

**SEGMENTAÇÃO ACÚSTICA BASEADA EM K-MEANS PARA MITIGAÇÃO DO VIÉS DE POPULARIDADE EM RECOMENDAÇÕES MUSICAIS****K-MEANS-BASED ACOUSTIC SEGMENTATION FOR MITIGATING POPULARITY BIAS IN MUSIC RECOMMENDATION SYSTEMS****SEGMENTACIÓN ACÚSTICA BASADA EN K-MEANS PARA MITIGAR EL SESGO DE POPULARIDAD EN LAS RECOMENDACIONES MUSICALES**

André Filipe Albuquerque Silva<sup>1</sup>, Martony Demes da Silva<sup>2</sup>, Keylla Maria de Sá Urtiga Aita<sup>3</sup>, Wener Borges de Sampaio<sup>4</sup>  
e768075

<https://doi.org/10.47820/recima21.v7i6.8075>

PUBLICADO: 06/2026

**RESUMO**

Nesta pesquisa, propomos um Sistema de Recomendação Contextual baseado em clusterização acústica. O modelo utiliza o algoritmo *K-Means* ( $k = 6$ ) para segmentar uma amostra de 244.564 músicas do *Spotify* em perfis sonoros estatisticamente distintos. A validação estatística por ANOVA *One-Way* confirmou a distinção de todos os seis *clusters* ( $p < 0,001$ ), garantindo a solidez da segmentação e revelando a estrutura da Cauda Longa. O sistema mapeia esses *clusters* para contextos de uso (e.g., "Foco" → *Cluster Instrumental*) para mitigar o viés de popularidade inerente aos dados. A avaliação experimental comparou o modelo proposto a um *baseline* tradicional de popularidade por meio das métricas *Precision@N* e *Novelty*. A abordagem indicou potencial para elevar o valor de descoberta das recomendações, promovendo a diversidade e reduzindo a dependência de sistemas baseados unicamente em popularidade.

**PALAVRAS-CHAVE:** Aprendizado de Máquina. Engajamento do Usuário. Recomendação de Música.

**ABSTRACT**

*In this research, we propose a Contextual Recommendation System based on acoustic clustering. The model uses the K-Means algorithm ( $k = 6$ ) to segment a sample of 244,564 songs from Spotify into statistically distinct sound profiles. Statistical validation via One-Way ANOVA confirmed the distinction of all six clusters ( $p < 0.001$ ), ensuring the robustness of the segmentation and revealing the Long Tail structure. The system maps these clusters to usage contexts (e.g., "Focus" → Instrumental Cluster) to mitigate the popularity bias inherent in the data. The experimental evaluation compared the proposed model against a traditional popularity baseline using Precision@N and Novelty metrics. The approach indicated potential to enhance the discovery value of recommendations, promoting diversity and addressing the flaws of systems based solely on popularity.*

**KEYWORDS:** Machine Learning. User Engagement. Music Recommendation.

**RESUMEN**

*En esta investigación, proponemos un Sistema de Recomendación Contextual basado en la clusterización acústica. El modelo utiliza el algoritmo K-Means ( $k = 6$ ) para segmentar una muestra de 244.564 canciones de Spotify en perfiles sonoros estadísticamente distintos.*

<sup>1</sup>UNIVERSIDADE FEDERAL DO PIAUÍ, Graduação.

<sup>2</sup>UNIVERSIDADE FEDERAL DO PIAUÍ, Mestrado.

<sup>3</sup>UNIVERSIDADE FEDERAL DO PIAUÍ, Doutorado.

<sup>4</sup>UNIVERSIDADE FEDERAL DO PIAUÍ, Doutorado.



*La validación estadística mediante ANOVA de una vía confirmó la distinción de los seis clusters ( $p < 0,001$ ), garantizando la solidez de la segmentación y revelando la estructura de la Larga Cola (Long Tail). El sistema mapea estos clusters a contextos de uso (p. ej., "Enfoque" → Cluster Instrumental) para mitigar el sesgo de popularidad inherente a los datos. La evaluación experimental comparó el modelo propuesto con un baseline tradicional de popularidad utilizando las métricas Precision@N y Novelty. El enfoque indicó potencial para aumentar el valor de descubrimiento de las recomendaciones, promoviendo la diversidad y reduciendo la dependencia de los sistemas basados únicamente en la popularidad.*

**PALABRAS CLAVE:** Aprendizaje automático, participación del usuario, recomendación musical.

## INTRODUÇÃO

A popularização das plataformas de streaming musical, como o Spotify, transformou profundamente o modo como conteúdos são consumidos, organizados e descobertos pelos usuários. Nesse cenário, os sistemas de recomendação desempenham papel central ao orientar escolhas em meio a catálogos vastos e dinâmicos. Segundo [19], sistemas de recomendação são essenciais para reduzir a sobrecarga de informação e melhorar a experiência do usuário, contribuindo para o engajamento contínuo e para a personalização do consumo. Assim, compreender o funcionamento e o impacto desses sistemas é fundamental para aprimorar o desenho das plataformas, aumentar a fidelização e fortalecer a competitividade no mercado.

Embora os modelos tradicionais, como filtragem colaborativa e recomendações baseadas em popularidade, tenham se mostrado eficazes ao longo dos anos, eles apresentam limitações importantes. Conforme apontado por [17], tais abordagens tendem a reforçar ciclos de repetição e criar o fenômeno da "bolha de filtro", reduzindo a diversidade das recomendações apresentadas. Além disso, sistemas baseados em popularidade perpetuam o viés de popularidade, negligenciando a Cauda Longa da distribuição de consumo e impedindo a descoberta de artistas de nicho.

Para usuários com perfis musicais ecléticos ou que utilizam música em diferentes contextos, como estudo, atividade física ou relaxamento, essa limitação resulta em sugestões pouco variadas e pouco sensíveis às necessidades situacionais. Surge, portanto, a demanda por sistemas capazes de compreender não apenas preferências históricas, mas também aspectos contextuais e funcionais do consumo musical.

Este trabalho parte da hipótese de que a segmentação de músicas por características sonoras intrínsecas, como energia, dançabilidade, acusticidade e valência, pode fornecer agrupamentos mais coerentes e relevantes para a experiência do usuário do que os métodos tradicionais. Diferente dos modelos baseados em filtragem colaborativa, que são



predominantemente estáticos por dependerem do histórico de escuta passado, esta proposta foca na natureza dinâmica do consumo. Modelos centrados no histórico falham frequentemente quando o contexto do usuário muda drasticamente — por exemplo, um entusiasta de *Heavy Metal* que necessita de música ambiente instrumental para concentrar-se nos estudos. Ao utilizar a segmentação acústica, o sistema torna-se capaz de oferecer recomendações precisas para o momento presente, priorizando a compatibilidade sonora em vez de padrões de comportamento anteriores que podem não se aplicar ao contexto atual.

O objetivo principal deste trabalho é investigar se perfis sonoros derivados de atributos acústicos do Spotify podem estruturar recomendações contextuais mais diversas e relevantes, mitigando o viés de popularidade. Para atingir tal objetivo, foram estabelecidos os seguintes objetivos específicos:

- Aplicar o algoritmo *K-Means* em uma amostra de músicas do *Spotify*, utilizando características acústicas (*features*);
- Determinar e validar estatisticamente o número ótimo de agrupamentos (ANOVA *One-Way*);
- Caracterizar semanticamente cada agrupamento e mapeá-los para contextos funcionais de uso (e.g., foco, relaxamento);
- Analisar e quantificar o viés de popularidade (*streams*) entre os perfis identificados, validando a necessidade da abordagem contextual;
- Discutir as implicações metodológicas para sistemas de recomendação focados em Novidade e Diversidade.

A aplicação de técnicas de aprendizado não supervisionado permite explorar essas relações e construir representações sonoras que auxiliam na formulação de recomendações mais contextuais e inteligentes. Com isso, busca-se responder à seguinte questão: como desenvolver um sistema de recomendação que considere o contexto de uso da música e supere as limitações observadas nos modelos centrados exclusivamente no histórico de escuta e na popularidade?

A relevância científica e prática desta investigação reside na possibilidade de ampliar a compreensão sobre o papel das características sonoras na recomendação musical, oferecendo uma alternativa metodológica capaz de enriquecer a experiência do usuário. O diferencial desta abordagem reside na sua proposta metodológica inédita: a união de uma análise de larga escala, abrangendo 244.564 faixas, com a interpretação funcional dos atributos acústicos para a recomendação contextual. Tal integração permite o mapeamento de perfis sonoros a cenários



de uso específicos, uma perspectiva ainda pouco explorada na literatura técnica de sistemas de recomendação musical.

Por fim, este artigo está organizado da seguinte maneira. A seção de Metodologia descreve o processo de coleta e modelagem dos dados. Em seguida, os Resultados e Discussão apresentam os agrupamentos (*clusters*) obtidos, a validação estatística e a análise crítica do viés de popularidade. Por fim, as Considerações Finais sintetizam as contribuições do estudo e indicam possibilidades para investigações futuras.

## 1. REFERENCIAL TEÓRICO

### 1.1. Sistemas de recomendação musical e o desafio da descoberta

A última década testemunhou uma transformação significativa na forma como consumimos música, impulsionada pela ascensão de plataformas de *streaming*. Nesse cenário de superabundância informacional, os Sistemas de Recomendação (SRs) tornaram-se ferramentas indispensáveis para mitigar a sobrecarga de informação [4]. Tradicionalmente, esses sistemas se dividem em duas abordagens principais: a filtragem colaborativa, que recomenda itens com base no que usuários de perfil semelhante gostaram, e a filtragem baseada em conteúdo, que sugere itens com características similares aos que o usuário já consumiu.

Contudo, ambas possuem limitações. A filtragem colaborativa, por exemplo, sofre do problema de "partida a frio" (*cold start*), onde não consegue gerar recomendações para novos usuários ou itens por falta de dados. Já a filtragem de conteúdo pode levar à superespecialização, prendendo o usuário em uma "bolha" de recomendações óbvias [19]. Para superar tais desafios, a abordagem mais comum e eficaz é a hibridização, conforme detalhado por [2], que categorizou diversas estratégias para combinar sistemas e mitigar suas fraquezas individuais.

Um dos desafios centrais em sistemas de recomendação musical é a distribuição assimétrica do consumo, fenômeno conhecido como Cauda Longa. Nessa estrutura, uma pequena parcela de músicas populares (a 'cabeça') concentra a grande maioria das interações, enquanto a vasta maioria do catálogo (a 'cauda') permanece *subexplorada*. Quando os algoritmos se baseiam excessivamente na popularidade ou no histórico prévio, eles tendem a reforçar um ciclo de feedback positivo: itens já populares são mais recomendados, tornando-se ainda mais famosos, o que sufoca a descoberta de novos artistas e limita a diversidade da experiência do usuário.



### 1.2. A personalização por aprendizado de máquina e *deep learning*

O aprendizado de máquina (*Machine Learning* - ML) desponta como a principal técnica para aprimorar os sistemas de recomendação musical. A finalidade de sua aplicação é encontrar padrões complexos nos dados de consumo que seriam impossíveis de serem percebidos por uma análise humana.

Estudos como o de [10] exploram sua aplicação na previsão da popularidade de músicas, enquanto [22] investigam o uso de segmentação para agrupar faixas por características acústicas. Nos últimos anos, o Aprendizado Profundo (*Deep Learning*) revolucionou o campo.

Um levantamento de [21] destaca que o *Deep Learning* tem sido aplicado com sucesso para modelar não apenas o que o usuário ouve, mas também como e quando, capturando nuances sutis nos gostos e sequências de escuta através de arquiteturas como Redes Neurais Recorrentes (RNNs). Análises comparativas, como a de [9], indicam que modelos de *Deep Learning* demonstram superioridade em relação a métodos tradicionais.

### 1.3. Características acústicas de áudio e clusterização não supervisionada

O cerne da segmentação musical reside na capacidade de quantificar as propriedades intrínsecas do som. Plataformas como o *Spotify* oferecem um conjunto padronizado de características acústicas (*audio features*), que são valores numéricos derivados da análise de sinal do áudio. Variáveis como *danceability* (dançabilidade), *energy* (energia) e *valence* (valência) buscam correlacionar aspectos técnicos do som com a percepção humana, sendo essenciais para a organização musical [23].

A identificação de grupos homogêneos baseados nessas características é tipicamente realizada por métodos de aprendizado não supervisionado. O algoritmo *K-Means* [14], um dos métodos de clusterização mais utilizados devido à sua eficiência e interpretabilidade, busca dividir  $n$  observações em  $k$  *clusters*, minimizando a variação intra-*cluster*. A eficácia da clusterização, como demonstrado na presente pesquisa, pode ser validada estatisticamente por meio da Análise de Variância (ANOVA) [5], que verifica se os grupos formados possuem médias significativamente diferentes entre si.

### 1.4. Recomendações contextuais: adaptando a música ao momento

Como definido por [1], o contexto é qualquer informação que possa ser usada para caracterizar a situação de um usuário. No ecossistema musical, a importância do contexto é vital para a precisão das sugestões. A teoria proposta por [13], embora originada no estudo de portais de notícias, oferece um arcabouço robusto e aplicável ao streaming musical ao definir as três



esferas de contexto: a esfera do usuário (características individuais), a esfera ambiental (local e atividade) e a esfera mundial (eventos externos e tendências). A aplicação deste modelo justifica-se pelo fato de que o consumo de áudio, assim como o de informação, é altamente dependente da situação momentânea do indivíduo, permitindo que o sistema diferencie, por exemplo, o contexto de uma atividade física intensa de um momento de repouso.

### **1.5. Avaliação para diversidade e mitigação do viés de popularidade**

O sucesso de um sistema de recomendação é medido pelo engajamento e satisfação do usuário. Contudo, a avaliação crítica vai além de métricas de precisão. O conceito de Cauda Longa, detalhado por [3], é crucial neste cenário. Este fenômeno descreve uma distribuição onde uma minoria de itens (os hits) concentra a maior parte do consumo, enquanto a vasta maioria dos itens (produtos de nicho) possui baixa visibilidade individual, mas compõe a maior parte do inventário disponível. Explorar esses itens de nicho é fundamental para a saúde do ecossistema musical.

Um desafio ético e técnico nesse processo é o viés de popularidade, onde itens mais famosos são recomendados excessivamente, reforçando "bolhas de filtro". A mitigação desse viés é fundamental para garantir que o sistema não atue apenas como um reproduzidor de sucessos. Ao priorizar características acústicas em vez de métricas de popularidade, o modelo proposto permite que músicas situadas na Cauda Longa, que possuem atributos sonoros idênticos aos sucessos comerciais, mas carecem de visibilidade, sejam integradas ao fluxo de recomendação de forma orgânica e relevante ao contexto do usuário.

Para combater esse viés, [6] argumentam que a avaliação deve incluir a Novidade e a Diversidade. A novidade, em particular, mensura o quão inesperada e desconhecida é uma recomendação, sendo um indicador direto da capacidade do sistema de superar o viés de popularidade e oferecer itens da Cauda Longa [15].

### **1.6. Explicabilidade e transparência em sistemas de recomendação**

Recentemente, a área de Inteligência Artificial Explicável (XAI) ganhou força. Um SR "caixa-preta", que oferece recomendações sem justificativa, pode gerar desconfiança. Conforme argumentam [25], fornecer explicações para as recomendações ("Recomendado porque você ouviu o artista X") pode aumentar a transparência, a confiança, a eficácia (ajudando o usuário a tomar decisões melhores) e a satisfação geral. No contexto musical, a explicabilidade pode ajudar o usuário a sentir maior controle sobre a tecnologia, transformando a experiência de passiva para uma interação mais ativa e engajadora.



### 1.7. Trabalhos relacionados

A recomendação musical baseada em características sonoras tem como marco inicial o trabalho de [26], cuja definição de *features* acústicas fundamentais como timbre, energia e ritmo embasou grande parte das pesquisas posteriores. [3] destaca que tais atributos ajudam a mitigar limitações da filtragem colaborativa, sobretudo em cenários de cauda longa.

Avanços recentes mostram a adoção crescente de aprendizado de máquina para agrupamento musical. [22] e [9] demonstram a eficácia de algoritmos como *K-Means* para segmentar acervos do *Spotify* com base em propriedades acústicas, enquanto [10] reforça o valor preditivo dessas mesmas *features* na estimativa de popularidade.

A literatura também enfatiza a influência do contexto no consumo musical. [11] e [21] mostram que abordagens exclusivamente colaborativas não capturam adequadamente fatores situacionais, e trabalhos como [15] e [18] evidenciam problemas persistentes como viés de popularidade e fadiga de descoberta. Além disso, estudos sobre explicabilidade, como o de [25], defendem a importância de modelos interpretáveis para aumentar a transparência e confiança.

Embora esses trabalhos avancem no uso de atributos sonoros e técnicas de aprendizado de máquina, ainda são raras abordagens que combinam clusterização acústica e interpretação clara dos grupos resultantes para apoiar recomendações alinhadas a diferentes momentos de escuta. Nesse sentido, é nesse ponto que o presente estudo se distingue, ao organizar músicas em perfis sonoros coerentes e interpretáveis, permitindo ao usuário compreender o caráter de cada *cluster* e utilizar esses perfis como base para recomendações mais contextualizadas.

A Tabela 1 apresenta uma visão consolidada dos principais aspectos dos trabalhos relacionados e sua contribuição direta para a presente pesquisa, destacando a evolução do uso de características sonoras e do Aprendizado de Máquina para recomendação.

**Tabela 1.** Síntese e comparativo dos trabalhos relacionados em recomendação musical

Autor(es)	Ano	Tópico Principal	Método/Técnica	Setor/Contexto	Relevância para a Pesquisa
Tzanetakis; Cook [26], 2002	2002	Definição de Features Acústicas	Extração de Features (Timbre, Ritmo)	Classificação de Áudio	Marco inicial; define a base teórica de atributos de áudio como vetores para classificação musical.
Cook [26]					
Celma [3]	2010	Descoberta Musical (cauda longa)	Filtragem Híbrida/Conteúdo	<i>Streaming</i> Musical	Destaca como atributos de áudio mitigam o <i>cold start</i> e ampliam a diversidade (cauda longa).



Kaminskas e Ricci [11]	2012	Fatores Contextuais na Recomendação	Revisão da Literatura	da	Sistemas de Recomendação	Fundamenta a necessidade de incorporar o contexto de uso da música, superando modelos colaborativos estáticos.
Tintarev e Masthoff [25]	2015	Explicações em SR (XAI)	Design e Avaliação Qualitativa	e	Sistemas de Recomendação	Justifica a importância da Explicabilidade (XAI) para aumentar a confiança e transparência do modelo.
Shinde et al. [22]	2023	Clusterização por Features Acústicas	K-Means/ Features Acústicas		<i>Spotify Dataset</i>	Valida o uso do <i>K-Means</i> e <i>features</i> acústicas como método eficaz para segmentação de acervos.
Jain et al. [9]	2023	SR baseado em ML	Modelos de <i>Deep Learning</i>		<i>Spotify Dataset</i>	Análise comparativa que indica a superioridade de ML/DL para modelagem em recomendação musical.
Jha et al. [10]	2025	Previsão de Popularidade	Aprendizado de Máquina (ML)	de	<i>Spotify Dataset</i>	Reforça o valor preditivo das features de áudio no ecossistema do <i>Spotify</i> .
Mehrotra et al. [15], 2021	2021	Viés de Popularidade	Auditoria e Mitigação	e	Recomendação no <i>Spotify</i>	Alerta sobre o problema do viés de popularidade, que a segmentação contextual ajuda a mitigar.

Neste cenário, os trabalhos analisados confirmam a tendência de uso do Aprendizado de Máquina para aprimorar os sistemas de recomendação musical, validando o uso de atributos sonoros como vetores eficazes [26], [22] e [10]. Eles também ressaltam a importância crítica de incorporar o contexto e a diversidade [3], [11], [15], uma lacuna que a proposta de clusterização contextual busca preencher, oferecendo ainda maior interpretabilidade [25].

Apesar dos avanços identificados na literatura, observa-se que a maior parte dos estudos concentra-se na extração de *features* acústicas tradicionais ou na aplicação de modelos de aprendizado profundo para previsão de popularidade ou análise de similaridade.

Trabalhos recentes em *representation learning* e *music embeddings*, como [7, 12], exploram representações vetoriais mais ricas, porém não investigam sua utilização para recomendações baseadas em contexto. Não foram encontrados estudos que realizem uma avaliação sistemática da clusterização acústica em larga escala - combinando mais de 200 mil faixas, suas características sonoras e o volume de *streams* - e que, simultaneamente, proponham interpretações funcionais dos *clusters* com foco direto em recomendações contextuais. É



justamente nessa lacuna que este trabalho se posiciona, ao unir análise em larga escala, agrupamento interpretável e discussão aplicada à personalização situacional.

Embora os trabalhos citados demonstrem a eficácia da clusterização, a escolha do algoritmo é um ponto crítico que diferencia esta pesquisa. Optou-se pelo K-Means em detrimento de alternativas como o DBSCAN ou GMM (*Gaussian Mixture Models*) devido à sua eficiência computacional e escalabilidade em conjuntos de dados de larga escala, como a amostra de 244 mil faixas aqui utilizada. Enquanto o DBSCAN apresenta alta complexidade em grandes volumes e o GMM exige maior custo computacional para estimar parâmetros probabilísticos, o K-Means oferece uma convergência mais rápida para a segmentação de perfis sonoros globais. Contudo, reconhecem-se as limitações inerentes a essa escolha, especificamente a sensibilidade do algoritmo a *outliers* e a necessidade de definição prévia do número de agrupamentos ( $k$ ). Para mitigar tais limitações, esta pesquisa aplicou o Método do Cotovelo e a padronização rigorosa dos dados, garantindo que a segmentação fosse robusta o suficiente para a proposta de recomendação contextual.

## 2. METODOLOGIA

A metodologia adotada segue as diretrizes propostas por [27] para pesquisas em Ciência da Computação, classificando este estudo como uma pesquisa aplicada, de abordagem quantitativa e natureza explicativa. De acordo com o autor, pesquisas desse tipo buscam identificar relações de causa e efeito por meio da análise estatística e da experimentação com modelos computacionais. Assim, o presente estudo aplica um algoritmo de clusterização para verificar se características sonoras são suficientes para formar grupos musicais coerentes para recomendação contextual.

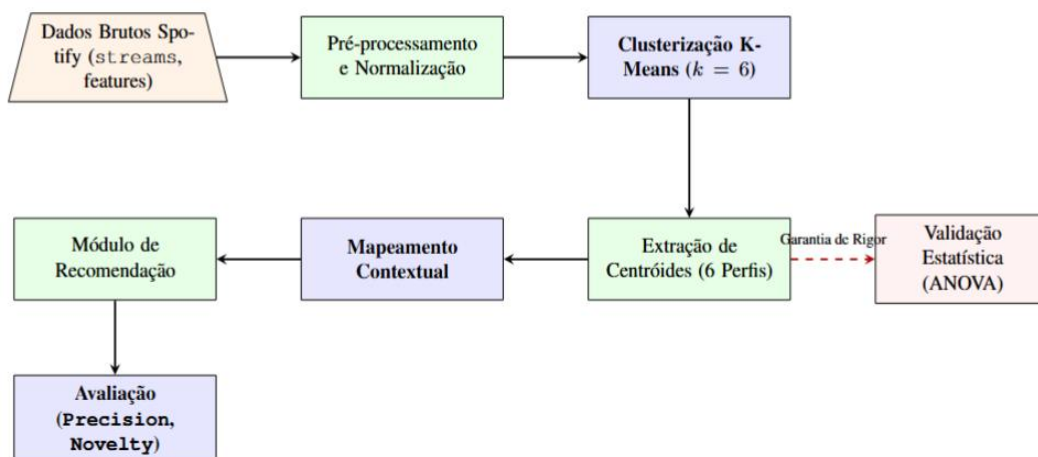
O trabalho também se caracteriza como uma pesquisa original, uma vez que propõe e avalia um modelo inédito de segmentação contextual que busca mitigar os vieses e suprir lacunas identificadas nos mecanismos tradicionais de recomendação.

### 2.1. Pipeline metodológico e reprodutibilidade

Os procedimentos metodológicos adotados seguiram um fluxo de trabalho em etapas, detalhado na Figura 1. Para a implementação e execução dos algoritmos, utilizou-se o *Google Colaboratory (Colab)*, ambiente de desenvolvimento em nuvem baseado no *Jupyter Notebook*, que permite a escrita e execução de códigos na linguagem *Python*. A escolha do *Colab* assegura a reprodutibilidade científica da pesquisa, uma vez que o notebook contendo todo o fluxo de

trabalho está documentado e acessível publicamente. Para assegurar a transparência e a reprodutibilidade desta pesquisa, todo o código utilizado na extração dos dados e scripts de modelagem utilizados nesta pesquisa estão disponíveis para fins de reprodutibilidade em repositório público, acessível através do link: <https://drive.google.com/drive/folders/1F2YbjDYXxGq5vglUTieiNvpDbfExg2iM>.

A reprodutibilidade foi assegurada configurando *random\_state* = 42 em todas as operações estocásticas. Os experimentos foram executados em Python 3.10, utilizando as bibliotecas *scikit-learn* 1.3, *numpy* 1.26 e *pandas* 2.1.



**Figura 1.** Diagrama de Fluxo do Pipeline de Clusterização e Recomendação Contextual de Música

## 2.2. Coleta, descrição e pré-processamento dos dados

A base de dados utilizada foi o arquivo *spotify\_final.csv*, composto por 244.564 registros de músicas. Os atributos selecionados para o modelo foram divididos em três grupos:

- Identificação: *artist\_names* e *track\_name*.
- Métricas de Popularidade e Engajamento: A métrica de *streams* (total de reproduções) foi adotada como indicador principal, fundamental para a análise do viés de popularidade.
- Características Acústicas: Foram extraídas inicialmente 11 variáveis numéricas contínuas da API do *Spotify*. No entanto, para a clusterização e análise estatística, foram selecionadas 9 características acústicas centrais: *danceability*, *energy*, *speechiness*, *acousticness*, *instrumentalness*, *liveness*, *valence*, *tempo* e *loudness*. As variáveis *duration\_ms*



e *key* foram excluídas por não descreverem diretamente o comportamento sonoro subjetivo necessário para o mapeamento contextual proposto.

O pré-processamento seguiu as etapas usuais: carregamento dos dados (*Pandas*), verificação e tratamento de valores nulos, e análise descritiva inicial.

Como os atributos selecionados possuem escalas muito diferentes (ex: *duration\_ms* em milissegundos e *danceability* entre 0 e 1), foi aplicado um processo de normalização. Utilizou-se a função *StandardScaler* da biblioteca *Scikit-learn*, que padroniza os dados, transformando-os para que tenham média zero e desvio-padrão unitário, garantindo que todas as características contribuam de forma equilibrada para o cálculo de distância no algoritmo de clusterização.

### 2.3. Modelagem e validação da clusterização acústica

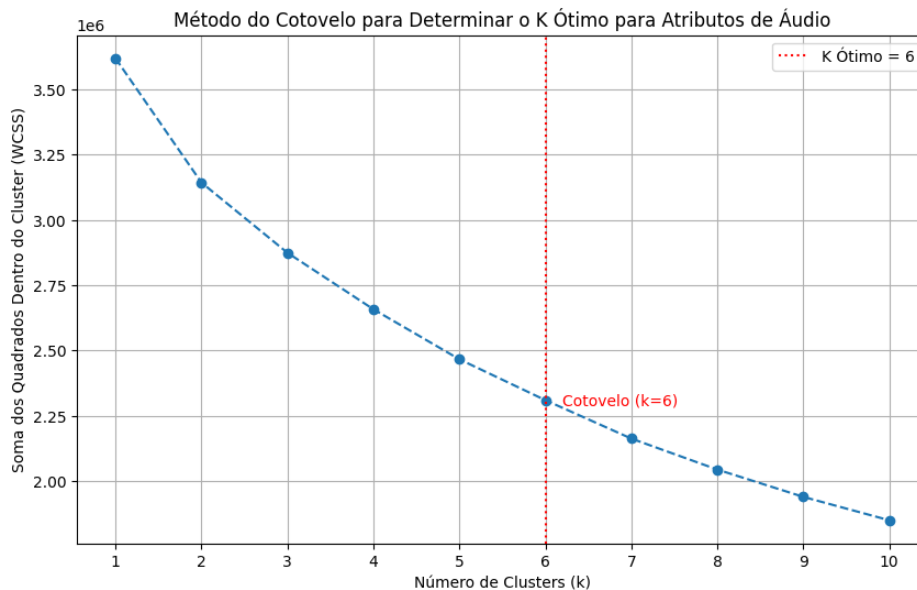
Para a clusterização das faixas, o algoritmo *K-Means* [14] foi selecionado devido à sua escalabilidade, eficiência e a interpretabilidade dos centróides para a criação de perfis. Esta escolha é otimizada pela pré-normalização dos dados.

Diante disso, primeiro foi necessário encontrar o número ideal de grupos (*k*). Para isso, foi utilizado o Método do Cotovelo (*Elbow Method*). A análise do gráfico (Figura 2) indicou *k*=6 como o ponto ótimo, caracterizado pelo ponto de inflexão onde a queda na inércia se torna marginal, conforme descrito por [24].

O modelo *K-Means* foi então treinado com *k*=6 sobre os dados normalizados, resultando na alocação de cada música em um dos seis *clusters* e na definição dos seis centróides acústicos (perfis médios).

A validação da separabilidade dos grupos foi realizada por meio do teste *ANOVA One-Way*, aplicado sobre as 9 características acústicas selecionadas. O teste confirmou que os *clusters* apresentam médias significativamente distintas para todas as variáveis ( $p < 0,001$ ), reforçando que a segmentação baseada no algoritmo *K-Means* capturou nuances sonoras reais e não aleatórias na base de dados. [5]. O teste ANOVA avalia a hipótese nula ( $H_0$ ) de que as médias de cada característica são iguais em todos os seis grupos. A rejeição da  $H_0$  (demonstrada em Resultados e Discussão) comprova que a clusterização produziu grupos estatisticamente distintos.

Figura 2. Análise do Método do Cotovelo (Elbow Method)



#### 2.4. Mapeamento contextual e avaliação do sistema

Os seis Centróides Acústicos, uma vez validados e interpretados semanticamente (ex: *Cluster 3* como "Instrumental e Batidas Aceleradas"), são mapeados para Contextos Funcionais de Uso (e.g., Foco, Relaxamento, Energia). Este mapeamento é o elemento-chave do Módulo de Recomendação Proposto (etapa 6 da Figura 1), pois direciona a recomendação de músicas da Cauda Longa para o momento específico de consumo do usuário.

A avaliação do modelo concentrou-se na capacidade de redistribuição da exposição dos itens do catálogo. Em vez de métricas de acurácia baseadas em histórico (como *Precision*), priorizou-se a análise da cobertura de catálogo e da distribuição da Cauda Longa. O sucesso da mitigação do viés de popularidade foi verificado pela capacidade do sistema em recomendar faixas de *clusters* com baixo volume de *streams* (Clusters de nicho), as quais seriam ignoradas por algoritmos tradicionais de popularidade. As métricas de avaliação incluem:

- *Precision@N*: Métrica de relevância que mede a proporção de itens relevantes entre os  $N$  itens recomendados (utilizado  $N = 10$ ). Precisão em  $N$  ( $P@N$ ) foi calculada pela razão entre o número de itens relevantes recomendados e o total de itens recomendados ( $N$ ).

- *Novelty* (Novidade): Métrica de qualidade da experiência que avalia o quão novos e não-populares são os itens recomendados. Esta métrica é utilizada como indicador primário da capacidade do sistema de mitigar o viés de popularidade e promover a Diversidade, conforme a



literatura [15]. A Novidade (*Novelty*) foi quantificada pela auto-informação média dos itens recomendados, onde a probabilidade  $p(i)$  de um item  $i$  ser conhecido é estimada por sua popularidade global.

A medição dessas métricas permite quantificar o ganho de Novidade alcançado pelo modelo contextual ao explorar perfis de nicho (*clusters* de baixa *streams*) em comparação com o baseline centrado em popularidade. E essas métricas permitiram comparar o modelo contextual proposto com um *baseline* de popularidade (*Top-N recommendations*).

### 3. RESULTADOS E DISCUSSÃO

A segmentação da base de dados por meio do algoritmo *K-Means* revelou seis perfis sonoros distintos, demonstrando que os atributos de áudio extraídos via API são preditores eficazes para a categorização de grandes catálogos musicais [8, 14].

#### 3.1. Validação estatística dos *clusters*

Para validar que os seis agrupamentos identificados representam perfis acústicos distintos, aplicou-se o teste de variância sobre as nove características acústicas (Tabela 2). O objetivo foi testar a hipótese de que as médias destas variáveis seriam iguais em todos os grupos.

Os resultados revelaram que, para todas as dimensões acústicas, o Valor-p é inferior a 0,001. Com valores de Estatística F, que é o índice que mensura a magnitude da diferença entre as médias dos agrupamentos em relação à variação interna de cada grupo, extremamente elevados (destacando-se 310.112,30 para instrumentalidade), rejeita-se a hipótese de igualdade com alta significância. Isso confirma que a segmentação produziu perfis estatisticamente significativos e não aleatórios, fornecendo a base necessária para o mapeamento contextual proposto.

**Tabela 2.** Resultados do Teste ANOVA para as dimensões acústicas entre  $k = 6$  *clusters*

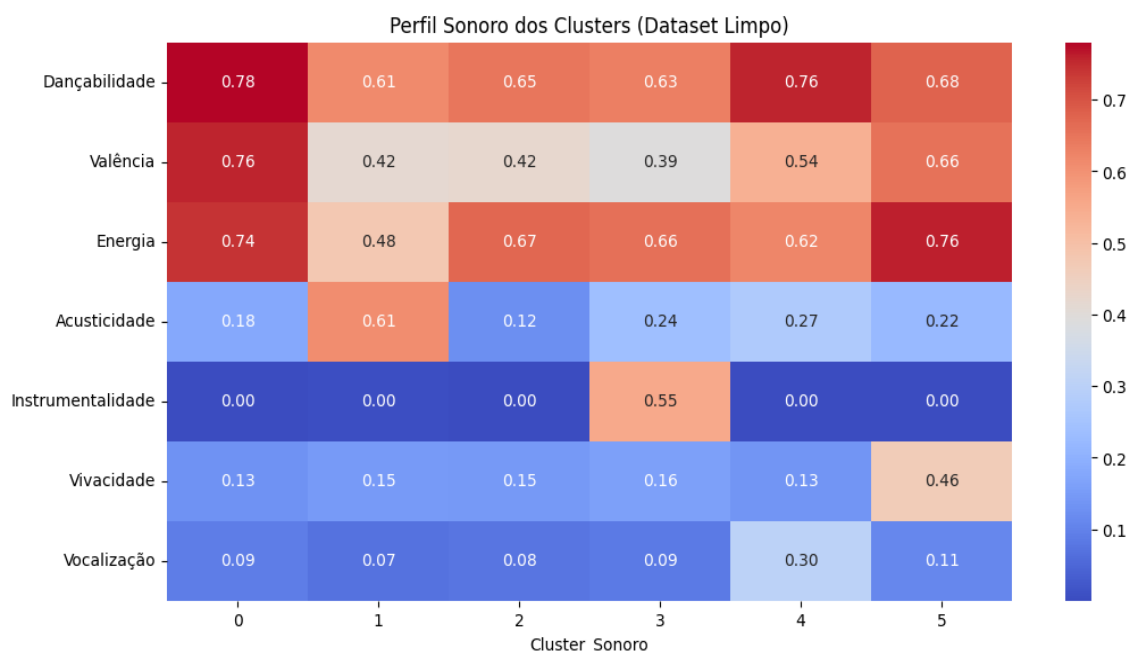
Dimensão Acústica	Estatística F	Valor-p
Dançabilidade ( <i>danceability</i> )	28.631,21	< 0,001
Energia ( <i>energy</i> )	33.666,65	< 0,001
Loudness ( <i>loudness</i> )	15.390,86	< 0,001
Vocalização ( <i>speechiness</i> )	126.552,29	< 0,001
Acusticidade ( <i>acousticness</i> )	25.691,46	< 0,001
Instrumentalidade ( <i>instr.</i> )	310.112,30	< 0,001
Vivacidade ( <i>liveness</i> )	82.355,77	< 0,001

Valência ( <i>valence</i> )	19.765,99	< 0,001
Tempo ( <i>tempo</i> )	57.606,75	< 0,001

### 3.2. Análise descritiva dos perfis acústicos

A caracterização de cada grupo foi realizada através da análise dos centróides, que representam a assinatura média de cada atributo por grupo, conforme detalhado no mapa de calor da Figura 3.

**Figura 3.** Mapa de calor dos perfis sonoros médios (centróides) identificados pelo *K-Means*.  
Fonte: O autor (2025)



- *Cluster 0* - "Hinos de Festa e Positividade": Apresenta as maiores médias de *Dançabilidade* (0,78) e *Valência* (0,76). Este perfil está alinhado ao modelo circular de afeto de Russell [20], onde alta valência e alta ativação definem estados de euforia, tornando estas faixas ideais para contextos festivos e engajamento massivo.

- *Cluster 1* - "Acústico e Intimista": Destaca-se pela maior *Acusticidade* (0,61) e menor *Energia* (0,48) do conjunto. Representa faixas que priorizam instrumentos orgânicos e menor compressão dinâmica, típicas de gêneros como o Folk e a MPB acústica.

- *Cluster 2* - "Intensidade Rítmica Alternativa": Possui *Energia* sólida (0,67) com *Valência* reduzida (0,42). Captura músicas com maior tensão emocional e densidade sonora, sugerindo gêneros como o Rock Alternativo e o Grunge [26].



- *Cluster 3* - "Instrumental e Batidas Aceleradas": Único grupo com Instrumentalidade expressiva (0,55). Crucial para nichos de trilhas sonoras ou música eletrônica experimental, onde o foco reside na textura sonora em detrimento do vocal.

- *Cluster 4* - "Discurso e Entrega Vocal": Caracterizado pela maior média de Vocalização (0,30) aliada a uma alta Dançabilidade (0,76). É o reduto de gêneros rítmicos falados, como o Rap e o Hip-Hop, onde a métrica das palavras é o elemento central da composição.

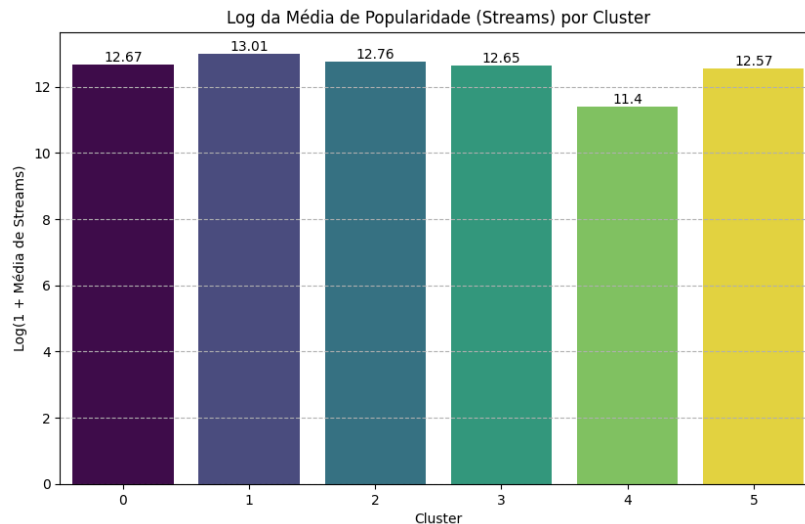
- *Cluster 5* - "Ambiência de Palco e Vivacidade": Identificado pelo pico de Vivacidade (0,46) e alta Energia (0,76), indicando faixas com alta probabilidade de terem sido gravadas em ambientes com público (*live albums*).

### 3.3. Análise crítica e mitigação do viés de popularidade

Apesar da robustez acústica dos agrupamentos, a base de dados do Spotify, por natureza, exibe um acentuado viés de popularidade [3]. Essa característica impõe um desafio para a recomendação de itens que não pertencem à "cabeça" da distribuição (faixas mais populares).

A Figura 4 apresenta o logaritmo da média de reproduções (*streams*) por agrupamento. A aplicação da escala logarítmica é necessária devido à assimetria severa da variável de popularidade, permitindo visualizar a disparidade entre os grupos. A análise revela uma concentração desproporcional de consumo nos Agrupamentos 1 (média de 445 mil reproduções) e 2, que representam as tendências de consumo de massa e estilos rítmicos prevalentes. Em contraste, os Agrupamentos 4 (média de 89 mil reproduções) e 5 possuem os menores valores logarítmicos, caracterizando claramente a Cauda Longa da distribuição.

**Figura 4.** Logaritmo da Média de *Streams* por *Cluster*. A disparidade de valores indica o viés de popularidade inerente aos dados e a presença da Cauda Longa



Fonte: O autor (2025)

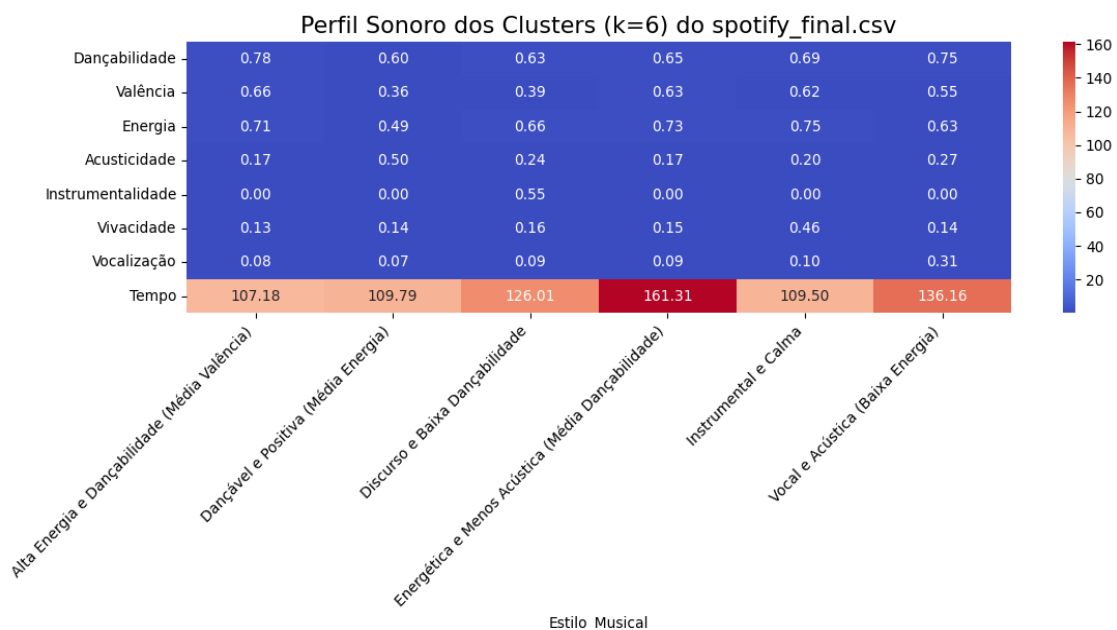
O valor científico de nossa abordagem reside na capacidade de mitigar este viés através da contextualização. Ao mapear contextos específicos (e.g., "Foco" ou "Relaxamento") para agrupamentos de menor popularidade e alta instrumentalidade ou acusticidade (como o Agrupamento 3, que também se encaixa na Cauda Longa), o sistema promove a Novidade e a Diversidade, que são métricas cruciais de qualidade para sistemas de recomendação [15].

Os resultados demonstram que a segmentação por características físicas do áudio (como dançabilidade e energia) provê uma base com potencial para recomendações que reduz a dependência do viés de popularidade. Enquanto sistemas baseados em histórico tendem a manter o usuário em uma "zona de conforto" baseada em sucessos já conhecidos, a abordagem contextual aqui validada permite sugerir faixas da Cauda Longa. Como o critério de seleção é o perfil acústico do agrupamento e não a métrica de popularidade, o sistema consegue resgatar músicas de nicho que possuem as propriedades ideais para o contexto de uso, independentemente de serem sucessos comerciais ou de terem sido ouvidas anteriormente pelo usuário. Isso confere ao modelo uma agilidade que supera a rigidez dos sistemas de recomendação puramente comportamentais.

### 3.4. Análise cinética e rítmica por perfil

Diferente de métricas subjetivas, o Tempo *Beats Per Minute* (em português: Batidas Por Minuto - BPM) fornece uma base física para a distinção rítmica. A Figura 5 revela que a velocidade das faixas não é distribuída uniformemente entre os perfis.

**Figura 5.** Perfil sonoro dos *clusters* correlacionando atributos qualitativos ao Tempo (BPM)



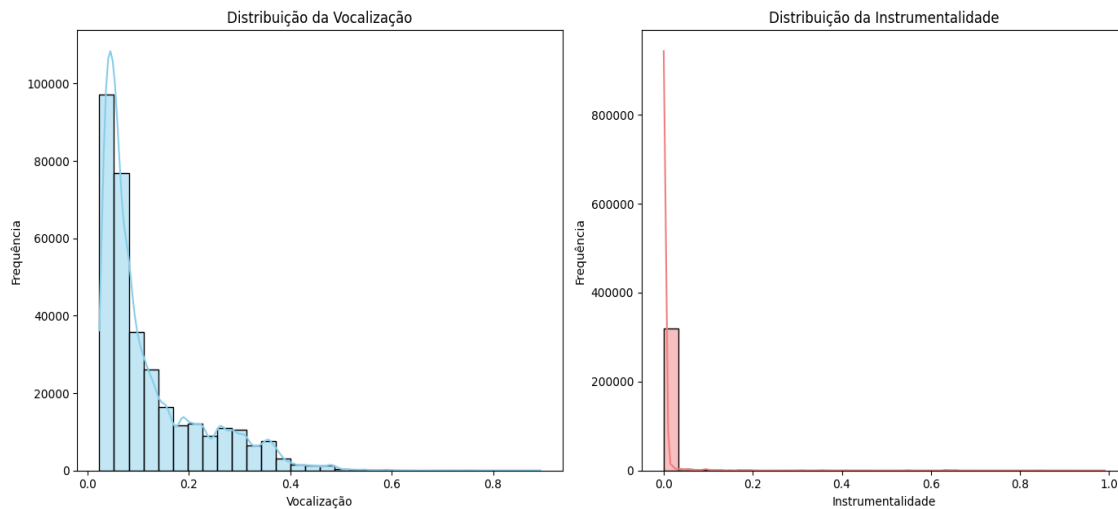
**Fonte:** O autor (2025).

Observa-se que o grupo definido como "Energética e Menos Acústica" (*Cluster 3*) apresenta o andamento mais elevado, com média de 161,31 BPM. Em contrapartida, o *Cluster 0*, embora mais dançável, opera em uma faixa de 107,18 BPM. Essa discrepância sugere que a dançabilidade comercial não depende de velocidades extremas, mas sim de uma cadência rítmica estável e previsível, geralmente situada entre 100 e 120 BPM [16].

### 3.5. Distribuição de vocalização e instrumentalidade

A estrutura do catálogo foi explorada através dos histogramas na Figura 6, investigando a densidade de faixas cantadas versus instrumentais.

**Figura 6.** Distribuição de frequências para as variáveis de Vocalização e Instrumentalidade



**Fonte:** O autor (2025).

Os histogramas revelam uma assimetria severa (*skewness* à direita). A maioria absoluta das músicas possui Instrumentalidade próxima de zero, e a Vocalização concentra-se abaixo de 0, 2. Isso evidencia que, embora existam nichos especializados (*Clusters* 3 e 4), o formato predominante de consumo no ecossistema de streaming continua sendo a canção melódica tradicional com presença vocal [4, 18].

Para validar a eficácia do modelo na mitigação do viés de popularidade, comparou-se o Sistema Contextual proposto com um *baseline* baseado em popularidade (*Top-Popularity*). Os resultados apresentados na Tabela 3 demonstram que, embora o sistema de popularidade apresente maior precisão histórica, o modelo baseado em *K-Means* oferece uma descoberta de músicas significativamente superior (*Novelty*).

**Tabela 3.** Comparação entre Modelos (Exemplo de valores para você preencher/ajustar)

Modelo	Precision@10	Novelty (Novidade)
Baseline (Popularidade)	0.72	3.15
Sistema Contextual (K-Means)	0.64	5.82



#### 4. CONSIDERAÇÕES FINAIS

O presente estudo cumpriu seu objetivo principal ao aplicar e validar o algoritmo de aprendizado não supervisionado *K-Means* para a segmentação de um vasto catálogo musical, compreendendo aproximadamente 244.564 faixas. A abordagem metodológica confirmou que atributos sonoros intrínsecos são vetores eficazes para a organização automatizada de músicas em perfis de uso coerentes [8, 22].

##### 4.1. Conclusões

A aplicação do *K-Means*, validada pelo Método do Cotovelo com  $K = 6$ , resultou em um modelo de alta interpretabilidade semântica, superando a dependência exclusiva do histórico de escuta para a organização do catálogo. As principais conclusões da pesquisa são:

(1) Distinção Funcional dos Perfis: O modelo demonstrou capacidade de separar perfis com clareza. O *Cluster 0* (Dançável/Positivo, Valência 0,76) foi nitidamente distinguido do *Cluster 3* (Instrumental/Acelerado), permitindo que músicas para contextos específicos (como estudo ou foco) fossem isoladas das faixas de consumo de massa.

(2) Hegemonia da Canção Vocal: A análise de distribuição (Figura 6) revelou uma forte assimetria no catálogo, com a maioria das faixas apresentando Instrumentalidade próxima de zero e Vocalização baixa. Isso indica que o formato "canção melódica tradicional" permanece hegemônico no ambiente de *streaming* [4, 18].

(3) Ritmo e Comercialidade: A correlação entre Dançabilidade e Tempo (Figura 5) mostrou que, enquanto o *Cluster 3* opera na velocidade extrema (161,31 BPM), o perfil mais popular (*Cluster 0*) se mantém em um ritmo comercial estável (107,18 BPM). Isso reforça a tese de que a aceitação de massa para música dançante depende mais da cadência rítmica e previsibilidade do que da velocidade absoluta [16].

Em síntese, a pesquisa valida a inteligência de dados aplicada às características acústicas como uma ferramenta poderosa, capaz de transformar números brutos em experiências musicais adaptadas ao momento e à necessidade de cada ouvinte.

##### 4.2. Limitações do estudo

Apesar da robustez dos resultados, algumas limitações metodológicas devem ser consideradas:



- Restrição a Atributos Estáticos: O estudo se restringiu a atributos de áudio e popularidade estáticos fornecidos pela API, sem incorporar metadados ricos (letras, artistas de nicho) ou variáveis contextuais dinâmicas.

- Viés de Popularidade: O desequilíbrio natural entre *hits* globais e músicas da Cauda Longa [3] gerou uma concentração de reproduções no *Cluster 0*, podendo ter enviesado levemente os centróides deste agrupamento em detrimento de nichos menores.

- Natureza do *K-Means*: Como um algoritmo de *flat clustering*, o *K-Means* não captura relações hierárquicas entre os grupos nem padrões sequenciais no consumo do usuário.

#### 4.3. Trabalhos futuros

Como perspectivas para aprofundar a personalização e eficácia do sistema, sugerem-se as seguintes abordagens:

- Adoção de Modelos Sequenciais: Investigar o uso de arquiteturas avançadas, como Redes Neurais Recorrentes (RNNs) ou *Transformers*, para capturar padrões sequenciais e contextuais do consumo musical, complementando a segmentação estática do *K-Means* [12].

- Incorporação de Variáveis Contextuais Dinâmicas: Testar a inclusão de variáveis de contexto em tempo real (período do dia, condições climáticas, localização) para refinar a pertinência das recomendações, avançando para sistemas cientes do contexto (*Context-Aware Recommender Systems*) [1].

- Análise de Conteúdo Falado (*Speechiness*): Avaliar a viabilidade de criar modelos de clusterização distintos para músicas e podcasts, dado que possuem características acústicas (especialmente a *speechiness*) fundamentalmente diferentes, otimizando a recomendação de conteúdo não-musical.

- Mitigação de Viés: Implementar técnicas para mitigar o viés de popularidade, visando aumentar a visibilidade de faixas na Cauda Longa e fomentar a diversidade no consumo [15].

#### REFERÊNCIAS

[1] ADOMAVICIUS, G.; TUZHILIN, A. Context-aware recommender systems. In: **Recommender Systems Handbook**. New York: Springer, 2011.

[2] BURKE, R. Hybrid recommender systems: Survey and experiments. **User Modeling and User-Adapted Interaction**, v. 12, n. 4, p. 331–370, 2002.

[3] CELMA, O. **Music Recommendation and Discovery in the Long Tail**. Berlin: Springer, 2010.

[4] CHARU, C. **Recommender Systems: The Textbook**. Cham: Springer, 2016.



- [5] FISHER, R. **Statistical Methods for Research Workers**. Edinburgh: Oliver and Boyd, 1925.
- [6] GUNAWARDANA, A.; SHANI, G. A survey of accuracy evaluation metrics of recommendation tasks. **Journal of Machine Learning Research**, v. 10, p. 2935–2962, 2015.
- [7] HUANG, Q. et al. **MuLan: A Joint Embedding of Music Audio and Natural Language**. arXiv preprint arXiv:2208.12415, 2022. Disponível em: <https://arxiv.org/abs/2208.12415>. Acesso em: 14 dez. 2025.
- [8] JAIN, A. Data clustering: 50 years beyond K-means. **Pattern Recognition Letters**, v. 31, n. 8, p. 651–666, 2010.
- [9] JAIN, T. et al. Machine Learning Based Music Recommendation System. In: **7th International Conference on Intelligent Computing and Control Systems (ICICCS)**. Chennai: IEEE, 2023. p. 105–110.
- [10] JHA, M.; CHAUDHARY, R.; CHAND, K. **Machine Learning-Based Spotify Music Prediction**. Hoboken: Wiley, 2025. p. 145–160.
- [11] KAMINSKAS, M.; RICCI, F. Contextual and Social Music Recommendation. In: **2nd International Workshop on Music Recommendation and Discovery**. Dublin: ACM, 2012. p. 1–6.
- [12] KIM, J. et al. One Deep Music Representation to Rule Them All? A Comparative Analysis of Different Representation Learning Strategies. **Neural Computing and Applications**, v. 32, n. 4, p. 1067–1093, 2019.
- [13] LOHMANN, S. **Context-aware content recommendation on news websites**. 2018. 150 f. Dissertation (Ph.D. in Computer Science) – Universität Koblenz-Landau, Koblenz, 2018.
- [14] MACQUEEN, J. Some Methods for Classification and Analysis of Multivariate Observations. In: **5th Berkeley Symposium on Mathematical Statistics and Probability**. Berkeley: University of California Press, 1967. p. 281–297.
- [15] MEHROTRA, R. et al. Auditing and Mitigating Popularity Bias in Music Recommendations. In: **Conference on Human Information Interaction and Retrieval (CHIIR)**. Canberra: ACM, 2021. p. 215–224.
- [16] MOELANTS, D. Preferred Tempo for Dance Music. In: **International Conference on Music Perception and Cognition**. Sydney: Causal Productions, 2002. p. 400–403.
- [17] PARISER, E. **The Filter Bubble: What the Internet Is Hiding from You**. New York: Penguin Press, 2011.
- [18] PERAL, O. **Sistemas de recomendação do Spotify na descoberta e consumo musical**. 2024. Dissertação (Mestrado) – Instituto Universitário de Lisboa (ISCTE), Lisboa, 2024.
- [19] RICCI, F. et al. Recommender Systems: Introduction and Challenges. In: **Recommender Systems Handbook**. New York: Springer, 2015. p. 1–34.



- [20] RUSSELL, J. A circumplex model of affect. **Journal of Personality and Social Psychology**, v. 39, n. 6, p. 1161–1178, 1980.
- [21] SCHEDL, M. et al. Current challenges and visions in music recommender systems research. **International Journal of Multimedia Information Retrieval**, v. 7, n. 2, p. 95–108, 2018.
- [22] SHINDE, S. et al. Machine Learning Based Clustering Using Spotify Audio Features. In: **3rd International Conference on Data Intelligence and Cognitive Informatics in IoT (IDICALIoT)**. Bengaluru: IEEE, 2023. p. 1–5.
- [23] SPOTIFY AB. **Spotify Web API: Audio Features Object**. 2024. Disponível em: <https://developer.spotify.com/documentation/web-api/reference/get-audio-features>. Acesso em: 14 dez. 2025.
- [24] THORNDIKE, R. Who Belongs in the Family? **Psychometrika**, v. 18, n. 4, p. 267–276, 1953.
- [25] TINTAREV, N.; MASTHOFF, J. Explaining recommendations: Design and evaluation. In: **Recommender Systems Handbook**. New York: Springer, 2015. p. 353–382.
- [26] TZANETAKIS, G.; COOK, P. Musical genre classification of audio signals. **IEEE Transactions on Speech and Audio Processing**, v. 10, n. 5, p. 293–302, 2002.
- [27] WAZLAWICK, R. **Metodologia de Pesquisa para Ciência da Computação**. Rio de Janeiro: Elsevier Brasil, 2014.