



This is the **published version** of the bachelor thesis:

Puigbó Paricio, Marc; Hernandez Sabate, Aura, dir.; Gil Resina, Debora, dir.
El ADN de los éxitos musicales : Análisis i recomendación basada en patrones.
2025. (Enginyeria de Dades)

This version is available at <https://ddd.uab.cat/record/317362>

under the terms of the  license

L'ADN dels èxits musicals: Anàlisi i recomanació basada en patrons

Marc Puigbó Paricio

Resum– Aquest treball de final de grau analitza l'existència de patrons o tendències entre cançons d'èxit mitjançant tècniques de processament de senyal i agrupació no supervisada (DBSCAN). A partir d'una base de dades amb les 200 cançons més escoltades del rànquing Billboard Global 2024, s'han extret característiques musicals (to, timbre, energia, etc.) i s'ha desenvolupat un sistema de recomanació basat en el contingut acústic. Els resultats mostren una agrupació coherent per gènere musical i una similitud en aspectes com el to, la intensitat sonora i el ritme, cosa que suggereix la presència de patrons comuns en les cançons d'èxit.

Paraules clau– Sistemes de recomanació, característiques acústiques, clustering no supervisat, DBSCAN, Billboard, similitud musical, recomanació basada en contingut, extracció de característiques.

Abstract– This final degree project investigates whether popular songs share common acoustic patterns by applying signal processing and unsupervised clustering (DBSCAN) techniques. Using a dataset of the 200 most streamed songs from the Billboard Global 2024 chart, musical features (tone, timbre, energy, etc.) were extracted and analyzed. A recommendation system based solely on audio content was implemented. Results show a coherent grouping by musical genre and a similarity in aspects such as tone, sound intensity, and rhythm, suggesting the presence of common patterns in hit songs.

Keywords– Recommendation systems, audio features, unsupervised clustering, DBSCAN, Billboard, music similarity, content-based recommendation.

1 INTRODUCCIÓ - CONTEXT DEL TREBALL

EN els darrers anys, les plataformes digitals han facilitat l'accés a la música, cosa que ha permès escoltar a baix cost tota mena de música sense limitacions, i descobrir una gran varietat de cançons. La constant aparició de noves tendències musicals, i amb elles milers de cançons d'èxit porta a qüestionar-se si existeix algun factor comú que contribueix a l'èxit de les cançons.

Les recomanacions solen tenir similituds en la popularitat, l'artista o fins i tot la presència de les cançons en les llistes de reproducció més escoltades, que acostumen a ser influenciades per les discogràfiques. Com a resultat, la recomanació pot presentar un biaix que tendeix a afavorir els artistes consolidats, i a deixar en un segon pla les propostes emergents o menys conegudes.

Aquest treball de fi de grau s'emmarca dins d'un projecte en col·laboració amb la meva companya Lucía Carmo-

na, que busca detectar l'existència de patrons entre els èxits musicals del moment, i com poden ser utilitzats per generar cançons amb un gran potencial. Concretament, aquest treball se centra en la fase prèvia d'exploració i anàlisi de similituds entre les cançons més escoltades de l'any passat, i en com desenvolupar un sistema de recomanació basat en el contingut acústic de les cançons.

La hipòtesi que es planteja és que els sistemes de recomanació actuals tenen en compte criteris comercials que afecten la recomanació per contingut musical, cosa que pot limitar el descobriment de cançons, que malgrat compartir similituds amb les cançons del moment, manquen de visibilitat. Mitjançant aquesta anàlisi de similitud acústica, es busca aportar una alternativa més objectiva en la recomanació de cançons.

2 OBJECTIUS

Per tal d'aconseguir la finalitat del projecte, es plantegen els següents objectius:

- E-mail de contacte: marc.puigbo@autonoma.cat
- Tutoritzat per: Débora Gil Resina i Aura Hernandez Sabate (Àrea de Ciències de la Computació i Intel·ligència Artificial)
- Curs 2024/25

- Crear una base de dades recopilant les cançons més escoltades de l'any passat, explorant i analitzant les cançons per obtenir la informació necessària.

- Explorar tècniques d'extracció de característiques d'àudio, per obtenir una representació del contingut acústic de les composicions musicals
- Detectar i analitzar patrons o tendències entre cançons a partir de les seves característiques acústiques i estructurals, explorant diferents tècniques de processament de senyal, i aprenentatge computacional.
- Desenvolupar un sistema de recomanació basat en contingut, considerant les característiques acústiques de les cançons, evitant factors externs com la popularitat o el nombre de reproduccions.

3 ESTAT DE L'ART

3.1 Extracció de característiques

L'extracció de característiques és una part necessària per detectar similituds entre cançons, és la base per obtenir bons resultats. És una fase present en la gran majoria d'articles sobre recuperació d'informació musical (MIR).

Diversos estudis utilitzen tècniques d'extracció aplicades a diferents dominis. L'article escrit per Mahajan, Kaavya (2023) [1], fa servir característiques com *chroma_sft* (energia harmònica distribuïda per notes musicals), *rmse* (nivell d'energia del senyal), *spectral_centroid* (centre de gravetat espectral que indica la brillantor del so) i, *spectral_rolloff* (freqüència per sota de la qual es concentra la major part de l'energia espectral), amb l'objectiu de classificar cançons. La investigació de Méndez, Miguel (2020) [2], es basa en l'ús de l'espectrograma, aplicant filtres per extreure una empremta digital única de cada fragment d'àudio, orientat al reconeixement automàtic musical. L'estudi de A. García-Hernandez (2017) [3], utilitza els MFCCs (coeficients ceps-trals de freqüència, que modelen com percebem el timbre del so) en el desenvolupament d'un sistema de reconeixement d'activitats humanes.

Cal destacar la importància de la Transformada de Fourier de Curt Temps (STFT), permet obtenir una representació (temps-freqüència) del senyal, essencial per analitzar canvis espectrals al llarg del temps.

L'aprenentatge profund també està present en l'extracció de característiques d'àudio. A diferència de les característiques anteriors utilitzades per captar propietats concretes del senyal, els models són entrenats per aprendre representacions inspirades en la similitud perceptiva.

OpenL3 es basa en dos articles [4][5], es presenta com una implementació oberta i optimitzada per obtenir embeddings d'àudio en diferents contextos. El model és multimodal no supervisat, format per una xarxa neuronal convolucional profunda que rep com a entrada un espectrograma Mel. El sistema s'entrena per predir si un fragment d'àudio coincideix amb una imatge, el que ajuda a representar sons d'una manera que conserva significat semàntic, no només característiques com el to o la intensitat.

3.2 Detecció de patrons i/o tendències

Per agrupar elements similars, existeixen diferents mètodes. Segons la disponibilitat d'etiquetes a les dades, poden ser supervisats i no supervisats. En el cas d'agrupacions supervisades s'usen models per a la classificació o regressió,

com SVM, NN... Però en el cas dels no supervisats, la millor opció són els algorismes clustering, que descobreixen estructures o grups latents sense informació prèvia.

L'algoritme K-Means [6] és un dels algorismes d'agrupació no supervisada més coneguts i utilitzats en ciència de dades. La seva funció és agrupar un conjunt de dades en "k" grups (clústers) basant-se en la similitud entre punts, normalment mesurada per la distància euclidiana. Concretament, el funcionament es basa en els següents passos: 1) Especificació de "k" grups a formar. 2) Definició aleatòria de "k" punts com a centroides. 3) Assignació de cada punt del conjunt a un dels "k" grups amb el centroide més proper. 4) Càlcul dels centroides per cada clúster. 5) Iteracions de l'algoritme fins a tenir agrupacions sense canvis de centroide, o fins que s'arriba a un màxim d'iteracions, és a dir, l'algoritme convergeix. El DBSCAN (Density-Based Spatial Clustering of Applications with Noise) [7] es basa en la densitat de punts per formar agrupacions, no és necessari prèviament definir el nombre de clústers i identifica el soroll del conjunt de dades.

El HDBSCAN (Hierarchical DBSCAN) [8] és una extensió del DBSCAN que crea una jerarquia de densitats i selecciona automàticament el nombre òptim de clústers.

3.3 Sistemes de recomanació musical

L'àmbit musical és un escenari interessant per implementar els sistemes de recomanació. Entre els tipus de sistemes de recomanació més habituals es troben el filtratge col·laboratiu, que fa recomanacions basades en els comportaments d'usuaris similars, el filtratge basat en contingut, que utilitza característiques de productes per trobar similituds, i els sistemes híbrids, que combinen els dos mètodes anteriors per obtenir millors resultats.

Actualment, les aplicacions com Spotify, Apple Music o Youtube fan servir sistemes de recomanació bastant sofisticats per suggerir contingut musical. Encara que fan servir els sistemes híbrids, les recomanacions no són completament precises pel que fa a la similitud sonora entre cançons, sovint són semblants en gènere musical, artista o popularitat. Les llistes de reproducció que ofereix Spotify [9][10] estan influenciades per les empreses, cosa que afecta directament els resultats de la recomanació.

4 METODOLOGIA

Pel desenvolupament del treball, he seguit una planificació estructurada en diferents fases que m'han permès una millor organització i comprensió del procés. En primer lloc, he creat la base de dades amb les cançons més escoltades globalment del 2024, fent una recerca per identificar les fonts de dades, determinar quins atributs eren necessaris i quin processament calia aplicar sobre les dades. A continuació, he explorat el camp de l'extracció de característiques d'àudio i he revisat diversos articles similars per saber quines característiques són les més utilitzades. Al mateix temps, he dut a terme un estudi de l'estat de l'art dels sistemes de recomanació, analitzant les plataformes digitals més populars i consultant diferents articles. També, he estudiat sistemes per detectar patrons similars entre cançons mitjançant l'ús de característiques extretes. Finalment, he implementat un sistema de recomanació basat en contingut

per comparar els resultats amb un sistema d'una plataforma popular. A la Figura 1 es pot observar l'esquema metodològic del treball.




Fig. 1: Esquema de la metodologia del treball

4.1 Processament de BD

La base de dades està formada per les 200 cançons de la Billboard Global 200 Songs End of Year [11], les més escoltades l'any 2024. Aquestes cançons han estat processades en fragments de 12 segons, a causa de la diversitat de la cançó, no totes les parts són iguals, i el mètode de detecció de similituds podria no detectar-les.

Per passar-li a la meua companyia la informació de les similituds entre les cançons, necessitem convertir els mp3 en arxius MIDI (Musical Instrument Digital Interface) [12]. El format MIDI és un format estàndard per guardar instruccions musicals en format digital. No té àudio, sinó la informació que ens indica com un dispositiu o programari ha d'interpretar una composició musical. Alguns aspectes són les notes musicals, la duració de les notes, la intensitat de cada nota, tempo, instruments, entre d'altres. En el projecte de la meua companyia, la intel·ligència artificial generativa que implementa utilitza aquest format. Per analitzar cançons es necessita més informació que únicament el contingut acústic, s'ha de descriure les cançons originals d'alguna manera. Per això, s'ha creat un fitxer de metadades que descriu les 200 cançons triades. A la Taula 1 tenim la descripció estadística de les dades del conjunt. Cada cançó pot tenir diversos gèneres, a la Taula 2 es pot observar la distribució de les cançons respecte als gèneres musicals.

Per veure la popularitat de cada gènere dins la base de dades, es representa amb un diagrama de caixa la distribució de les posicions de les cançons agrupades per gènere.

Si s'analitza el gràfic de la Figura 22 situada a l'annex, es pot observar com la majoria dels gèneres tenen cançons al llarg de tot el top, però hi ha alguns gèneres que es classifiquen en un clar percentil.

És el cas dels gèneres 'Corridos Tumbados' i 'Indie'; se situen en extrems diferents, un a la part més baixa de la classificació i l'altre a posicions més altes respectivament.

TAULA 1: DESCRIPCIÓ METADADES DE LES CANÇONS DE LA BD.

Metadata	Valors	Descripció
Genres	45 gèneres únics	Gèneres de la cançó
Authors	187 autors únics	Intèrpretes de la cançó
Duration	Rang: [1:27, 6:23] μ : 3:40	Duració
Num fragments	Rang: [7,31] μ : 16,57	Nombre de fragments
Song	-	Nom de la cançó
Filename	-	Nom de l'arxiu dins la BD
Ranking	Rang: [1,200]	Posició dins el top 200

TAULA 2: DISTRIBUCIÓ DE CANÇONS PER GÈNERE MUSICAL.

Genres	Nº Songs	Genres	Nº Songs
Pop	61	Corridos Tumbados	10
Hip-Hop	33	Country	10
R&B	19	Rock	8
Rap	18	Indie	7
Synth Pop	17	Alternative Rock	6
Dance Pop	14	Soul	6
Reggaeton	12	Country Pop	5
Latin Urban	11	Alternative Pop	5
Pop Rock	11	Indie Pop	5
Trap	10		

4.2 Extracció de característiques

Davant la gran diversitat de característiques que hi ha per extreure informació, s'ha dividit l'espai en tres subespais diferents. En aquest apartat es defineixen i s'explica la funció de les característiques triades.

4.2.1 Subespai de característiques 1

La primera característica triada és la velocitat de pas zero (ZCR en anglès), una eina d'anàlisi en el domini temporal que ens ajuda a calcular la freqüència d'àudio. Concretament, mesura la quantitat de vegades que un senyal d'àudio creua l'eix zero, és a dir, canvia de positiu a negatiu.

$$zcr = \frac{1}{T-1} \sum_{t=1}^{T-1} |\text{sgn}[s(t)] - \text{sgn}[s(t-1)]| \quad (1)$$

Com es pot veure a l'equació 1, es comparen els signes de cada parell de mostres consecutives definides com a $s(t)$ i $s(t-1)$. Si són diferents, significa que el senyal ha creuat el zero, i s'incrementa el valor. Al final, es normalitza dividint pel total de transicions possibles ($T-1$).

La segona característica triada s'anomena centroides espectral, ens indica on se situa el centre de la massa d'un so. En una cançó on tenim freqüències altes a l'instant $[t]$, el centroides tindrà un valor alt; en canvi, en una cançó amb

frequències més baixes, el centroide serà més baix.

$$\text{centroide}[t] = \frac{\sum_k S[k, t] \cdot \text{freq}[k]}{\sum_k S[k, t]} \quad (2)$$

L'equació 2 defineix la fórmula del càlcul del centre de massa en un instant (t). Per un instant "t" (una columna de l'espectrograma "S"), es multiplica cada magnitud ($S[k, t]$) per la seva freqüència associada ($\text{freq}[k]$), se sumen tots els productes i es divideix per la suma total de magnituds en aquell instant ($S[k, t]$).

Com a tercera característica s'ha triat l'amplada de banda espectral d'ordre p. És una mesura de dispersió de l'espectre respecte al centroide espectral. En altres paraules, serveix per determinar el rang de freqüències d'un senyal. Una amplada alta indica un so més complex, en canvi, un nivell més baix, correspon a un so més suau i pur.

$$\text{ABE}[t] = \left(\sum_k S[k, t] \cdot (\text{freq}[k] - \text{centroide}[t])^p \right)^{\frac{1}{p}} \quad (3)$$

El càlcul de l'amplada de la banda espectral, abreujat com ABE a l'equació 3, es resumeix com la distància mitjana (elevada a la potència "p") entre cada freqüència ($\text{freq}[k]$) i el centroide espectral ($\text{centroide}[t]$), ponderada per la seva magnitud ($S[k, t]$).

Una altra característica triada és l'arrel de la mitjana del quadrat (de l'energia), també anomenada RMS, que mesura l'energia de la cançó, és a dir, com de forta o intensa és en mitjana.

$$\text{RMS} = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2} \quad (4)$$

En resum, el càlcul de l'equació 4 consisteix a elevar al quadrat tots els valors del senyal, treure la mitjana i després calcular l'arrel quadrada. El que defineix el volum o potència sonora d'un fragment d'àudio. Per completar aquest subespai, es calcula el tempo de la cançó, que es basa en el càlcul de beats per minut.

4.2.2 Subespai de característiques 2

En aquest subespai es calculen els coeficients cepstrals de freqüència Mel. Són un conjunt de característiques (entre 10 i 20 normalment) que descriuen de forma concisa la forma general de l'espectre basat en la percepció auditiva humana. D'aquesta forma ens aporta informació sobre el timbre de la cançó. En primer lloc, per calcular els coeficients, se separa el senyal en petits trams. A continuació a cada tram se li aplica la transformada de Fourier discreta per obtenir la potència espectral del senyal. Després se li aplica el banc de filtres corresponents de l'escala Mel [13] a l'espectre del pas anterior, i se sumen les energies de cada espectre. Finalment, es calcula el logaritme de totes les energies de cada freqüència Mel, l'escala del to que percebem els humans, i se li aplica la transformada de cosinus discreta. Els valors resultants són els coeficients cepstrals de freqüència Mel.

4.2.3 Subespai de característiques 3

L'extracció de característiques de l'últim subespai es tracta de la funció de la llibreria 'librosa' [14] *chroma stft* que

calcula un cromatograma a partir d'un senyal acústic. És útil per detectar acords, i identificar la tonalitat de la cançó, mesurant l'energia en les 12 classes de notes musicals independentment de l'octava en la qual es trobin. Per extreure aquesta informació, es genera un espectrograma dividint el senyal en x fotogrames. A cada fotograma se li aplica la transformada de Fourier, i utilitzant una escala logarítmica s'associa una nota musical a cada freqüència. Les freqüències que corresponen a cada nota se sumen independentment de l'octava, i obtenim un vector de 12 valors per fotograma de temps, representant la intensitat de cada nota en aquell instant.

4.3 Detecció de patrons

Per assolir l'objectiu de detectar i analitzar patrons de similitud entre cançons, s'ha fet servir l'algoritme d'agrupació no supervisat DBSCAN que permet explorar la distribució i relacions entre les cançons. L'algoritme DBSCAN (*Density-Based Spatial Clustering of Applications with Noise*), genera agrupacions de punts amb alta densitat dins de l'espai de característiques, alhora que diferencia els punts que no pertanyen a cap grup classificant-los com a punts atípics. A diferència d'altres algorismes, DBSCAN no requereix l'especificació prèvia del nombre d'agrupacions, cosa que afavoreix l'exploració de dades. L'algoritme es basa en tres conceptes clau: 1) Els punts centrals que tenen com a mínim un nombre especificat de punts (anomenats "*minSamples*") a una distància determinada (que rep el nom d'"èpsilon"). 2) Els punts fronterers que es troben dins de la distància "èpsilon" d'un punt central, però no tenen un nombre suficient de veïns "*minSamples*". 3) Els punts de soroll que no es troben prou a prop de cap punt per a ser inclosos. DBSCAN utilitza dos paràmetres principals, l'"èpsilon" que determina la distància màxima entre dos punts per considerar-los veïns. I *minSamples* que especifica el nombre mínim de punts necessaris per formar una regió densa. A la Figura 23 situada a l'annex, es detalla el funcionament de l'algoritme amb un diagrama de flux. És important assenyalar que l'elecció dels paràmetres pot afectar significativament els resultats de l'agrupació. I que els paràmetres òptims poden variar segons el conjunt de dades utilitzat. L'ús d'aquest algoritme, permet estudiar les tendències d'agrupació entre els fragments de les cançons, observant si es formen clústers en funció de variables com el gènere musical, la posició al rànking de Billboard o similituds acústiques.

4.4 Sistema de recomanació

La hipòtesi del treball especifica que els sistemes de recomanació actuals, que es fan servir en plataformes com "Spotify", tenen en compte criteris comercials com la popularitat de l'artista, o les interaccions globals amb composicions musicals, per sobre de la similitud musical real. El que comporta una limitació de descobrir nova música amb característiques similars a les més populars, però que no disposen de suport comercial. Per evitar-ho, es planteja una alternativa d'un sistema de recomanació basat exclusivament en les característiques acústiques de les cançons, excloent la popularitat, les reproduccions i els artistes populars del moment. Les metadades de la base de dades no

s'utilitzaran perquè es vol observar l'impacte que té el contingut musical en les recomanacions, i si és suficient per a satisfer les necessitats de l'usuari. Per això, també es proposa una comparació entre el sistema desenvolupat i el sistema de recomanació d'una plataforma popular, amb la finalitat d'acceptar o refutar la hipòtesi, i valorar els resultats de les recomanacions. El funcionament del sistema proposat, es basa a utilitzar l'algoritme KNN amb l'espai total de característiques, per garantir que les cançons siguin tan similars com sigui possible. A partir d'escollir una cançó del rànquing "Top 200 de Billboard", es calcula la distància euclidiana entre els fragments de la cançó i la resta de la base de dades. Per cada fragment de la cançó seleccionada, el KNN retorna els 10 fragments més propers. Finalment, els fragments s'agrupen per cançó d'origen, identificant les 10 cançons que presenten un major nombre de fragments únics, retornant a l'usuari el top 10 de cançons recomanades.

5 DISSENY EXPERIMENTAL

En aquest apartat, es descriuen els experiments dissenyats per assolir els objectius establerts. La detecció i anàlisi de patrons o tendències entre cançons, així com la validació del sistema de recomanació proposat.

D'una banda, es faran diferents experiments amb l'objectiu d'analitzar els resultats de l'algoritme d'agrupació no supervisat DBSCAN. Aquests experiments consistiran en l'ajust de diferents configuracions del paràmetre de densitat mínima, és a dir, el mínim de punts per formar un grup, i de la distància màxima d'agrupació (èpsilon), per examinar com aquestes variacions afecten la formació de grups. Les diferents proves es faran per tots els subespais de característiques i per l'espai total.

D'altra banda, es farà una anàlisi i avaluació dels resultats del sistema de recomanació proposat. Fent proves amb un conjunt d'usuaris reals, que permeten avaluar la qualitat de les recomanacions i la seva relació amb les similituds acústiques.

Adicionalment, es compararan els resultats amb els generats per un sistema de recomanació d'una plataforma musical popular, per determinar si les recomanacions basades exclusivament en contingut poden oferir una alternativa vàlida a les estratègies comercials actuals.

5.1 Distribució de distàncies entre fragments

L'objectiu del primer experiment és explorar la distribució de distàncies entre fragments musicals en diferents subespais de característiques, així com en l'espai total. Cada subespai representa un o alguns aspectes musicals (to, tonalitat, energia, timbre...), l'anàlisi d'aquests espais de manera separada ajuda a observar quins aspectes musicals generen una major similitud entre les cançons.

Per dur a terme l'anàlisi, farem el gràfic de les k-distàncies, que consisteix a calcular, per a cada punt, la distància al seu k-èsim veí més proper, que en aquest cas s'ha establert a 8, per tenir un nombre no molt petit, ni molt gran. Seguidament, aquestes distàncies s'ordenen de menor a major, obtenint una corba d'utilitat per identificar el valor òptim del paràmetre èpsilon de l'algoritme DBSCAN, que defineix la distància màxima entre punts per considerar-los

dins d'una mateixa agrupació. El punt òptim es troba en el "colze" de la corba, és a dir, en el punt on el pendent augmenta significativament.

5.2 Estudi del comportament del DBSCAN

El segon experiment s'enfoca a analitzar el comportament de l'algoritme DBSCAN en funció de la variació dels seus paràmetres: la distància màxima (èpsilon), i el nombre mínim de punts "minSamples". L'experiment és necessari per entendre com els paràmetres afecten la capacitat de l'algoritme per detectar agrupacions dins dels diferents subespais de característiques, i dins de l'espai total.

Aquest estudi es presenta com a continuació de l'experiment de la subsecció 5.1, on es determina un valor òptim d'èpsilon mitjançant l'anàlisi de les distàncies. Per dur a terme l'experiment s'explora el comportament del DBSCAN al voltant d'aquest valor òptim, i així determinar amb més detall la sensibilitat de l'algoritme, observant com canvien les agrupacions generades i la proporció de punts considerats atípics.

Per visualitzar el comportament, es generen dues gràfiques. La primera representació mostra el nombre de clústers generats en funció del valor d'èpsilon, per a diferents configuracions de "minSamples", concretament (4, 6, 8 i 10). La segona gràfica representa el percentatge de punts classificats com a atípics sota la mateixa estructura.

5.3 Tendència de classificació per rànquing

L'objectiu d'aquest experiment és analitzar si existeix una tendència d'agrupació entre les cançons en funció de la seva posició al rànquing Billboard. Es busca determinar si les cançons que ocupen les deu primeres i últimes posicions de la classificació tendeixen a agrupar-se de manera diferenciada.

Amb això, es pot avaluar si les cançons populars tendeixen a compartir patrons acústics més similars entre si, formant clústers més sòlids i amb menys presència de punts atípics, o, per contra, la seva posició no reflecteix cap similitud observable.

Per tal de visualitzar aquesta informació, es representaran dos gràfics de dispersió. A cada gràfic, per a cada cançó, es mostra el nombre de clústers únics en què s'han classificat els seus fragments, així com el percentatge de fragments que han estat identificats com a punts atípics per l'algoritme. Cada punt del gràfic representa una cançó, distingint-los pel seu color i forma. En el primer gràfic es mostren els resultats corresponents a les deu primeres cançons del rànquing, i en el segon els corresponents a les darreres cançons de la classificació.

5.4 Tendència de classificació per gènere

Amb l'objectiu d'analitzar la tendència de classificació dels fragments, s'ha desenvolupat una eina de visualització interactiva que permet examinar com els fragments s'agrupen progressivament en clústers.

L'estructura del gràfic interactiu està formada per tres gràfics que es basen en la reducció de dimensionalitat mitjançant tres tècniques: 1) l'anàlisi de components principals (PCA), 2) La incrustació estocàstica de veïns propers

amb distribució t (tSNE), 3) Aproximació i projecció uniforme de varietats (UMAP). Es mostrarà cada punt en els tres gràfics per tenir més opcions de visualitzacions. Cada punt en el gràfic correspon a un fragment musical, i es representa amb dos atributs: el color indica el clúster que forma part, i la forma geomètrica representa el gènere musical. Per facilitar la visualització s'ha tornat a classificar els fragments en gèneres, evitant els gèneres específics (Pop Rock, Country Pop). S'han classificat en gèneres globals (Pop, Rock, Indie)...

El gràfic incorpora un control per augmentar o disminuir el valor de l'èpsilon, actualitzant la classificació dels fragments. Per millorar l'anàlisi cada fragment té incorporat una etiqueta amb el títol de la cançó, el gènere assignat i el clúster al qual pertany. Addicionalment, per ajudar a la comprensió del gràfic, s'inclou una llegenda amb informació dels gèneres i els clústers. El gràfic es troba en el repositori Git: <https://github.com/NIU1636671/TFG>

5.5 Avaluació del sistema de recomanació

L'últim experiment del projecte se centra a avaluar la qualitat del sistema de recomanació desenvolupat, tant en comparació amb un sistema de recomanació d'una plataforma musical popular com a través de la valoració d'usuaris. Aquesta avaluació es mostrarà mitjançant quatre taules. La primera i segona taula representen una anàlisi objectiva de les característiques de les recomanacions generades pels sistemes propi i popular respectivament, i la tercera i quarta taula descriuen la valoració subjectiva de les recomanacions basada en la percepció dels usuaris.

S'ha demanat a cinc voluntaris que escullin una cançó que els agradés de les 200 cançons de la base de dades. A partir de la cançó d'origen, es generen dues llistes de recomanacions: una generada pel sistema desenvolupat (basat en similitud acústica), i una altra, utilitzant un sistema de recomanació d'una plataforma comercial.

La valoració objectiva està formada per aspectes com: el percentatge de cançons del mateix gènere de la cançó original, el percentatge de cançons d'altres gèneres, la mitjana i interval de posicions dins del rànking de Billboard per les recomanacions del sistema propi, i per acabar, la mitjana i interval de reproduccions (en milions) pel sistema popular.

La valoració subjectiva mostra informació com: la quantitat de cançons recomanades que als usuaris els agraden, i, la quantitat de cançons recomanades que s'assemblen a la cançó seleccionada per l'usuari.

6 RESULTATS

A continuació, es presenten els resultats obtinguts a partir dels experiments descrits en el disseny experimental.

6.1 Distribució de distàncies entre fragments

Iniciem l'anàlisi amb la representació del primer subespai que es mostra a la Figura 2, aquest subespai com s'ha explicat anteriorment destaca per contenir característiques que determinen l'activitat temporal, freqüencial i enèrgica de les cançons, que en aspectes musicals, es tradueix en la intensitat sonora, to i ritme. En aquest cas l'èpsilon que el gràfic ens recomana, es troba en 1.06.

Seguim l'anàlisi amb el segon subespai de característiques, que se centra en l'espectre de l'àudio. En aquest cas s'observa a la Figura 3 que les distàncies, a diferència del primer subespai, són més elevades i que l'èpsilon òptima hauria de ser 4.28. En aspectes musicals ens dona informació sobre el timbre de la cançó. Comparant el primer i segon subespai, els fragments tenen més similitud en aspectes d'intensitat sonora, to o ritme, que en el timbre de la cançó, perquè l'èpsilon òptima del primer subespai és menor que la del segon.

Gràfic de K-distàncies i estimació d'èpsilon òptim (Subespai 1)




Fig. 2: Distribució de distàncies del primer subespai

Gràfic de K-distàncies i estimació d'èpsilon òptim (Subespai 2)




Fig. 3: Distribució de distàncies del segon subespai

A la gràfica de la Figura 4 es mostra la distribució de distàncies del tercer subespai. L'èpsilon òptima per aquest subespai és de 2.63. És una característica que ens aporta informació musical com la similitud d'acord i la tonalitat de la cançó. Comparant amb els altres subespais presenta distàncies menys elevades que el segon espai, però més elevades que el primer. Per tant, es pot dir que la característica on més similitud hi ha és en el to, la intensitat sonora i l'energia de la cançó.

Per finalitzar l'anàlisi, s'ha realitzat un estudi de la distribució de distàncies considerant totes les característiques. Com s'observa a la Figura 5 presenta les distàncies més elevades que en els altres casos, i no sorprèn, perquè com més característiques considerem, més informació tindrem dels fragments i menys similars seran entre ells. L'èpsilon òptima se situa a 5.75.




Fig. 4: Distribució de distàncies del tercer subespai




Fig. 5: Distribució de distàncies de l'espai total




Fig. 6: Generació de clústers variant els paràmetres d'agrupació per l'espai total




Fig. 7: Percentatge de punts atípics variant els paràmetres d'agrupació per l'espai total

6.2 Estudi del comportament del DBSCAN

L'anàlisi dels clústers generats en diferents subespais es mostra de forma detallada a les Figures 10 a 15 (incloses en l'annex). Aquestes figures mostren la sensibilitat del paràmetre èpsilon i el nombre mínim de punts per formar clústers. Es mostren variacions notables en la quantitat de clústers i punts atípics segons els valors utilitzats. En general, un menor valor de "minSamples" genera més clústers, mentre que valors elevats redueixen la quantitat de clústers, possiblement indicant agrupacions més coherents. La tendència comuna és la reducció de punts atípics a mesura que augmenta èpsilon, encara que aquesta disminució és més o menys gradual segons l'espai. En concret, el nombre de clústers que arriba a generar l'algoritme en els subespais 1, 2 i 3, és 120, 140 i 60 respectivament.

La Figura 6, corresponent a l'espai total de característiques, destaca per generar la quantitat més gran de clústers (fins a 200). A diferència dels subespais, aquí la disminució de clústers amb l'augment d'èpsilon és més suau, suggerint una estructura més complexa. La Figura 7 complementa aquesta observació, mostrant que, tot i augmentar la distància màxima d'agrupació, es mantenen alguns punts atípics. Això indica que, en integrar totes les característiques, es fa més difícil identificar patrons comuns entre els fragments, evidenciant la presència d'elements clarament atípics.

En conjunt, s'observa que el segon subespai i l'espai total són els que produeixen més clústers, mentre que el tercer subespai genera agrupacions molt més simples. En relació amb els punts atípics, el primer subespai és el que presenta

una reducció més accentuada, mentre que l'espai total mostra persistència de punts atípics fins i tot amb èpsilons elevades. Això pot reflectir la dificultat de trobar semblances globals entre fragments quan es combinen totes les dimensions.

6.3 Tendència de classificació per rànkung

L'anàlisi dels clústers generats en funció de la posició presenta resultats diversos. Les Figures 16 a 21 (incloses en l'annex) representen els resultats obtinguts per als diferents subespais de característiques, mentre que les Figures 8 i 9 se centren en l'espai total.

En general, s'observa que les cançons situades en posicions més baixes del rànkung tendeixen a generar un nombre lleugerament superior de clústers respecte a les que ocupen les primeres posicions, amb l'excepció del tercer subespai, on es produeix el cas contrari. Per ser més precís, als subespais 1 i 2 les cançons de posicions inferiors generen fins a 3 i 4 clústers diferents, mentre que les del top 10 n'arriben a generar com a màxim 2 o 3.

No obstant això, pel que fa al subespai 3 i, especialment, a l'espai total de característiques en les Figures 6 i 7, les primeres cançons generen fins a 4 clústers, i les darreres cançons en generen 2 i 3.

Per tant, veient la variabilitat de resultats que hi ha entre subespais i l'espai total de característiques, així com la poca

diferència en el nombre de clústers obtinguts, es conclou que no hi ha una tendència clara de classificació segons la posició en el rànquing de Billboard.




Fig. 8: Classificació de fragments a l'espai total de les primeres cançons del rànquing Billboard




Fig. 9: Classificació de fragments a l'espai total de les darreres cançons del rànquing Billboard

6.4 Tendència de classificació per gènere

L'anàlisi del gràfic interactiu mostra una clara tendència de classificació per gènere musical. A mesura que la distància màxima augmenta els fragments es van agrupant progressivament en l'espai. Els clústers que es formen mostren més proximitat en l'espai si contenen cançons del mateix gènere. El gràfic mostra el comportament descrit en l'experiment analitzat a la subsecció 6.2. Inicialment, l'algoritme detecta petits clústers que van creixent a mesura que l'èpsilon augmenta, però arriba un punt, on els clústers es comencen a fusionar, fent disminuir el nombre de clústers fins a convergir en un únic clúster que engloba tots els fragments.

TAULA 3: RESULTATS ESTADÍSTICS DE LES RECOMANACIONS DEL SISTEMA PROPI

SISTEMA RECOMANACIÓ PROPI				
	% Gèneres relacionats	% Altres gèneres	μ Ranking	Int. Ranking
s_1	87%	13%	80,9	[7 - 196]
s_9	24%	76%	117,3	[12 - 194]
s_19	13%	87%	90,6	[23 - 197]
s_142	56%	44%	76,2	[10 - 143]
s_156	36%	64%	108,8	[35 - 191]

TAULA 4: RESULTATS ESTADÍSTICS DE LES RECOMANACIONS DEL SISTEMA POPULAR

SISTEMA RECOMANACIÓ POPULAR				
	% Gèneres relacionats	% Altres gèneres	μ Repr. (en M)	Int. Repr. (en M)
s_1	70%	30%	1075,1	[11 - 3063]
s_9	90%	10%	785,4	[245 - 1303]
s_19	40%	60%	1751,1	[304 - 3934]
s_142	80%	20%	309	[13 - 1105]
s_156	70%	30%	1113,9	[563 - 2670]

6.5 Avaluació del sistema de recomanació

La informació presentada a la Taula 3 recull, per a cada cançó seleccionada pels usuaris, les estadístiques de les recomanacions generades pel sistema de recomanació propi. La primera columna mostra el percentatge de gèneres que coincideixen amb el gènere de la cançó escollida, o que són similars, mentre que la segona reflecteix el percentatge de gèneres diferents.

En general, s'observa una presència destacada del gènere de la cançó inicial en les recomanacions. No obstant això, en alguns casos es detecta una major proporció de cançons de gèneres diferents, el que podria indicar que la limitada mida de la base de dades condiciona els resultats del sistema. També es podria explicar pel fet que, tot i que una cançó estigui etiquetada amb un gènere concret, presenti influències d'altres estils musicals, cosa que afavoreix la recomanació de cançons de gèneres diversos.

Pel que fa a la Taula 4, les dues primeres columnes ofereixen la mateixa informació, però corresponent al sistema de recomanació d'una plataforma popular. Té una major presència de cançons del gènere de la cançó seleccionada, encara que també es mantenen proporcions significatives d'altres gèneres.

Analitzant les dues últimes columnes de la Taula 3, es desprèn que el sistema propi no té en compte la posició en el rànquing de Billboard, ja que les cançons recomanades abasten un ampli ventall de posicions. Les darreres columnes de la Taula 4 representen dades sobre la mitjana de reproduccions i l'interval de reproduccions de les cançons recomanades, perquè les cançons que recomana el sistema de la plataforma popular no estan dins la BD, per tant, no es poden calcular les estadístiques del rànquing. A partir de l'anàlisi, es pot afirmar que aquestes cançons tenen, en general, un nombre elevat de reproduccions, totes superen el milió, i que aquelles amb menys reproduccions solen correspondre a nous llançaments d'artistes populars o similars.

TAULA 5: VALORACIONS D'USUARIS A LES RECOMANACIONS DEL SISTEMA PROPI

Sistema Propi		
Cançó Triada	Quantes t'agraden?	Quantes s'assemblen?
song_1	9	8
song_9	7	5
song_19	10	6
song_142	10	9
song_156	9	6

TAULA 6: VALORACIONS D'USUARIS A LES RECOMANACIONS DEL SISTEMA POPULAR

Sistema Popular		
Cançó Triada	Quantes t'agraden?	Quantes s'assemblen?
song_1	10	9
song_9	8	8
song_19	10	8
song_142	10	8
song_156	8	8

Així, es pot validar la hipòtesi inicial del projecte, segons la qual les recomanacions d'aquesta plataforma estan influenciades per criteris comercials, fet que pot perjudicar la visibilitat d'artistes emergents.

Les Taules 5 i 6 mostren una comparativa subjectiva per part dels usuaris entre els dos sistemes de recomanació: la Taula 5 correspon al sistema propi desenvolupat, i la Taula 6 a les valoracions del sistema de la plataforma musical popular.

En general, les puntuacions en ambdós sistemes són força altes, però es poden observar algunes diferències. En el cas de les recomanacions del sistema popular, les respostes a la pregunta "Quantes t'agraden?" són molt elevades, amb diverses puntuacions de 10, concretament en les cançons (song_1, song_19 i song_142), mentre que la semblança de les cançons es manté valorada en un 8.

En canvi, les recomanacions del sistema propi presenten una variabilitat major per les dues preguntes. Per exemple, l'usuari que se li ha recomanat cançons similars a la song_9, ha respost amb un 7 la pregunta "t'agraden?", i només amb un 5 "s'assemblen" el que indica una recomanació menys encertada.

Les dades suggereixen que el sistema propi se situa un punt per sota en la mitjana de respostes a la pregunta "T'agraden?" el que pot significar una equivalència amb el sistema popular o, la necessitat de provar amb més mostres per observar diferències significatives.

Pel que fa a les puntuacions de la semblança de les recomanacions, el sistema propi s'allunya una mica de l'objectiu inicial. Hi ha opinions que indiquen que les recomanacions no acaben d'assemblar-se entre elles, però el fet que a l'usuari li agradin les recomanacions, pot ser que el sistema s'estigui basant en paràmetres que no són tan tangibles per a l'usuari, i al mateix temps recomana cançons que agraden.

Cal destacar, però, que les recomanacions pròpies poden

estar limitades per la quantitat de cançons disponibles a la base de dades d'alguns gèneres, la qual és molt més reduïda en comparació amb la gran varietat que ofereix una plataforma comercial. Aquesta limitació afecta la capacitat del sistema per oferir recomanacions més afinades o similars, ja que treballa amb un univers molt més restringit. Però, tot i això, els resultats de les recomanacions, són força similars, sobretot per les cançons de gènere Pop. I no tan similars per cançons com Reggaeton, que compten amb 12 cançons dins la base de dades.

7 CONCLUSIONS I TREBALL FUTUR

Per concloure el treball, en aquesta secció s'explicarà que s'ha aconseguit, i el treball futur que es pot considerar per escalar el projecte.

Seguint les fases establertes a la metodologia, s'ha aconseguit crear la base de dades, investigant diverses fonts, implementant els processaments necessaris i recopilant atributs de les dades.

S'han explorat tècniques d'extracció de característiques acústiques, dels quals se n'han generat tres subespais que representen aspectes musicals diferents. En concret, representen el ritme, intensitat sonora, to, timbre, acords i tonalitat.

Per assolir el tercer objectiu, s'ha utilitzat un algoritme capaç de detectar patrons de similitud, i diferents visualitzacions per observar el comportament del model i analitzar els resultats obtinguts.

Tot i que inicialment es buscava una relació entre la similitud acústica i la posició de les cançons en el rànquing Billboard, els resultats mostren que no hi ha una tendència clara d'agrupació.

No obstant això, sí que s'observa una classificació per gènere musical, a mesura que s'augmenta la distància màxima d'agrupació, fins al punt on acaben convergint en un únic clúster. Aquest comportament determina que les característiques extrems representen correctament el contingut acústic.

D'altra banda, a partir de l'anàlisi de la distribució de distàncies dels subespais, i el baix valor de l'èpsilon òptima en el primer subespai. Es conclou que els fragments de la base de dades presenten una major similitud en aspectes com el to, la intensitat sonora i l'energia. El que suggereix que les cançons amb més èxit comparteixen patrons comuns en aquestes dimensions. Per tant, es podria suposar que generar noves cançons amb característiques similars podria augmentar les probabilitats d'èxit.

A partir d'aquests resultats, es decideix proporcionar a la Lucía tot el conjunt de fragments MIDI, amb l'objectiu de què generi noves cançons mitjançant el seu sistema d'IA, agrupant-les per gènere. Tot i això, el seu treball conclou que, malgrat l'ús de la intel·ligència artificial, és necessari incloure un toc humà perquè una cançó connecti amb el públic.

Pel que fa al quart objectiu també ha estat assolit, s'ha aconseguit desenvolupar un sistema de recomanació basat en contingut, considerant les característiques acústiques de les cançons, evitant factors externs com la popularitat o el nombre de reproduccions.

Els baixos resultats en la valoració de la semblança de les recomanacions del sistema propi, mostren que el sistema

s'allunya lleugerament de l'objectiu inicial. Tot i això, el fet que les recomanacions agradin a l'usuari, pot suposar que el sistema es basa en aspectes que no són tan tangibles per l'usuari, i per tant acústicament no tenen similitud, però agraden als usuaris.

A més, s'ha aconseguit validar la hipòtesi plantejada amb la comparació del sistema desenvolupat amb un sistema de recomanació d'una plataforma musical popular. Amb l'anàlisi de les reproduccions de les recomanacions populars, s'observa que les recomanacions tenen milions de reproduccions, i que les cançons amb menys reproduccions recomanades, són cançons noves d'artistes populars, per tant, afirmem que els sistemes de recomanació actuals estan esbiaixats per criteris comercials que afecten les recomanacions per contingut; deixant de banda propostes emergents o cançons poc populars.

Per escalar el treball, es plantegen diferents objectius per un treball futur.

En primer lloc, per millorar l'anàlisi de detecció de patrons, es podria analitzar el comportament dels clústers al llarg de les èpsilons: els que es mantenen, els que apareixen tard, l'evolució de la seva composició, una anàlisi de la seva persistència...

En segon lloc, relacionat amb el sistema de recomanació, caldria avaluar el sistema de recomanació propi amb més usuaris, per determinar el seu funcionament amb precisió.

Finalment, seria interessant analitzar cerebralment amb un EEG, als usuaris del sistema de recomanació reaccionant a les recomanacions proposades. D'aquesta manera, es podria obtenir més informació sobre per què els agraden les recomanacions als usuaris, independentment de la seva semblança acústica.

AGRAÏMENTS

Vull agrair a les meves tutores, Débora i Aura, pel seu suport, i orientació durant tot el procés del TFG.

També vull donar les gràcies a la meva amiga Lucía, per ajudar-me i motivar-me a tirar endavant aquest projecte.

Molt especialment, vull donar les gràcies a la meva família, i en particular als meus pares, pel seu amor, paciència i suport incondicional en tot moment.

This work was supported by the project Càtedra ENIA UAB-Cruïlla (TSI-100929-2023-2)

REFERÈNCIES

- [1] K. Mahajan. "Extracting audio features using Librosa". Medium. Accedit el 20 d'abril de 2025. [En línia]. Disponible: <https://kaavyamaha12.medium.com/extracting-audio-features-using-librosa-3be4ff1fe57f>
- [2] M. Fuentes Méndez and J. M. Gutiérrez Arriola, "Reconocedor automático de patrones musicales," Proyecto Fin de Carrera/Grado, E.T.S.I. y Sistemas de Telecomunicación (UPM), 2020.
- [3] A. García-Hernandez et al, "A Similarity Analysis of Audio Signal to Develop a Human Activity Recognition Using Si-milarity Networks," Sensors, vol. 17, (11), pp. 2688, 2017. Available: <https://www.proquest.com/scholarly-journals/similarity-analysis-audio-signal-develop-human/docview/1977885562/se-2>. DOI: <https://doi.org/10.3390/s17112688>.
- [4] Look, Listen and Learn More: Design Choices for Deep Audio Embeddings Aurora Cramer, Ho-Hsiang Wu, Justin Salamon, and Juan Pablo Bello. IEEE Int. Conf. on Acoustics, Speech and Signal Processing (ICASSP), pages 3852-3856, Brighton, UK, May 2019.
- [5] Look, Listen and Learn Relja Arandjelović and Andrew Zisserman IEEE International Conference on Computer Vision (ICCV), Venice, Italy, Oct. 2017
- [6] K. Babitz. "Introduction to k-Means Clustering with scikit-learn in Python". DataCamp.com. [En línia]. Disponible: <https://www.datacamp.com/tutorial/k-means-clustering-python>
- [7] R. Kumar. "Guía del algoritmo de agrupación DBSCAN". DataCamp.com. [En línia]. Disponible: <https://www.datacamp.com/es/tutorial/dbscan-clustering-algorithm>
- [8] "HDBSCAN". scikit-learn. Accedit el 20 d'abril de 2025. [En línia]. Disponible: <https://scikit-learn.org/stable/modules/generated/sklearn.cluster.HDBSCAN.html>
- [9] "Seguridad y Centro de Privacidad". Como funcionan las recomendaciones.[En línia]. Disponible: <https://www.spotify.com/es/safetyandprivacy/understanding-recommendations>
- [10] J. Hernández. "Cómo el algoritmo de Spotify influye en el consumo de música - Industria Musical". Industria Musical - Otro sitio realizado con WordPress. Accedit el 20 d'abril de 2025. [En línia]. Disponible: <https://industriamusical.com/como-el-algoritmo-de-spotify-influye-en-el-consumo-de-musica/>
- [11] "Billboard Global 200 Songs". Billboard. Accedit el 20 d'abril de 2025. [En línia]. Disponible: <https://www.billboard.com/charts/year-end/billboard-global-200/>
- [12] Colaboradores de los proyectos Wikimedia. "MIDI - Wikipedia, la enciclopedia libre". Wikipedia, la enciclopedia libre. Accedit el 20 d'abril de 2025. [En línia]. Disponible: <https://es.wikipedia.org/wiki/MIDI>
- [13] Contributors to Wikimedia projects. "Escala Mel - Viquipèdia, l'enciclopèdia lliure". Viquipèdia. Accedit el 20 d'abril de 2025. [En línia]. Disponible: https://ca.wikipedia.org/wiki/Escala_Mel
- [14] "Feature extraction — librosa 0.11.0 documentation". Librosa. Accedit el 20 d'abril de 2025. [En línia]. Disponible: <https://librosa.org/doc/main/feature.html>

APÈNDIX

A.1 Figures experiments




Fig. 10: Evolució del nombre de clústers per diferents mínims de punts i valors d'èpsilon en el primer subespai.




Fig. 13: Evolució del percentatge de punts atípics per diferents mínims de punts i valors d'èpsilon en el primer subespai.




Fig. 11: Evolució del nombre de clústers per diferents mínims de punts i valors d'èpsilon en el segon subespai.




Fig. 14: Evolució del percentatge de punts atípics per diferents mínims de punts i valors d'èpsilon en el segon subespai.




Fig. 12: Evolució del nombre de clústers per diferents mínims de punts i valors d'èpsilon en el tercer subespai.




Fig. 15: Evolució del percentatge de punts atípics per diferents mínims de punts i valors d'èpsilon en el tercer subespai.




Fig. 16: Nombre de clústers i percentatge de fragments no classificats per les primeres 10 cançons del primer subespai.




Fig. 19: Nombre de clústers i percentatge de fragments no classificats per les darreres 10 cançons del segon subespai.




Fig. 17: Nombre de clústers i percentatge de fragments no classificats per les darreres 10 cançons del primer subespai.




Fig. 20: Nombre de clústers i percentatge de fragments no classificats per les primeres 10 cançons del tercer subespai.




Fig. 18: Nombre de clústers i percentatge de fragments no classificats per les primeres 10 cançons del segon subespai.




Fig. 21: Nombre de clústers i percentatge de fragments no classificats per les darreres 10 cançons del tercer subespai.




Fig. 22: Distribució de les posicions del rànkung Billboard de les cançons agrupades per gènere.




Fig. 23: Diagrama explicatiu de l'algoritme DBSCAN.