciónSalsa1	100%	0%	0%	0%	0%
CanciónSalsa2	70%	0%	0%	30%	0%
CanciónSalsa3	100%	0%	0%	0%	0%
CanciónSalsa4	100%	0%	0%	0%	0%
CanciónSalsa5	40%	0%	60%	0%	0%
Media	82%	0%	12%	6%	0%

Cuadro 3. Media de recomendación a canciones de Reggaeton

Género	Salsa	Regg	Rom	Bach	Rock
CanciónRegg1	0%	100%	0%	0%	0%
CanciónRegg2	100%	0%	0%	0%	0%
CanciónRegg3	0%	30%	0%	70%	0%
CanciónRegg4	40%	0%	60%	0%	0%
CanciónRegg5	0%	0%	10%	0%	90%
Media	28%	26%	14%	14%	18%

6.4. Recomendación musical utilizando las características seleccionadas con el mRMR

6.4.1. Recomendación musical en base a las características de significancia

En estas pruebas, se realizó la indexación de las características con significancia a la estructura métrica LAESA. La cual nos devolvió distintas recomendaciones, en base a unas 100 iteraciones de recomendación, como se observa en el cuadro 1, 2 y 3.

De los resultados obtenidos, como se observa en el cuadro 3, se puede apreciar que para las canciones del género Reggaeton la media de recomendación hacia su género no es la más alta. Así mismo, podemos apreciar la media de recomendación de que tienen las canciones de la base de datos hacia sus respectivos géneros, en algunos casos la recomendación no es la más óptima siendo necesaria una recomendación más exacta, por eso se realizará recomendación musical en base a las características y el género musical.

Cuadro 4. Media de recomendación a canciones de Rock

Nombre	Bach	Rock	Sal	Reg	Rom
Bon Jovi - Living on a prayer	4%	5%	5%	3%	5%
Características	0%	11%	4%	...	8%

Cuadro 5. Media de recomendación a canciones de Romántica

Género	Salsa	Regg	Rom	Bach	Rock
CanciónRom1	10%	10%	40%	10%	30%
CanciónRom2	10%	10%	40%	10%	30%
CanciónRom3	0%	0%	70%	30%	0%
CanciónRom4	0%	30%	40%	0%	30%
CanciónRom5	20%	60%	10%	10%	0%
Media	8%	22%	40%	12%	18%

6.4.2. Recomendación musical en base a los géneros musicales calculados con mRMR

En esta sección, se realizaron los experimentos para realizar la recomendación musical en base a las características de las canciones y la ponderación de pertenencia de estas canciones hacia los distintos géneros obtenidos del mRMR, tal como se observa en el cuadro 4. Este conjunto de características se indexa a la estructura métrica LAESA.

Se realizaron 100 iteraciones de las pruebas de recomendación musical con las canciones de prueba, obteniendo como resultado una mejor recomendación, tal como se pueden observar en los cuadros 5, 6 y 7.

Comparando el resultado del cuadro 7 con el cuadro 3, podemos observar que la recomendación musical ha mejorado en un 20% para ese género, solucionando el

problema de una mala recomendación musical. También observamos que la recomendación de las canciones de prueba a sus géneros respectivo se mantiene alta, como en los cuadros 5 y 6.

Cuadro 6. Media de recomendación a canciones de Salsa

Género	Salsa	Regg	Rom	Bach	Rock
CanciónSalsa1	100%	0%	0%	0%	0%
CanciónSalsa2	60%	0%	0%	40%	0%
CanciónSalsa3	100%	0%	0%	0%	0%
CanciónSalsa4	90%	0%	0%	0%	10%
CanciónSalsa5	30%	0%	70%	0%	0%
Media	76%	0%	14%	8%	2%

Cuadro 7. Media de recomendación a canciones de Reggaeton

Género	Salsa	Regg	Rom	Bach	Rock
CanciónRegg1	0%	90%	10%	0%	0%
CanciónRegg2	0%	90%	0%	0%	10%
CanciónRegg3	0%	0%	40%	60%	0%
CanciónRegg4	60%	0%	30%	0%	10%
CanciónRegg5	0%	30%	0%	0%	70%
Media	12%	46%	16%	12%	18%

Cuadro 8. Media de recomendación a canciones de Reggaeton

Genero	Salsa	Regg	Rom	Bach	Rock
CanciónSalsa1	95%	0%	5%	0%	0%
CanciónSalsa2	100%	0%	0%	0%	0%
CanciónSalsa3	100%	0%	0%	0%	0%
CanciónSalsa4	70%	0%	0%	30%	0%
CanciónSalsa5	95%	0%	5%	0%	0%
Media	92%	0%	2%	6%	0%

6.5. Recomendación musical utilizando las características seleccionadas con el SIR

6.5.1. Recomendación musical en base a las características de significancia de los instrumentos

La recomendación musical que se realizó en esta etapa fue en base a las características de significancia de instrumentos que tiene cada canción, las características de cada canción se indexaron a la estructura métrica LAESA para lograr la recomendación musical. La cual nos dio los siguientes resultados en base a unas 100 iteraciones de recomendación como se observa en el cuadro 8, 9 y 10. Como se puede observar en el cuadro 9, la recomendación musical que realiza de las canciones de bachata con su género es de 27% siendo menos que el 31% de recomendación para el género de la salsa. Se puede tener en cuenta que existe instrumentos semejantes entre estos

géneros y por ello la semejanza en la recomendación. Estas pruebas se realizaron con 100 iteraciones de recomendación por canción.

Cuadro 9. Media de recomendación a canciones de Bachata

Género	Salsa	Regg	Rom	Bach	Rock
CanciónBachata 1	0%	0%	0%	5%	95%
CanciónBachata 2	0%	0%	5%	95%	0%
CanciónBachata 3	60%	20%	5%	15%	0%
CanciónBachata 4	0%	0%	80%	20%	0%
CanciónBachata 5	95%	0%	5%	0%	0%
Media	31%	4%	19%	27%	19%

Cuadro 10. Media de recomendación a canciones de Rock

Género	Salsa	Regg	Rom	Bach	Rock
CanciónRock1	0%	0%	0%	5%	95%
CanciónRock2	0%	0%	0%	0%	100%
CanciónRock3	0%	0%	0%	65%	35%
CanciónRock4	0%	0%	0%	0%	100%
CanciónRock5	50%	45%	5%	0%	0%
Media	10%	9%	1%	14%	66%

Cuadro 11. Media de recomendación a canciones de Rock

Nombre	Bach	Rock	Sal	Reg	Rom
RedHotChili	42%	85%	0%	0%	21%
Características	0%	27%	0%	...	8%

Cuadro 12. Media de recomendación a canciones de Salsa

Género	Salsa	Regg	Rom	Bach	Rock
CanciónSalsa1	100%	0%	0%	0%	0%
CanciónSalsa2	60%	0%	0%	40%	0%
CanciónSalsa3	100%	0%	0%	0%	0%
CanciónSalsa4	80%	0%	10%	10%	0%
CanciónSalsa5	40%	0%	0%	60%	0%
Media	76%	0%	2%	22%	0%

6.5.2. Recomendación musical en base a los géneros musicales calculados con SIR

Las pruebas en esta etapa utilizan la ponderación de pertenencia de la canción a los 5 géneros calculados con SIR y las características de significancia de instrumentos en la canción, como se muestra en el cuadro 11.

Las pruebas que se realizaron con este tipo de características fueron en base al género de mayor ponderación, para posteriormente indexar a LAESA y obtenerla recomendación musical más precisa para las canciones de prueba, como se observa en los cuadros 12, 13 y 14.

Cuadro 13. Media de recomendación a canciones de Bachata

Género	Salsa	Regg	Rom	Bach	Rock
CanciónBach1	0%	0%	0%	10%	90%
CanciónBach2	0%	0%	10%	90%	0%
CanciónBach3	0%	70%	10%	10%	10%
CanciónBach4	0%	0%	70%	30%	0%
CanciónBach5	100%	0%	0%	0%	0%
Media	20%	14%	20%	26%	20%

Cuadro 14. Media de recomendación a canciones de Rock

Género	Salsa	Regg	Rom	Bach	Rock
CanciónRock1	0%	0%	10%	50%	40%
CanciónRock2	10%	0%	0%	0%	90%
CanciónRock3	10%	0%	30%	10%	50%
CanciónRock4	0%	0%	0%	0%	100%
CanciónRock5	0%	0%	0%	0%	100%
Media	4%	0%	8%	12%	76%

Como se puede observar en el cuadro 14 de la recomendación musical hacia el mismo género mejoró, teniendo como primera recomendación musical el género de bachata con un 26%.

Debido a que las canciones del género Rock, Salsa y Reggaetón tienen instrumentos representativos bien definidos, el porcentaje de recomendación de dichas canciones hacia su propio género es mayor. En otros, como la Bachata y Romántica, muestran una recomendación hacia otros géneros ya que en algunas canciones se utilizan algunos instrumentos de otros géneros.

7. Conclusiones y trabajos futuros

Se ha desarrollado, en este trabajo, un método de recomendación musical, que utiliza características de alto nivel basada en los archivos MIDI, así como dos seleccionadores de características: SIR y RMR y, finalmente, la estructura métrica LAESA para devolver la recomendación musical.

Gracias a las pruebas realizadas, se obtuvieron los siguientes resultados:

Utilizar la información que nos brinda los archivos MIDI nos da una recomendación musical de 11,6% de exactitud (al devolver canciones similares), por lo que se utiliza un seleccionador de características para mejorar dicha eficiencia, así como el uso de los géneros de las canciones para tener una mayor precisión en la recomendación.

Utilizando mRMR, se obtuvo un 55,6% de eficiencia, con deficiencias en la recomendación del género de reggaetón. De la misma forma, el SIR obtuvo un 57,8% de eficiencia en la recomendación musical, pero también presentando una recomendación no tan precisa con el género de bachata.

Finalmente, para dar solución a la recomendación notan precisa con algunos géneros se agrega la ponderación de pertenencia a los géneros. Utilizando el SIR, se obtuvo un 50% de eficiencia, solucionando la recomendación en el género bachata, la cual, en la recomendación anterior, no era tan precisa. De igual manera, con el mRMR, se obtuvo un 54% de eficiencia solucionando la recomendación de canciones en el género reggaetón. Por lo tanto, con la utilización de selección de características representativas, se mejora del 11,6% de eficiencia de recomendación a más del 50% de eficiencia en la recomendación musical.

Referencias bibliográficas

- [Aizenberg et al., 2012] Aizenberg, N., Koren, Y., and Somekh, O. (2012). Build your own music recommender by modeling internet radio streams. In Proceedings of the 21st international conference on World Wide Web, WWW '12, pages 1–10, New York, NY, USA. ACM.
- [Amatriain et al., 2003] Amatriain, X., Bonada, J., lex Loscos, Arcos, J. L., and Verfaillie, V. (2003). Content-based transformations. *Journal of New Music Research*, 32:2003.
- [Blum and Langley, 1997] Blum, A. L. and Langley, P. (1997). Selection of relevant features and examples in machine learning. *ARTIFICIAL INTELLIGENCE*, 97:245–271.
- [Brassard et al., 1997] Brassard, G., Bratley, P., and García-Bermejo, R. (1997). *Fundamentos de Algoritmia*. Fuera de colección Out of series. Prentice-Hall.
- [Dash and Liu, 1997] Dash, M. and Liu, H. (1997). Feature selection for classification. *Intelligent Data Analysis*, 1:131–156.
- [Glaser et al., 2006] Glaser, W. T., Westergren, T. B., Stearns, J. P., and Kraft, J. M. (2006). Consumer item matching method and system.
- [Ieee et al., 2008] Ieee, M., Veltkamp, R., Goto, M., Leman, M., Rhodes, C., Slaney, M., and Ieee, S. M. (2008). Invited paper content-based music information retrieval: Current directions and future challenges.
- [John et al., 1994] John, G. H., Kohavi, R., and Pflieger, K. (1994). Irrelevant features and the subset selection problem. In *MACHINE LEARNING: PROCEEDINGS OF THE ELEVENTH INTERNATIONAL*, pages 121–129. Morgan Kaufmann.
- [Kohavi and John, 1997] Kohavi, R. and John, G. H. (1997). Wrappers for feature subset selection.
- [Langley, 1994] Langley, P. (1994). Selection of relevant features in machine learning.
- [Lashkia and Anthony, 2004] Lashkia, G. V. and Anthony, L. (2004). Relevant, irredundant feature selection and noisy example elimination. *IEEE Transactions on Systems, Man, and Cybernetics, Part B*, 34(2):888–897.
- [Levy and Sandler, 2009] Levy, M. and Sandler, M. (2009). Music information retrieval using social tags and audio. *Trans. Multi.*, 11(3):383–395.
- [McKay, 2004] McKay, C. (2004). Automatic genre classification of midi recordings.
- [Mckay and Fujinaga, 2006] Mckay, C. and Fujinaga, I. (2006). jsymbolic: A feature extractor for midi files. In *In Int. Computer Music Conf*, pages 302–305.
- [Nanopoulos et al., 2010] Nanopoulos, A., Rafailidis, D., Symeonidis, P., and Manolopoulos, Y. (2010). Musicbox: Personalized music recommendation based on cubic analysis of social tags. *Trans. Audio, Speech and Lang. Proc.*, 18(2):407–412.
- [Novk, 2006] Novk, V. (2006). What is the fuzzy logic.
- [Peng et al., 2005] Peng, H., Long, F., and Ding, C. H. Q. (2005). Feature selection based on mutual information: Criteria of max-dependency, max-relevance, and minredundancy. *IEEE Trans. Pattern Anal. Mach. Intell.*, 27(8):1226–1238.
- [Perrot and Gjerdingen, 1999] Perrot, D. and Gjerdingen, R. O. (1999). Scanning the dial: An exploration of factors in the identification of musical style. *Proceedings of the Society for Music Perception and Cognition*.
- [Petr Somol, 2004] Petr Somol, Pavel Pudil, F. J. F. J. K. (2004). Fast branch and bound algorithms for optimal feature selection. *IEEE Trans. Pattern Anal. Mach. Intell.*
- [Schedl et al., 2009] Schedl, M., Knees, P., and Kepler, J. (2009). Context-based music similarity estimation. In *in Proceedings of the 3rd International Workshop on Learning the Semantics of Audio Signals (LSAS 2009)*.
- [Sewell, 2007] Sewell, M. (2007). Feature selection.
- [Slaney, 2011] Slaney, M. (2011). Web-scale multimedia analysis: Does content matter? *IEEE MultiMedia*, 18(2):12–15.