



Instituto Federal de Educação, Ciência e Tecnologia da
Paraíba
Campus Campina Grande
Coordenação do Curso Superior de Engenharia de
Computação

**Sentimentos de Alegria e Tristeza na Música
Brasileira: Uma análise exploratória com
Inteligência Artificial**

RENATA DA SILVA FERREIRA

Orientador: Igor Barbosa da Costa, D.Sc.

Campina Grande, Novembro de 2023
©Renata da Silva Ferreira



Instituto Federal de Educação, Ciência e Tecnologia da
Paraíba
Campus Campina Grande
Coordenação do Curso Superior de Engenharia de
Computação

Sentimentos de Alegria e Tristeza na Música Brasileira: Uma Análise Exploratória com Inteligência Artificial

RENATA DA SILVA FERREIRA

Trabalho de Conclusão de Curso apresentado ao Curso Engenharia de Computação, do Instituto Federal da Paraíba – Campus Campina Grande, em cumprimento às exigências parciais para a obtenção do título de Bacharel em Engenharia de Computação.

Orientador: Igor Barbosa da Costa, D.Sc.

Campina Grande, Novembro de 2023

F723s Ferreira, Renata da Silva

Sentimentos de alegria e tristeza na música brasileira: uma análise exploratória com inteligência artificial / Renata da Silva. - Campina Grande, 2023.

19f. : il.

Trabalho de Conclusão de Curso (Curso Superior de Engenharia da computação) - Instituto Federal da Paraíba, 2023.

Orientador: Prof. D.Sc Igor Barbosa da Costa

1. Engenharia da computação 2. Música - Características técnicas e líricas 3. Spotify 4. Inteligência artificial - ChatGPT I. Costa, Igor Barbosa da II. Título.

CDU 004

Sentimentos de Alegria e Tristeza na Música Brasileira: Uma Análise Exploratória com Inteligência Artificial

Trabalho de Conclusão de Curso apresentado ao Curso Engenharia de Computação, do Instituto Federal da Paraíba – Campus Campina Grande, em cumprimento às exigências parciais para a obtenção do título de Bacharel em Engenharia de Computação.

Igor Barbosa da Costa, D.Sc.
Orientador

Indefinido
Membro da Banca

Indefinido
Membro da Banca

Campina Grande, Paraíba, Brasil
Novembro, 2023

“O mundo está cheio de coisas que possuem características próprias e que se relacionam entre si.”

Peter Chen

*À Deus. À minha mãe, familiares e amigos,
por todo apoio e carinho!*

Sumário

1	Introdução	11
2	Fundamentação Teórica	12
2.1	Análise de Sentimento	12
2.2	GPT-3	13
2.3	Spotify	14
3	Conjunto de Dados	15
4	Resultados e Discussões	16
4.1	Existe uma correlação significativa entre as características técnicas de uma música brasileira e a evocação de sentimentos de alegria ou tristeza nos ouvintes?	16
4.2	A análise de sentimentos da letra da música realizada pelo ChatGPT concorda com a percepção dos ouvintes sobre o sentimento transmitido pela música?	18
5	Conclusão	19

Lista de Abreviaturas

API *Application Programming Interface*
MER *Music Emotion Recognition*

Lista de Figuras

- 1 Matriz de correlação de Pearson das características técnicas das músicas brasileiras e a evocação de sentimentos. 17

Lista de Tabelas

- 1 Análise de importância das características pelo modelo *Random Forest*. . 18
- 2 Matriz de confusão da classificação de sentimentos pelo ChatGPT 18

Sentimentos de Alegria e Tristeza na Música Brasileira: Uma Análise Exploratória com Inteligência Artificial

Silva F. Renata¹, Barbosa C. Igor¹

¹Instituto Federal de Ciência e Tecnologia– IFPB - Campus Campina Grande (IFPB)
CEP 58432-300– Campina Grande - PB– Brazil

{renata.ferreira,igor.costa}@academico.ifpb.edu.br

Resumo. Este estudo explora a dinâmica entre as características técnicas e líricas de músicas brasileiras e a indução dos sentimentos de alegria e tristeza nos ouvintes, aplicando técnicas computacionais avançadas como aprendizado de máquina e processamento de linguagem natural. A análise foi realizada com base em dados obtidos através da API (Application Programming Interface) do Spotify, abrangendo elementos como energia, valência e dançabilidade das músicas. Paralelamente, as letras foram submetidas ao modelo de inteligência artificial ChatGPT para identificar emoções expressas textualmente. Empregando a correlação de Pearson, o estudo quantifica a relação entre as características musicais e a resposta emocional dos ouvintes, enquanto a precisão da análise de sentimentos das letras pelo ChatGPT foi avaliada através de uma matriz de confusão. Os resultados destacam uma relação significativa entre variáveis técnicas como energia e valência e os sentimentos experimentados pelos ouvintes. Entretanto, a pesquisa também aponta para desafios na análise de sentimentos das letras, evidenciando discrepâncias entre as classificações automáticas e a percepção humana, especialmente em letras com maior complexidade lírica. Este estudo não só comprova a utilidade de abordagens computacionais na análise de emoções em músicas, mas também sugere melhorias para sistemas de recomendação musical e plataformas de streaming. As limitações identificadas incluem a subjetividade nas categorizações emocionais e as restrições impostas pela API do Spotify. Além disso, recomenda-se a expansão do espectro emocional analisado e o aperfeiçoamento dos modelos de inteligência artificial para uma interpretação mais precisa da riqueza lírica da língua portuguesa em músicas brasileiras em futuras pesquisas.

Abstract. This study explores the dynamics between the technical and lyrical characteristics of Brazilian music and the induction of feelings of happiness and sadness in listeners, applying advanced computational techniques such as machine learning and natural language processing. The analysis was conducted using data obtained from the Spotify API, covering elements like energy, valence, and danceability of the songs. In parallel, the lyrics were subjected to the ChatGPT artificial intelligence model to identify textually expressed emotions. Employing Pearson's correlation, the study quantifies the relationship between musical characteristics and the emotional response of the listeners, while the accuracy of the sentiment analysis of the lyrics by ChatGPT was evaluated using a confusion matrix. The results highlight a significant relationship between technical variables such as energy and valence and the feelings experienced by the

listeners. However, the research also points to challenges in sentiment analysis of lyrics, revealing discrepancies between automatic classifications and human perception, especially in lyrics with greater lyrical complexity. This study not only proves the usefulness of computational approaches in analyzing emotions in music but also suggests improvements for music recommendation systems and streaming platforms. The identified limitations include subjectivity in emotional categorizations and the restrictions imposed by the Spotify API. Additionally, it is recommended to expand the emotional spectrum analyzed and refine the artificial intelligence models for a more accurate interpretation of the lyrical richness of the Portuguese language in Brazilian songs in future research.

1. Introdução

No contexto da atual revolução tecnológica e cultural, a experiência musical tem sofrido transformações notáveis. A ascensão das plataformas de *streaming*, juntamente com a expansão das redes sociais e o acesso facilitado à música via internet, tem redefinido a forma pela qual a música é consumida, compartilhada e percebida. Essa metamorfose tecnológica não somente altera os padrões de consumo musical, como também tem um impacto profundo nas emoções que a música evoca, ressaltando a necessidade de uma análise mais aprofundada sobre como a música influencia o estado emocional dos indivíduos.

A música, imersa na cultura humana, é reconhecida por sua habilidade de despertar uma rica variedade de emoções, com a alegria e a tristeza sendo particularmente prevalentes em todas as culturas [Bowling et al. 2012]. Tempos musicais rápidos e modos maiores tendem a ser associados à alegria, enquanto que tempos lentos e modos menores estão frequentemente ligados à tristeza [Hunter et al. 2010]. Apesar dos avanços neurocientíficos da última década, que esclareceram como a música afeta as estruturas cerebrais ligadas à emoção [Koelsch 2014], os impactos cognitivos das músicas tristes e alegres ainda não estão completamente definidos [Taruffi et al. 2017].

O estudo das emoções em composições musicais ganha relevância no contexto das atuais mudanças comportamentais na apreciação da música. [Brattico et al. 2011] investigou a interação entre letras e emoções musicais em gêneros *pop* e *rock*. Já [Panda et al. 2018] examinou a eficácia dos recursos de áudio da API (*Application Programming Interface*) do *Spotify* em tarefas de *Music Emotion Recognition (MER)*, destacando a importância de atributos como energia e valência no reconhecimento de emoções. Estudos no contexto brasileiro, como o de [Custódio et al. 2021], revelaram padrões nas preferências musicais no país, indicando inclinação por faixas de curta duração e alto volume.

A análise de sentimentos nas músicas, que engloba tanto aspectos técnicos quanto líricos, emerge como um campo crucial de estudo. Essa abordagem não apenas proporciona um entendimento mais profundo das reações emocionais à música, mas também tem aplicações práticas, como na criação e recomendação de *playlists* que se alinhem aos estados emocionais dos ouvintes [Sangnark et al. 2019].

Avaliações da eficácia do ChatGPT na análise de sentimentos em *tweets*, realizadas por [Kheiri and Karimi 2023], demonstraram a capacidade do modelo de lidar com ambiguidades e a linguagem coloquial das redes sociais, revelando potencial para

aplicação em contextos musicais.

O foco deste trabalho, é investigar especificamente a relação entre as características técnicas e líricas das músicas e os sentimentos de “alegria” e “tristeza” percebidos pelos ouvintes. A escolha desses sentimentos específicos se justifica pela sua natureza polarizada e pela forma como representam espectros emocionais amplos e fundamentais na experiência humana. Além disso, a alegria e a tristeza são emoções frequentemente evocadas pela música, oferecendo um campo fértil para análises comparativas.

Este estudo concentra-se em músicas brasileiras, proporcionando uma lente única através da qual esses fenômenos podem ser explorados. A música brasileira, rica em diversidade e profundamente enraizada na cultura e história do país, oferece um contexto singular para investigar como as emoções são expressas e percebidas. Além disso, dada a influência global da música brasileira e a sua crescente presença em plataformas digitais, compreender a relação entre as suas características e as emoções que ela evoca torna-se relevante tanto cultural quanto cientificamente.

As questões de pesquisa que orientam esta investigação incluem:

1. Existe uma correlação significativa entre as características técnicas de uma música brasileira e a evocação de sentimentos de alegria ou tristeza nos ouvintes?
2. As análises de sentimentos das letras, realizadas por ferramentas de inteligência artificial como o ChatGPT, correspondem à percepção dos ouvintes sobre os sentimentos de alegria ou tristeza transmitidos pela música brasileira?

Para abordar essas questões, foi desenvolvido um conjunto de dados robusto utilizando a API do Spotify, incluindo informações detalhadas de 26 *playlists* escolhidas para refletir uma ampla gama de preferências musicais. A análise desses dados foi realizada utilizando técnicas de aprendizagem de máquina, como também o modelo de correlação de Pearson.

Este estudo visa oferecer percepções sobre como as características inerentes às músicas brasileiras influenciam as emoções de alegria e tristeza nos ouvintes. A identificação de padrões e correlações específicas entre as características das músicas brasileiras e estes sentimentos é fundamental para aprofundar a compreensão da interação complexa entre música e emoção, abrindo caminhos para futuras pesquisas e aplicações práticas no campo da música e da psicologia emocional.

2. Fundamentação Teórica

Esta seção esclarece os principais conceitos abordados no trabalho. São detalhadas ideias e termos-chave para facilitar a compreensão do estudo e das escolhas feitas durante a pesquisa.

2.1. Análise de Sentimento

A Análise de Sentimento busca capturar e entender informações subjetivas vindas de diferentes fontes, com o objetivo de perceber a opinião de alguém sobre um tema específico ou detectar tendências em um documento.

Nas fases iniciais, a análise de sentimento se apoiava principalmente em métodos lexicais [J. Hartmann and Heitmann 2019]. Estes métodos somavam palavras de teor positivo e negativo no texto para, depois, determinar o sentimento predominante. Baseavam-se em léxicos predefinidos, nos quais cada palavra tinha uma avaliação emocional [Esuli

and Sebastiani 2007]. Mesmo sendo simples e claros, esses métodos enfrentavam dificuldades em compreender diferentes contextos e lidar com aspectos mais complexos da linguagem. Eles também tinham desafios em se adaptar às constantes mudanças da linguagem [Kenyon-Dean 2018].

A chegada do aprendizado de máquina trouxe uma virada no campo da análise de sentimentos, movendo o foco das técnicas lexicais para estratégias baseadas em dados. A utilização de métodos de aprendizagem supervisionada, em que modelos eram treinados com dados já categorizados e depois usados para prever sentimentos em novos dados, tornou-se popular [M. Birjali and Beni-Hssane 2021]. Algoritmos como Naive Bayes, Support Vector Machines e Random Forests mostraram-se superiores às técnicas lexicais, principalmente por sua adaptabilidade e capacidade de entender nuances dos textos [Mullen and Collier 2004]. Essas inovações iniciais destacaram a força do aprendizado de máquina no campo da análise de sentimentos.

No entanto, mesmo com esses avanços, as abordagens tradicionais de aprendizado de máquina enfrentaram barreiras ao tentar entender completamente as nuances da linguagem humana [Guthier et al. 2017]. Isso levou a uma pesquisa mais detalhada e ao aperfeiçoamento de estratégias voltadas para a compreensão profunda dos sentimentos nos textos. Com mais investigações, os sistemas de aprendizado de máquina foram adotados em grandes conjuntos de dados, como nas redes sociais, mostrando sua versatilidade e ampla aplicabilidade [Kouloumpis et al. 2011]. Estes desenvolvimentos destacam o contínuo crescimento da análise de sentimentos e a relevância constante das técnicas de aprendizado de máquina neste setor.

2.2. GPT-3

A OpenAI, uma destacada instituição no campo da inteligência artificial, tem sido fundamental no avanço dos modelos de linguagem de alto desempenho. Um de seus marcos é o desenvolvimento do GPT-3, um avançado modelo de linguagem autorregressivo [Brown et al. 2020]. Ancorado na arquitetura de transformadores e munido de 175 bilhões de parâmetros, o GPT-3 se destaca por gerar textos que imitam fielmente a linguagem humana. Ele foi treinado a partir de um vasto conteúdo da web, tornando-se uma ferramenta versátil capaz de elaborar frases contextualizadas e lógicas, mesmo que seu rendimento possa variar de acordo com a tarefa [Chiu et al. 2021].

A abrangência de aplicações de modelos de linguagem avançados no tratamento de textos é vasta e continuamente expansiva. Desde tradução automática e síntese de texto até interfaces de diálogo, a adaptabilidade desses modelos se manifesta. Suas performances em tarefas de compreensão linguística, como análise de sentimentos e reconhecimento de emoções, acentuam ainda mais a aplicação destes, graças à sua capacidade de simular a linguagem humana. Embora estes modelos tenham demonstrado habilidades impressionantes, a complexidade de suas aplicações requer investigações contínuas e melhorias constantes. Instituições como a OpenAI, com inovações como o GPT-3, fortalecem imensamente este segmento de pesquisa, mas a jornada em busca de inovações persiste.

Atualmente, a análise de sentimentos está vivenciando uma transformação guiada pela emergência de modelos baseados em transformadores, como BERT, GPT-3 e afins. Estes modelos, fundamentados em arquiteturas de aprendizado profundo, oferecem um entendimento contextual superior em relação aos modelos precedentes [Kheiri and Karimi

2023]. Organizados sob a lógica de pré-treino e *fine-tuning*, têm mostrado destreza em tarefas de análise de sentimentos, lidando eficientemente com aspectos como negações, intensificadores e sentimentos subjacentes [Praveen and Vajrobol 2023].

2.3. Spotify

O *Spotify* se consolidou como um dos principais serviços de streaming musical do mundo, contando com uma base de 551 milhões de usuários ativos mensais e uma vasta biblioteca que abriga mais de 70 milhões de músicas [Mukherje 2023]. O impacto do *Spotify* no cenário musical atual é inegável, transformando a maneira como os ouvintes acessam e experimentam suas faixas favoritas. Além do vasto catálogo, uma das características mais apreciadas pelos usuários é seu sofisticado sistema de recomendação, que facilita as buscas e oferece sugestões personalizadas.

Historicamente, sistemas de recomendação dependiam de técnicas de filtragem colaborativa. Essas técnicas baseiam-se na análise dos padrões de consumo musical dos usuários para prever preferências, independentemente do conteúdo das faixas [Hunter et al. 2010]. Entretanto, esse método apresenta limitações, especialmente ao tentar recomendar músicas novas ou menos populares, devido à escassez de dados. A aquisição do The Echo Nest em 2014 pelo Spotify marcou uma evolução nesse cenário. Especializado em inteligência musical, o The Echo Nest potencializou a capacidade do *Spotify* de extrair informações de músicas, usando tanto metadados quanto técnicas de processamento de sinal digital [Aguilar 2014].

Atualmente, o *Spotify* não só atua como plataforma de *streaming*, mas também como contribuinte para pesquisas em diversas áreas da música. Contudo, uma lacuna permanece no contexto do MER (*Music Emotion Recognition*): a falta de anotações emocionais de alta qualidade. A solução para essa deficiência pode residir nos dados fornecidos pela própria API do *Spotify*, que disponibiliza diversos recursos de áudio das faixas. Estes incluem:

- **Dançabilidade (*Danceability*):** indica o quão adequada uma faixa é para dançar, levando em consideração fatores como andamento, estabilidade rítmica, força da batida e regularidade. O valor varia de 0,0 (menos dançável) a 1,0 (mais dançável).
- **Energia (*Energy*):** mede a intensidade e atividade percebidas em uma faixa, com valores variando de 0,0 a 1,0. Faixas com alta energia geralmente têm uma sonoridade rápida, alta e barulhenta, enquanto faixas com baixa energia podem ser mais suaves e calmas.
- **Tom (*Key*):** indica a tonalidade da faixa, representada por um número inteiro mapeado para notas musicais (por exemplo, 0 = C, 1 = C#/Db, 2 = D, e assim por diante). Um valor de -1 indica que a tonalidade não foi detectada.
- **Volume (*Loudness*):** representa o volume geral da faixa em decibéis (dB). Os valores de volume são calculados em média em toda a faixa e podem ser úteis para comparar o volume relativo entre diferentes faixas.
- **Modo (*Mode*):** indica a modalidade (maior ou menor) da faixa. O valor 1 representa o modo maior, enquanto o valor 0 representa o modo menor.
- **Fala (*Speechiness*):** detecta a presença de palavras faladas em uma faixa. Valores próximos a 1,0 indicam que a faixa é predominantemente composta por palavras faladas, como programas de rádio ou audiolivros, enquanto valores abaixo de 0,33 geralmente representam faixas instrumentais.

- **Acústica (*Acousticness*):** medida que indica a probabilidade de a faixa ser acústica, variando de 0,0 (menor probabilidade) a 1,0 (maior probabilidade).
- **Instrumentalidade (*Instrumentalness*):** prevê se uma faixa não contém vocais. Valores próximos de 1,0 indicam uma alta probabilidade de a faixa ser instrumental.
- **Vivacidade (*Liveness*):** detecta a presença de uma plateia na gravação da faixa. Valores mais altos indicam uma maior probabilidade de a faixa ter sido gravada ao vivo.
- **Valência (*Valence*):** mede a positividade musical transmitida por uma faixa, variando de 0,0 (mais negativa) a 1,0 (mais positiva). Faixas com alta valência têm uma sonoridade mais alegre e animada, enquanto faixas com baixa valência podem transmitir tristeza ou melancolia.
- **Tempo (*Tempo*):** indica o andamento estimado da faixa em batidas por minuto (BPM). É uma medida da velocidade ou ritmo da música.
- **Duração (*Duration*):** representa a duração da faixa em milissegundos.
- **Assinatura temporal (*Time Signature*):** fornece uma estimativa da fórmula de compasso da faixa. A fórmula de compasso especifica quantas batidas existem em cada compasso, variando de 3 a 7.

A análise desses recursos de áudio pode ser fundamental para entender as emoções transmitidas por uma música, permitindo aos pesquisadores e desenvolvedores avançar no campo do MER e proporcionar experiências ainda mais enriquecedoras aos usuários [Panda et al. 2018].

3. Conjunto de Dados

O propósito desta seção é elucidar a metodologia adotada para construir o conjunto de dados empregado neste estudo, detalhando aspectos como conteúdo, qualidade, dimensão e proveniência dos dados. Serão abordadas tanto as técnicas aplicadas quanto as limitações enfrentadas, visando oferecer um panorama completo da origem e tratamento dos dados.

Este trabalho busca analisar características musicais associadas a emoções, especificamente categorizadas como “triste” e “alegre”. Para isso, optou-se por coletar dados de *playlists* criadas por usuários no *Spotify*, uma plataforma amplamente utilizada e que permite acesso a um vasto repertório musical. A estratégia adotada compreendeu as seguintes etapas:

1. **Extração de Playlists:** Foram selecionadas *playlists* criadas por usuários na temática “triste” e “alegre”. A decisão por explorar *playlists* de usuários visa capturar uma representação mais autêntica da percepção do público sobre essas emoções na música. Por isso, buscou-se dentro da plataforma por *playlists* intituladas: ‘Músicas Tristes’ e ‘Músicas Felizes’. Dos resultados obtidos, foram selecionadas 26 *playlists*, 13 com músicas tristes e outras 13 com músicas alegres.
2. **Amostragem de Faixas:** De cada *playlist*, 10 faixas foram selecionadas aleatoriamente, garantindo que, independente do tamanho da *playlist*, uma representação equitativa fosse obtida. Tal decisão visa evitar vieses relacionados ao tamanho das *playlists*.
3. **Coleta de Informações:** Foram extraídas informações relevantes como ID, nome do artista, letra, nome das faixas, bem como características de áudio (ex.: dançabilidade, energia, tonalidade, intensidade, etc.).

Uma vez coletados, os dados passaram por uma fase de pré-processamento que envolveu:

1. **Eliminação de Duplicatas:** Identificou-se e removeu-se registros repetidos. Músicas que por ventura poderiam aparecer mais de uma vez na mesma *playlist* ou em *playlists* diferentes foram descartadas.
2. **Correção de Inconsistências:** Verificou-se os metadados dos artistas, álbuns e faixas para identificar e corrigir erros ou incongruências. Músicas internacionais ou de artistas internacionais foram descartadas.
3. **Normalização:** As características de áudio foram padronizadas e normalizadas para garantir consistência e comparabilidade entre faixas.

O conjunto resultante fornece uma visão abrangente sobre faixas de artistas brasileiros, centrando-se em suas características e emoções associadas. Entretanto, é importante ressaltar que, por ser baseado em *playlists* categorizadas como “triste” e “feliz”, o conjunto pode não abranger a total diversidade da música brasileira. Cada entrada do conjunto contém:

- Identificação do artista.
- Médias das características de áudio.
- Número de faixas utilizadas para cálculo das médias.
- Categoria emocional associada.

No total, foram coletadas informações de 260 faixas musicais, oriundas de 26 *playlists* de cada categoria emocional.

4. Resultados e Discussões

Nesta seção, são apresentados os resultados provenientes da aplicação de técnicas de aprendizado de máquina e do modelo de correlação de Pearson, buscando elucidar a relação entre as características das músicas brasileiras e a evocação de sentimentos nos ouvintes.

4.1. Existe uma correlação significativa entre as características técnicas de uma música brasileira e a evocação de sentimentos de alegria ou tristeza nos ouvintes?

Investigou-se a correlação entre propriedades técnicas intrínsecas da música brasileira, que se caracteriza por sua diversidade rítmica e melódica, e a indução de sentimentos de alegria ou tristeza. Para tal, duas metodologias analíticas foram empregadas: a *correlação de Pearson* e a análise de importância das características pelo modelo *Random Forest*.




Figura 1. Matriz de correlação de Pearson das características técnicas das músicas brasileiras e a evocação de sentimentos.

A *correlação de Pearson* (Figura 1) indicou uma forte associação entre a **valência** e sentimentos positivos, com um coeficiente de 0.45. Isso demonstra que, dentro do espectro da música brasileira, a positividade musical é um fator relevante na percepção emocional dos ouvintes. A **energia** surgiu como outro aspecto significativo, sugerindo que faixas com maior dinamismo são comumente associadas a estados de ânimo mais elevados. **Dançabilidade** e **vivacidade** também revelaram correlações positivas, implicando que a capacidade de uma música incitar movimento e sua percepção de ‘vida’ podem afetar positivamente o sentimento dos ouvintes. Em contraste, a duração e a assinatura temporal exibiram correlações mais baixas, o que pode sugerir uma influência secundária desses fatores na percepção emocional na música brasileira.

Em complemento, é ilustrado na Tabela 1, a análise de importância das características realizada pelo modelo *Random Forest* proporcionou uma visão quantitativa da contribuição individual de cada característica técnica na classificação dos sentimentos evocados pelas músicas brasileiras. A **energia** destacou-se como o atributo de maior peso, com uma importância de 19.52%, enfatizando seu papel central na definição do ânimo que a música brasileira pode proporcionar. A **valência**, com uma importância de 13.51%, e a **acústica**, com 10.97%, também foram identificadas como características influentes, corroborando a hipótese de que elementos como a positividade e a naturalidade sonora são determinantes na emoção transmitida pela música. A dançabilidade, com 9.67%, reafirma a relevância do ritmo na música brasileira, tradicionalmente voltada para a dança.

Características como **tonalidade** e **assinatura de tempo** demonstraram um impacto mais modesto na classificação dos sentimentos, com 4.06% e 0.71% respectivamente, sugerindo que, embora presentes, não são tão preponderantes na definição emocional da música quando comparadas a outros atributos.

Tabela 1. Análise de importância das características pelo modelo *Random Forest*.

Recursos de áudio	%
Energia	19,52%
Valência	13,50%
Acústica	10,97%
Danças	9,67%
Volume	8,81%
Fala	8,34%
Vivacidade	8,32%
Tempo	5,50%
Duração	5,68%
Tonalidade	4,06%
Instrumental	3,66%
Modo	1,24%
Assinatura temporal	0,71%

Conclui-se que, no contexto da música brasileira, características como energia e valência são preponderantes na evocação de sentimentos, enquanto dança e acústica também têm seus papéis significativos. Os resultados deste estudo sublinham a complexa interação entre as propriedades técnicas e a emoção na música, oferecendo uma compreensão mais rica da música brasileira como um poderoso vetor de expressão emocional.

4.2. A análise de sentimentos da letra da música realizada pelo ChatGPT concorda com a percepção dos ouvintes sobre o sentimento transmitido pela música?

A análise quantitativa da emoção nas letras das músicas brasileiras foi executada utilizando uma escala que varia de 0 a 1. A pontuação atribuída às letras reflete um espectro emocional, onde valores mais baixos correspondem a sentimentos de tristeza e valores mais altos a sentimentos de alegria. A categorização baseada nesta métrica numérica oferece uma perspectiva objetiva da tonalidade emocional das letras, permitindo uma interpretação sistemática do conteúdo emocional das canções. O *prompt* utilizado na plataforma para solicitar a análise emocional da letra da música foi formulado da seguinte maneira: *"Identify the emotions of sadness or happiness expressed by the writer in the following review. Return a single value between 0 and 1, where 0 indicates sadness and 1 indicates happiness. Your final answer should only be a numerical value."*

Para melhor entendimento utilizou-se a matriz de confusão como uma ferramenta de avaliação para comparar a classificação de sentimentos das letras realizada pelo ChatGPT com a percepção dos ouvintes.

Tabela 2. Matriz de confusão da classificação de sentimentos pelo ChatGPT

		Classificação do ChatGPT	
		[HTML]E4E0E0 alegre	[HTML]E4E0E0Triste
Classificação dos usuários	[HTML]E4E0E0 alegre	[HTML]9AFF99107	[HTML]FFCCC923
	[HTML]E4E0E0 Triste	[HTML]FFCCC948	[HTML]9AFF9982

Conforme a Tabela 2, a matriz de confusão indica que houve 107 verdadeiros positivos, refletindo letras alegres corretamente identificadas pelo ChatGPT. Por outro lado, 82 verdadeiros negativos representam as letras tristes corretamente classificadas. Falsos positivos somam 48, indicando letras tristes que foram classificadas como alegres, e falsos negativos totalizam 23, refletindo letras alegres classificadas como tristes pelo modelo.

Os dados sugerem que o *ChatGPT* possui uma capacidade mais consistente de classificar letras alegres corretamente em comparação com letras tristes, como evidenciado pela maior quantidade de verdadeiros positivos em relação aos verdadeiros negativos. A presença de 48 falsos positivos aponta para uma tendência do modelo em interpretar certas expressões tristes como alegres, o que pode ser decorrente de limitações na compreensão do contexto ou na identificação de nuances mais sutis da língua portuguesa.

A acurácia do modelo, calculada como a soma dos verdadeiros positivos e verdadeiros negativos dividida pelo total de classificações, resulta em uma taxa de acerto de aproximadamente 70%. No entanto, as discrepâncias observadas em falsos negativos e positivos fornecem um terreno fértil para análise.

Os falsos negativos, onde o ChatGPT classificou como tristes músicas consideradas alegres pelos ouvintes, foram frequentemente marcados por letras com linguagem explícita ou de duplo sentido. Este padrão sugere que o modelo pode não estar captando adequadamente as intenções implícitas ou o humor subjacente nessas expressões, um aspecto crítico na música brasileira, que é rica em trocadilhos e subtexto.

Em relação aos falsos positivos, músicas que os ouvintes sentiram como tristes, mas foram classificadas pelo ChatGPT como alegres, muitas vezes continham temas de amor ou pedidos de perdão. A recorrência da palavra ‘amor’, mesmo em contextos de lamento ou saudade, parece ter influenciado o modelo a associar essas canções a sentimentos positivos. Isso indica que o modelo pode estar atribuindo um peso emocional positivo à palavra ‘amor’, independentemente do contexto mais amplo da letra.

Estas descobertas apontam para desafios específicos que o modelo enfrenta ao interpretar a complexidade e a sutileza das emoções nas letras de músicas brasileiras. A presença de elementos culturais, uso de figuras de linguagem e a expressão de sentimentos contraditórios nas letras são aspectos que requerem uma análise mais contextualizada.

Os resultados da matriz de confusão revelam oportunidades para aprimorar o modelo de análise de sentimentos, visando um alinhamento mais preciso com a percepção emocional humana. A análise aprofundada dos falsos positivos e negativos pode fornecer *insights* sobre aspectos linguísticos específicos que requerem atenção, como o uso de metáforas, ironia ou elementos culturais inerentes às músicas brasileiras.

5. Conclusão

Neste estudo, foi explorada a complexidade das relações entre as características técnicas de músicas brasileiras e a percepção emocional dos ouvintes, revelando que atributos como energia, dançabilidade e valência têm influência significativa sobre a classificação de músicas como alegres ou tristes. A música brasileira, com sua diversidade rítmica e melódica, oferece um riquíssimo contexto para o estudo das emoções humanas em resposta à arte.

A análise de sentimentos das letras realizada pelo ChatGPT levantou questões importantes quanto à sua congruência com a percepção emocional dos ouvintes. Observou-se que o modelo, apesar de apresentar uma acurácia geral razoável, enfrentou desafios ao interpretar expressões de duplo sentido ou contextos emocionais complexos, particularmente aqueles envolvendo amor e perdão. Essas descobertas destacam a necessidade de um aprimoramento nos modelos de linguagem para que possam entender e refletir mais precisamente a complexidade emocional presente nas letras das músicas brasileiras.

As limitações deste trabalho incluem a subjetividade inerente à categorização das emoções pelas *playlists* dos usuários e as restrições impostas pela API do Spotify. Adicionalmente, a análise restringiu-se a duas dimensões emocionais, o que pode não ter capturado toda a amplitude emocional da música brasileira. Trabalhos futuros deverão expandir o espectro de emoções analisadas e considerar uma gama mais ampla de fontes de dados e métodos analíticos.


Recomenda-se também a exploração de modelos computacionais avançados para a análise de sentimentos em letras de música, aprimorando a capacidade de discernir sutilezas linguísticas e culturais. Isso pode incluir a utilização de técnicas de aprendizado profundo e a incorporação de um contexto cultural mais amplo nas análises.

Para superar as limitações da API do Spotify e a subjetividade das categorizações emocionais, futuras pesquisas podem empregar metodologias mais objetivas, como a análise de reações fisiológicas em conjunto com questionários detalhados e entrevistas para capturar as respostas emocionais dos ouvintes. A intersecção da tecnologia com a rica música brasileira continua a ser um campo promissor para a pesquisa, com o potencial de enriquecer nossa compreensão da interação entre música, emoção e experiência humana.

Referências

- Aguilar, M. (2014). Spotify comprou a empresa de dados musicais the echo nest. *UoL*.
- Bowling, D. L., Sundararajan, J., Han, S., and Purves, D. (2012). Expression of emotion in eastern and western music mirrors vocalization. *PloS one*, 7(3):e31942.
- Brattico, E., Alluri, V., Bogert, B., Jacobsen, T., Vartiainen, N., Nieminen, S., and Ter-vaniemi, M. (2011). A functional mri study of happy and sad emotions in music with and without lyrics. *Frontiers in psychology*, 2:308.
- Brown, T., Mann, B., Ryder, N., Subbiah, M., Kaplan, J. D., Dhariwal, P., Neelakantan, A., Shyam, P., Sastry, G., Askell, A., et al. (2020). Language models are few-shot learners. *Advances in neural information processing systems*, 33:1877–1901.
- Chiu, K.-L., Collins, A., and Alexander, R. (2021). Detecting hate speech with gpt-3. *arXiv preprint arXiv:2103.12407*.
- Custódio, K. C. d. L. et al. (2021). Padrões na preferência musical dos (as) brasileiros (as) sob a ótica do spotify.
- Esuli, A. and Sebastiani, F. (2007). Sentiwordnet: a high-coverage lexical resource for opinion mining. *Evaluation*, 17(1):26.

- Guthier, B., Ho, K., and El Saddik, A. (2017). Language-independent data set annotation for machine learning-based sentiment analysis. In *2017 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, pages 2105–2110.
- Hunter, P. G., Schellenberg, E. G., and Schimmack, U. (2010). Feelings and perceptions of happiness and sadness induced by music: Similarities, differences, and mixed emotions. *Psychology of Aesthetics, Creativity, and the Arts*, 4(1):47.
- J. Hartmann, J. Huppertz, C. S. and Heitmann, M. (2019). Comparing automated text classification methods. *International Journal of Research in Marketing*, 36(1):20–38.
- Kenyon-Dean, K. (2018). Sentiment analysis: It’s complicated!
- Kheiri, K. and Karimi, H. (2023). Sentimentgpt: Exploiting gpt for advanced sentiment analysis and its departure from current machine learning. *arXiv preprint arXiv:2307.10234*.
- Koelsch, S. (2014). Brain correlates of music-evoked emotions. *Nature Reviews Neuroscience*, 15(3):170–180.
- Kouloumpis, E., Wilson, T., and Moore, J. D. (2011). Twitter sentiment analysis: The good the bad and the omg! *Proceedings of the International AAAI Conference on Web and Social Media*.
- M. Birjali, M. K. and Beni-Hssane, A. (2021). A comprehensive survey on sentiment analysis: Approaches, challenges and trends. *KnowledgeBased Systems*, 226(1):107134.
- Mukherje, S. (2023). Número de usuários premium cresce 17decepçiona analistas. *CNN Brasil*.
- Mullen, T. and Collier, N. (2004). Sentiment analysis using support vector machines with diverse information sources. In *Proceedings of the 2004 Conference on Empirical Methods in Natural Language Processing*, pages 412–418, Barcelona, Spain. Association for Computational Linguistics.
- Panda, R., Malheiro, R., and Paiva, R. P. (2018). Novel audio features for music emotion recognition. *IEEE Transactions on Affective Computing*, 11:614 – 626.
- Praveen, S. and Vajrobol, V. (2023). Understanding the perceptions of healthcare researchers regarding chatgpt: a study based on bidirectional encoder representation from transformers (bert) sentiment analysis and topic modeling. *Annals of Biomedical Engineering*, pages 1–3.
- Sangnark, S., Lertwatechakul, M., and Benjangkprasert, C. (2019). Thai music emotion recognition based on western music. In *Journal of Physics: Conference Series*, volume 1195, page 012009. IOP Publishing.
- Taruffi, L., Pehrs, C., Skouras, S., and Koelsch, S. (2017). Effects of sad and happy music on mind-wandering and the default mode network. *Scientific reports*, 7(1):14396.

	INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DA PARAÍBA
	Campus Campina Grande
	R. Tranquílino Coelho Lemos, 671, Dinamérica, CEP 58432-300, Campina Grande (PB)
	CNPJ: 10.783.898/0003-37 - Telefone: (83) 2102.6200

Documento Digitalizado Ostensivo (Público)

Entrega TCC

Assunto:	Entrega TCC
Assinado por:	Renata Ferreira
Tipo do Documento:	Anexo
Situação:	Finalizado
Nível de Acesso:	Ostensivo (Público)
Tipo do Conferência:	Cópia Simples

Documento assinado eletronicamente por:

- Renata da Silva Ferreira, ALUNO (201911250033) DE BACHARELADO EM ENGENHARIA DE COMPUTAÇÃO - CAMPINA GRANDE, em 25/01/2024 08:35:37.

Este documento foi armazenado no SUAP em 25/01/2024. Para comprovar sua integridade, faça a leitura do QRCode ao lado ou acesse <https://suap.ifpb.edu.br/verificar-documento-externo/> e forneça os dados abaixo:

Código Verificador: 1061632

Código de Autenticação: d5d5820043

