



INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DO PIAUÍ
CAMPUS PICOS
TECNOLOGIA EM ANÁLISE E DESENVOLVIMENTO DE SISTEMAS

DANIEL ARAUJO LEAL

**ANÁLISE DE SENTIMENTOS EM COMENTÁRIOS DO YOUTUBE: UMA
INVESTIGAÇÃO SOBRE MÚSICA POPULAR CONTEMPORÂNEA**

PICOS, PIAUÍ
2026

DANIEL ARAUJO LEAL

ANÁLISE DE SENTIMENTOS EM COMENTÁRIOS DO YOUTUBE: UMA
INVESTIGAÇÃO SOBRE MÚSICA POPULAR CONTEMPORÂNEA

Trabalho de Conclusão de Curso (monografia) apresentado como exigência parcial para obtenção do diploma do Curso de Análise e Desenvolvimento de Sistemas do Instituto Federal de Educação, Ciência e Tecnologia do Piauí, Campus Picos.

Orientador: Prof. Dr. Rogério Figueiredo de Sousa

PICOS, PIAUÍ
2026

Dados Internacionais de Catalogação na Publicação (CIP) de acordo com ISBD

Leal, Daniel Araújo

L435a Análise de sentimentos em comentários do youtube : uma investigação sobre música popular contemporânea / Daniel Araújo Leal. - 2026.
34 f.

Trabalho de Conclusão de Curso (Tecnologia em Análise e Desenvolvimento de Sistemas) - Instituto Federal de Educação, Ciência e Tecnologia do Piauí, Campus Picos, 2026.

Orientador : Prof Dr. Rogério Figueiredo de Sousa.

Coorientador : Prof Dr. Rafael Torres Anchieta.

1. Processamento de Linguagem Natural (PLN). 2. Modelos de Linguagem de Grande Porte (LLM). 3. Plataformas digitais. 4. Comentários do YouTube. I. Título.

CDD - 004.21

Elaborado por Silvio de Carvalho Gomes Coutinho CRB 3/1362

DANIEL ARAUJO LEAL

ANÁLISE DE SENTIMENTOS EM COMENTÁRIOS DO YOUTUBE: UMA
INVESTIGAÇÃO SOBRE MÚSICA POPULAR CONTEMPORÂNEA

Trabalho de Conclusão de Curso (monografia) apresentado como exigência parcial para obtenção do diploma do Curso de Análise e Desenvolvimento de Sistemas do Instituto Federal de Educação, Ciência e Tecnologia do Piauí, Campus Picos.

Aprovada em 11 de agosto de 2026

BANCA EXAMINADORA:

Prof. Dr. Rogério Figueiredo de Sousa

Orientador
Instituto Federal do Piauí (IFPI)

Prof. Dr. Rafael Torres Anchieta

Coorientador
Instituto Federal do Piauí (IFPI)

Prof. M^e. Anthony Irlan Marques Luz

Instituto Federal do Piauí (IFPI)

Prof. M^e. Denis Costa Paiva

Instituto Federal do Piauí (IFPI)

PICOS, PIAUÍ
2026

RESUMO

Este estudo investiga os sentimentos expressos pelo público em comentários publicados em vídeos de música popular contemporânea no YouTube. Com o avanço das plataformas digitais e o aumento da interação entre usuários e conteúdos audiovisuais, tornou-se possível observar de forma sistemática como os ouvintes reagem às músicas que consomem. Para tanto, a pesquisa utiliza o modelo de linguagem Gemma 3 4B, executado com a técnica de *few-shot*, para classificar a polaridade dos comentários em três categorias: positiva, negativa e neutra. Foram coletados aproximadamente 21.700 comentários, dos quais 4.705 compuseram uma amostra anotada manualmente e utilizada como referência para a avaliação da classificação automática. O desempenho do modelo foi avaliado por meio das métricas de acurácia, precisão, revocação e *F1-score*. Na avaliação global, o modelo alcançou acurácia de 0,849 e *F1-macro* de 0,826. Na análise por vídeo, os valores de *F1-macro* variaram entre 0,538 e 0,943, demonstrando diferenças de desempenho entre os conjuntos de comentários analisados. A inspeção qualitativa identificou exemplos de avaliações mistas e expressões dependentes de contexto que podem orientar investigações posteriores sobre os erros de classificação, sem estabelecer relação causal entre essas características e o desempenho do modelo. Os resultados indicam que o Gemma 3 4B apresenta potencial para a classificação automática de sentimentos em comentários de vídeos musicais, embora seu desempenho varie entre diferentes conjuntos de comentários.

Palavras-chave: Música Popular Contemporânea, Comentários do YouTube, Processamento de Linguagem Natural (PLN), Análise de Sentimentos, Modelos de Linguagem de Grande Porte (LLM).

ABSTRACT

This study investigates the sentiments expressed by users in comments posted on contemporary pop music videos on YouTube. With the growth of digital platforms and the increasing interaction between users and audiovisual content, it has become possible to systematically observe how listeners react to the music they consume. To this end, this research employs the Gemma 3 4B language model using a *few-shot* approach to classify comment polarity into three categories: positive, negative, and neutral. Approximately 21,700 comments were collected, of which 4,705 were manually annotated and used as a reference set for evaluating the automatic classification. The model's performance was assessed using accuracy, precision, recall, and *F1-score*. In the global evaluation, the model achieved an accuracy of 0.849 and a macro *F1-score* of 0.826. In the per-video analysis, macro *F1-scores* ranged from 0.538 to 0.943, demonstrating performance differences across the analyzed comment sets. The qualitative inspection identified examples of mixed evaluations and context-dependent expressions that may guide further investigation of classification errors, without establishing a causal relationship between these characteristics and model performance. The results indicate that Gemma 3 4B has potential for automatic sentiment classification in music video comments, although its performance varies across different comment sets.

Keywords: Contemporary Popular Music, YouTube Comments, Natural Language Processing (NLP), Sentiment Analysis, Large Language Models (LLM).

LISTA DE ILUSTRAÇÕES

Figura 1 – Etapas do processo metodológico.	18
Figura 2 – Fluxo ilustrativo da anotação manual de sentimentos.	20
Figura 3 – Fluxo simplificado da categorização automática de sentimentos. . .	21
Figura 4 – Comparação de <i>F1-macro</i> entre arquivos de vídeos musicais. . . .	25

LISTA DE TABELAS

Tabela 1 – Classificação de Sentimentos	19
Tabela 2 – Exemplo de anotação manual de sentimento.	20
Tabela 3 – Exemplos de categorização automática gerada pelo modelo Gemma 3 4B.	21
Tabela 4 – <i>Classification report</i> global do modelo Gemma 3 4B.	23
Tabela 5 – Métricas de avaliação por vídeo musical.	24

LISTA DE ABREVIATURAS E SIGLAS

LLM	Large Language Model
-----	----------------------

SUMÁRIO

1	INTRODUÇÃO	11
2	TRABALHOS RELACIONADOS	13
3	FUNDAMENTAÇÃO TEÓRICA	15
3.1	A Música, seus Elementos e o Impacto Emocional	15
3.2	Plataformas Digitais e Interações do Público	16
3.3	Abordagens para Análise de Comentários	16
4	METODOLOGIA	18
4.1	Coleta de Dados	18
4.2	Pré-processamento dos Dados	19
4.3	Classificação e Análise	19
4.3.1	Classificação Manual	20
4.3.2	Classificação Automática	20
4.3.3	Métricas de Avaliação	21
5	RESULTADOS	23
5.1	Análise Qualitativa dos Comentários	25
5.1.1	Olivia Rodrigo - Obsessed	25
5.1.2	Lady Gaga & Bruno Mars - Die With a Smile	26
5.1.3	Rose & Bruno Mars - Apt	26
5.1.4	Ariana Grande - We Can't Be Friends (Wait for Your Love)	27
6	CONCLUSÃO	30
6.1	Trabalhos Futuros	31
	REFERÊNCIAS	33

1 INTRODUÇÃO

A música é uma das formas de expressão humana mais poderosas, capaz de evocar emoções, criar memórias e estabelecer conexões profundas entre as pessoas. Com o crescimento das plataformas de *streaming*, como o YouTube, a música se tornou ainda mais acessível e compartilhável, permitindo que ouvintes de diferentes partes do mundo compartilhem suas experiências e sentimentos em relação às canções. Nos comentários dessas plataformas, surgem dados valiosos que podem ser analisados, permitindo compreender os sentimentos expressos pelos usuários em relação às músicas.

A análise das reações emocionais de ouvintes, particularmente nos espaços digitais, levanta questões importantes sobre como as emoções são expressas e interpretadas em ambientes virtuais. A problemática central deste estudo envolve a complexidade de identificar e categorizar sentimentos nos comentários de vídeos musicais. Embora o aumento do volume de dados digitais ofereça um enorme potencial para análises, também apresenta desafios em termos de precisão e escalabilidade, especialmente quando se lida com um grande número de interações em diferentes idiomas e contextos culturais.

A motivação para realizar este estudo é a crescente importância de ferramentas automatizadas capazes de processar, analisar e interpretar os sentimentos expressos nas plataformas digitais. A utilização de técnicas de Processamento de Linguagem Natural (PLN), Análise de Sentimentos e Modelos de Linguagem de Grande Porte (LLM) oferece uma oportunidade de avançar nesse campo, possibilitando uma análise automatizada e em larga escala dos sentimentos dos usuários. O diferencial deste trabalho está na aplicação do modelo de linguagem Gemma 3 4B para a classificação automática de sentimentos em comentários de vídeos musicais, utilizando uma amostra de comentários anotados manualmente como referência para a avaliação do desempenho do modelo. Dessa forma, busca-se investigar o potencial dessa abordagem na análise automatizada de sentimentos em comentários publicados no YouTube.

O objetivo principal deste estudo é analisar os sentimentos expressos pelos ouvintes em comentários de vídeos musicais no YouTube, considerando as categorias Positivo, Negativo e Neutro. Para alcançar esse objetivo, foi empregada uma metodologia que combina técnicas de PLN, como análise de sentimentos e classificação de texto, permitindo uma análise automatizada e eficiente de grandes volumes de dados. A coleta de dados envolveu a extração de comentários de vídeos de músicas populares, sendo a maioria das canções analisadas composta e interpretada predominantemente em língua inglesa. Outro fator que motivou essa escolha foi a constatação da predominância do inglês nas interações coletadas, o que também se relaciona ao alcance

global da plataforma e à participação de usuários de diferentes países.

Apesar do avanço das pesquisas em análise de sentimentos, ainda são escassos os estudos que aplicam Modelos de Linguagem de Grande Porte (LLM) especificamente para compreender reações emocionais à música popular contemporânea em larga escala. Assim, este trabalho contribui ao combinar anotações humanas e classificações automáticas para avaliar a eficácia dessas abordagens no contexto musical, preenchendo uma lacuna ainda pouco explorada na literatura.

Nas próximas seções, o leitor encontrará uma descrição detalhada da metodologia utilizada, dos resultados obtidos e das discussões sobre as implicações desses achados para o campo da ciência de dados aplicada à música e à análise de sentimentos.

2 TRABALHOS RELACIONADOS

(AFONSO; GOTTSCHALG-DUQUE, 2019) analisam sentimentos em comentários do YouTube utilizando o *software Weka* e o classificador SMO. Os autores compararam classificações com três polaridades (positiva, negativa e neutra) e duas polaridades (negativa e não negativa), obtendo 81% de precisão ao focar em postagens que mencionam uma entidade específica. Ressaltam que a ausência de filtragem torna a análise confusa, enquanto a utilização de palavras-chave garante que 100% dos dados coletados sejam relevantes, melhorando a precisão. Concluem que múltiplas entidades dificultam a classificação da polaridade pelos algoritmos tradicionais.

(AFONSO; TÉ, 2017) investigam a construção de opiniões no YouTube por meio da referenciação, com foco no processo de impeachment da presidente Dilma Rousseff. O estudo explora como o fenômeno da referenciação ocorre nas postagens opinativas, observando como o objeto discursivo “impeachment” é reconfigurado em formas nominais pelos internautas. A pesquisa analisa a relação entre essas formas nominais e as polaridades expressas nas opiniões (positivas ou negativas), utilizando ferramentas de análise de corpora. Os autores discutem como as formas nominais variam entre postagens a favor e contra o impeachment, contribuindo para o aprimoramento da análise de sentimentos em mídias sociais.

(AFONSO, 2017) apresenta estudo sobre a referenciação em postagens do YouTube, com foco na análise de sentimentos. A pesquisa investiga como diferentes referentes (como personagens, cenas, críticas e outros elementos de um filme) são mencionados em postagens positivas, negativas e neutras, e como essas informações podem aprimorar técnicas de análise de sentimentos. Utilizando análise de conteúdo e discurso, além de *software* estatístico, o estudo identifica e quantifica a frequência das palavras nos comentários. Os resultados indicam que postagens, mesmo positivas ou negativas, frequentemente contêm opiniões mistas sobre diferentes referentes, mostrando que a polaridade nem sempre é clara. A pesquisa conclui que, para aprimorar a análise de sentimentos em postagens de vídeos, é essencial desenvolver critérios que considerem a complexidade e diversidade das opiniões expressas.

(CICILIO; SAQUI, 2023) investigam a relação entre linguagem emocional em vídeos educacionais e engajamento dos alunos no YouTube, utilizando um algoritmo de análise de sentimentos aplicado às legendas extraídas dos vídeos. Os autores correlacionaram as emoções expressas nos comentários com a proporção de *likes/views*, mas os resultados indicaram que a correlação entre positividade da linguagem e engajamento foi mínima. Destacam que outros fatores, como elementos visuais, humor e conteúdo curioso, tiveram maior impacto no engajamento. Concluem que a análise de sentimentos isolada não é suficiente para explicar o engajamento, sugerindo que

futuras pesquisas considerem elementos adicionais para compreender os fatores que motivam a interação dos espectadores.

(ALVES *et al.*, 2024) investigam comentários publicados em *trailers* de filmes da Netflix Brasil no YouTube, explorando interações do público por meio de análise de sentimentos. A pesquisa destaca que há um pico de comentários logo após o lançamento dos trailers, seguido de uma queda acentuada ao longo do tempo. Além disso, os autores identificam correlações entre curtidas, duração dos vídeos e o volume de comentários positivos, indicando que *trailers* mais longos tendem a gerar maior engajamento. O trabalho emprega técnicas de Processamento de Linguagem Natural (PLN) com apoio do modelo GPT (Generative Pre-trained Transformer) via ChatGPT, que demonstrou eficiência superior em relação a métodos tradicionais de classificação de sentimentos. Esse estudo reforça a relevância da aplicação de IA para lidar com grandes volumes de dados em língua portuguesa, suprimindo a lacuna existente frente à predominância de pesquisas em inglês.

(KUILA; SARKAR, 2024) analisam a aplicação de Modelos de Linguagem de Grande Porte (LLM) na identificação de sentimentos relacionados a entidades presentes em notícias políticas. Os autores avaliam estratégias zero-shot e few-shot, utilizando modelos como Mistral-7B, LLaMA2-13B e Falcon-40B, além de técnicas de Chain-of-Thought e aprendizagem em contexto. Os resultados demonstram que os Modelos de Linguagem de Grande Porte (LLM) podem superar modelos BERT ajustados especificamente para a tarefa e que a utilização de exemplos em contexto melhora significativamente o desempenho da classificação. Entretanto, os autores observam que os benefícios do Chain-of-Thought não são consistentes em todos os experimentos, destacando a importância da escolha adequada das estratégias de prompting.

Diferentemente dos trabalhos relacionados, este estudo analisa comentários em vídeos de música popular contemporânea em larga escala, com foco em produções de alcance global e interações em inglês, cenário ainda pouco explorado na literatura. Enquanto pesquisas anteriores priorizam abordagens discursivas, classificadores supervisionados tradicionais ou métodos lexicais, este trabalho utiliza o modelo Gemma 3 4B no esquema de inferência *few-shot*, tendo como referência uma base de comentários anotados manualmente para a avaliação do desempenho. A utilização do Gemma 3 4B, associada à validação por anotações manuais, permite avaliar sua capacidade de classificar sentimentos em comentários de vídeos musicais. Assim, a pesquisa contribui ao oferecer uma metodologia baseada em métricas quantitativas e análise por vídeo, ampliando a compreensão do desempenho e das limitações da análise automática de sentimentos no contexto da música popular contemporânea.

3 FUNDAMENTAÇÃO TEÓRICA

A Fundamentação Teórica apresentada neste capítulo fornece o embasamento conceitual necessário para compreender como a música influencia as emoções humanas e de que maneira essas respostas emocionais se manifestam nas interações dos usuários em plataformas digitais. Inicialmente, discute-se o impacto psicológico e emocional da música, abordando como elementos musicais como melodia e letra contribuem para a construção de significados e experiências afetivas. Em seguida, são exploradas as dinâmicas contemporâneas das plataformas de *streaming* e das mídias sociais, destacando como elas transformam as formas de engajamento do público e permitem novas expressões emocionais por meio de comentários e interações online. Por fim, apresentam-se abordagens utilizadas para a análise de comentários, com enfoque na análise qualitativa e em técnicas de análise de sentimentos, utilizadas para investigar as reações manifestadas nos conteúdos textuais dos usuários.

3.1 A MÚSICA, SEUS ELEMENTOS E O IMPACTO EMOCIONAL

A música tem sido um elemento central nas culturas humanas ao longo de milênios, desempenhando um papel significativo na expressão emocional e na formação de identidades individuais e coletivas. A música e a emoção têm uma relação amplamente discutida na literatura acadêmica. Vários estudos mostram que a música pode afetar seus ouvintes e evocar uma ampla gama de emoções, que vão desde euforia e alegria até tristeza e melancolia (JUSLIN; SLOBODA, 2011). As respostas emocionais à música podem ser tanto universais quanto subjetivas, influenciadas por fatores culturais, contextuais e individuais. Estudos em neurociência revelam que a música estimula áreas do cérebro associadas ao processamento de emoções, como o sistema límbico, que inclui a amígdala e o hipocampo (KOELSCH, 2014). A ativação dessas áreas ajuda a compreender por que elementos musicais podem estar associados a diferentes respostas emocionais.

Além da relação entre música e emoção, os diferentes elementos presentes em uma composição contribuem para a construção da experiência musical. Compositores de música popular elaboram letras, melodia e instrumentação em conjunto para criar uma cena emocional consistente e envolvente. As relações entre esses elementos são relevantes para a comunicação musical, e compreender as características dessas relações pode contribuir para diferentes problemas na recuperação de informações musicais e no suporte à criatividade (NICHOLS *et al.*, 2009).

A letra acrescenta à música um componente verbal capaz de transmitir narrativas, ideias e sentimentos, enquanto elementos como melodia e instrumentação

participam da construção da experiência sonora. Dessa forma, as reações dos ouvintes podem estar relacionadas a diferentes componentes da obra musical. A compreensão de como esses elementos são mencionados e discutidos nos comentários pode fornecer informações sobre as percepções expressas pelo público em relação às músicas analisadas.

3.2 PLATAFORMAS DIGITAIS E INTERAÇÕES DO PÚBLICO

Antigamente, as audiências da música de massa não tinham uma relação “real” com os artistas, que eram poderosos e distantes (BAYM, 2018). Atualmente, os músicos buscam se conectar com seus públicos por diferentes plataformas, tentando estabelecer uma presença e criar vínculos mais diretos (BAYM, 2018). Nesse contexto, as plataformas digitais modificaram não apenas as formas de distribuição e consumo da música, mas também as possibilidades de interação entre artistas e ouvintes.

As possibilidades conectivas das mídias sociais permitem a expressão e o compartilhamento de informações, experiências e percepções entre os usuários. Esses públicos podem ser ativados e sustentados por sentimentos de pertencimento e solidariedade, ainda que esses vínculos possam apresentar diferentes níveis de duração e intensidade (PAPACHARISSI, 2015). Em plataformas que permitem comentários e outras formas de participação, os ouvintes passam a dispor de espaços nos quais podem registrar suas reações e compartilhar suas percepções sobre os conteúdos consumidos.

Além disso, as mídias sociais possibilitam a formação de comunidades em torno de interesses e experiências compartilhadas. Nessas comunidades, a música pode atuar como um elemento de conexão entre indivíduos, contribuindo para a formação de identidades coletivas e para o compartilhamento de experiências emocionais (PAPACHARISSI, 2015). Canções, performances musicais e gêneros podem, assim, contribuir para a formação de públicos que se organizam em torno de interesses e experiências afetivas compartilhadas.

No contexto do YouTube, os comentários publicados em vídeos musicais constituem uma forma direta de manifestação do público. Esses espaços permitem que os usuários expressem opiniões sobre músicas e artistas, compartilhem experiências pessoais e interajam com outros ouvintes. Dessa forma, os comentários podem ser utilizados como fonte de dados textuais para investigar as percepções e os sentimentos manifestados pelo público em relação aos conteúdos musicais.

3.3 ABORDAGENS PARA ANÁLISE DE COMENTÁRIOS

A análise de comentários pode ser realizada por meio de diferentes abordagens. A análise qualitativa permite uma investigação mais aprofundada das nuances

emocionais expressas pelos usuários (THELWALL, 2017). Nesse contexto, a análise de conteúdo qualitativa possibilita identificar padrões e temas presentes nos comentários, como manifestações de alegria ou tristeza, contribuindo para a compreensão das reações emocionais dos usuários (HSIEH; SHANNON, 2005).

De forma complementar, a análise de sentimentos utiliza ferramentas computacionais para avaliar a polaridade expressa em conteúdos textuais. Segundo (LIU, 2012), essa abordagem permite identificar opiniões e sentimentos presentes nos textos, sendo comum sua organização em categorias de polaridade. No contexto deste estudo, são consideradas as categorias Positivo, Negativo e Neutro, permitindo uma visão geral das classificações atribuídas aos comentários.

Entre as abordagens computacionais aplicadas à análise de sentimentos, os Modelos de Linguagem de Grande Porte (LLM) têm sido utilizados em diferentes tarefas de Processamento de Linguagem Natural. Zhang *et al.* (2024) avaliaram esses modelos em diferentes tarefas de análise de sentimentos e observaram resultados satisfatórios em tarefas de classificação, especialmente em cenários de *few-shot learning*, nos quais poucos exemplos são fornecidos ao modelo como contexto. Essa abordagem permite orientar a classificação por meio de exemplos previamente rotulados, sem a necessidade de um novo treinamento específico.

A utilização de métodos computacionais possibilita analisar um volume maior de dados e organizar as manifestações dos usuários de maneira estruturada. Entretanto, a análise quantitativa pode ser complementada pela observação qualitativa de comentários específicos, permitindo examinar de maneira mais detalhada determinados exemplos presentes no conjunto analisado. Dessa forma, as abordagens qualitativa e quantitativa oferecem perspectivas complementares para a análise dos comentários. Enquanto a classificação de sentimentos permite observar a distribuição das categorias e avaliar o desempenho da classificação automática, a inspeção qualitativa possibilita examinar exemplos específicos e características presentes nos textos.

4 METODOLOGIA

O processo metodológico foi estruturado em quatro etapas principais: (I) Coleta de Dados, (II) Pré-processamento, (III) Classificação e Análise e (IV) Interpretação dos Resultados.




Figura 1 – Etapas do processo metodológico.

4.1 COLETA DE DADOS

A coleta foi realizada por meio da API YouTube Data v3¹, entre os dias 31 de julho e 1º de agosto de 2025. Foram escolhidos vídeos das músicas mais populares de 2024, priorizando obras de grande alcance e ampla audiência após o lançamento. Essa estratégia teve como objetivo obter uma amostra representativa das interações do público consumidor de música popular contemporânea no conjunto analisado.

Devido ao alcance global dessas músicas e à predominância do inglês nas interações coletadas, o *dataset* é composto majoritariamente por comentários em inglês, refletindo a participação de uma audiência internacional. Ao todo, foram obtidos aproximadamente 21.700 comentários, contendo informações como texto do comentário, autor, data de publicação e número de curtidas.

Durante a coleta, foram aplicados filtros baseados em palavras-chave com o objetivo de selecionar comentários que apresentassem conteúdo relacionado à música ou à percepção dos ouvintes. A lista utilizada contemplou termos associados a aspectos musicais, como melodia, harmonia, ritmo, letra e elementos vocais; características de produção e mixagem; referências à conexão e ao impacto emocional; aspectos relacionados à narrativa e ao significado da música; além de termos utilizados em avaliações positivas ou negativas das canções. Dessa forma, buscou-se reduzir a presença de comentários sem relação direta com os aspectos investigados no estudo.

Também foram excluídos comentários compostos por múltiplas linhas, considerados possíveis transcrições de estrofes. Além disso, os comentários foram comparados com as letras das músicas utilizando a medida de similaridade implementada no algoritmo de coleta, com limiar de 0,8. Comentários considerados semelhantes a trechos das letras foram removidos. A coleta foi limitada a, no máximo, 300 comentários principais por vídeo, sem incluir respostas a outros comentários. Esse limite foi estabelecido como um critério de padronização da coleta, buscando manter uma quantidade

¹ Documentação oficial da API YouTube Data v3 disponível em: <<https://developers.google.com/youtube/v3?hl=pt-br>>.

comparável de comentários entre os diferentes vídeos analisados e evitar que vídeos com maior volume de interações tivessem participação desproporcional no conjunto de dados. Além disso, a delimitação tornou viável o processamento e a posterior análise manual da amostra. O valor de 300 comentários, portanto, corresponde a um limite operacional adotado para cada vídeo, e não a um tamanho amostral determinado por cálculo estatístico.

Os dados completos coletados estão disponíveis neste repositório²

4.2 PRÉ-PROCESSAMENTO DOS DADOS

Após a coleta, os dados foram padronizados e preparados para análise. Em seguida, aplicou-se a transformação numérica das categorias de sentimento, conforme a seguinte regra:

Tabela 1 – Classificação de Sentimentos

Sentimento	Valor
Positivo	1
Neutro	0
Negativo	-1

Essa padronização possibilitou a aplicação de métricas de desempenho utilizadas em tarefas de classificação (LIU, 2012). As implementações foram realizadas em Python, com uso das bibliotecas *pandas*³ e *regex*⁴ para manipulação textual e estrutural dos dados.

4.3 CLASSIFICAÇÃO E ANÁLISE

A etapa de classificação e análise teve como objetivo identificar e avaliar os sentimentos expressos nos comentários dos usuários. Para isso, foram utilizadas duas etapas complementares: a classificação manual, realizada por um único anotador humano (o próprio autor), com base em diretrizes previamente estabelecidas, e a classificação automática, realizada pelo modelo Gemma 3 4B. Por se tratar de uma rotulagem individual, o processo dispensou protocolos de resolução de divergências.

As anotações manuais foram utilizadas como referência para avaliar as classificações produzidas automaticamente, permitindo identificar concordâncias e divergências entre os rótulos humanos e as previsões do modelo. As subseções a seguir detalham os procedimentos adotados em cada etapa.

² Os dados completos coletados estão disponíveis no Google Drive: <https://drive.google.com/drive/folders/1k6WbFSVeyDE4Me6NYD7N857gGjej3H_i?usp=sharing>.

³ <<https://pandas.pydata.org/>>

⁴ <<https://docs.python.org/3/library/re.html>>

4.3.1 Classificação Manual

Uma amostra de 4.705 comentários foi rotulada manualmente em três categorias: *Positivo*, *Neutro* e *Negativo*. Esse conjunto serviu como base de referência para a avaliação da classificação automática realizada pelo modelo Gemma 3 4B, conforme apresentado na Tabela 2.

Tabela 2 – Exemplo de anotação manual de sentimento.

Classe	Comentário Original	Tradução aproximada	Sentimento
Positive	The best song I've ever heard in my entire life, nothing beats this song.	A melhor música que já ouvi em toda a minha vida, nenhuma outra consegue superá-la.	Positive




Figura 2 – Fluxo ilustrativo da anotação manual de sentimentos.

4.3.2 Classificação Automática

A classificação automática dos comentários foi realizada utilizando o modelo de linguagem Gemma 3 4B, executado localmente via *Ollama*⁵. Foi utilizada a técnica de *few-shot*, na qual exemplos previamente anotados são fornecidos como contexto para orientar a classificação realizada pelo modelo.

Os exemplos utilizados contemplam as três categorias de interesse (*Negativo*, *Positivo* e *Neutro*), cada um acompanhado de uma justificativa sintética. Foram selecionados cinco exemplos para compor o contexto fornecido ao modelo. O prompt base aplicado ao Gemma 3 4B encontra-se a seguir:

⁵ <<https://ollama.com/>>

Quadro 4.1 – Prompt utilizado na classificação automática com o modelo Gemma 3 4B.

Prompt
“Você é um especialista em análise de sentimentos. Classifique o comentário de vídeo musical do YouTube como <i>Positivo</i> , <i>Negativo</i> ou <i>Neutro</i> e forneça uma justificativa breve em uma frase.”

Fonte: Elaborado pelo autor.

A Tabela 3 apresenta exemplos representativos gerados pelo modelo durante o processo de categorização automática.

Tabela 3 – Exemplos de categorização automática gerada pelo modelo Gemma 3 4B.

Classificação	Comentário	Justificativa
Negativo	“This morbid song really sucks, one of the top 5 worst songs of all time.”	Expressa rejeição intensa e avaliação extremamente negativa da música.
Positivo	“I love this song... it reminds me of leaving my hometown and feeling happy again.”	Associa a música a lembranças positivas e sentimentos de satisfação.
Neutro	“First verse sounds like Rihanna. It’s ok, but the lyrics could be better.”	Apresenta uma avaliação moderada, combinando apreciação e crítica.




Figura 3 – Fluxo simplificado da categorização automática de sentimentos.

A escolha do modelo Gemma 3 4B considerou sua possibilidade de execução local. Diferentemente de modelos de maior porte, que podem demandar maior capacidade computacional, o Gemma 3 4B pode ser executado localmente, característica compatível com a infraestrutura utilizada nesta pesquisa.

4.3.3 Métricas de Avaliação

O desempenho das classificações automáticas foi comparado com as anotações manuais por meio de métricas clássicas utilizadas em tarefas de classificação (PEDREGOSA *et al.*, 2011), tais como:

1. Acurácia, correspondente à proporção de classificações corretas no conjunto avaliado;
2. Precisão por classe;
3. Revocação por classe;
4. *F1-score* por classe;
5. *F1-macro*;
6. *F1-score* ponderado (*weighted average*).

A acurácia corresponde à proporção total de comentários classificados corretamente. A precisão indica, para cada classe, a proporção de previsões corretas entre os comentários que o modelo classificou naquela categoria. A revocação representa a proporção de comentários pertencentes a uma determinada classe que foram corretamente identificados pelo modelo.

O *F1-score* corresponde à média harmônica entre precisão e revocação, buscando representar um equilíbrio entre essas duas métricas. O *F1-macro* é calculado a partir da média aritmética dos valores de *F1-score* das três classes, atribuindo o mesmo peso a cada categoria, independentemente de sua frequência. Já o *F1-score* ponderado considera o suporte de cada classe, atribuindo maior influência às categorias com maior número de exemplos. Nesse contexto, o suporte corresponde à quantidade de comentários pertencentes a cada classe no conjunto de referência.

Todas as métricas foram calculadas em Python, com apoio da biblioteca *scikit-learn* (PEDREGOSA *et al.*, 2011).

5 RESULTADOS

Os resultados foram obtidos a partir da comparação entre as classificações automáticas realizadas pelo modelo Gemma 3 4B, utilizando a técnica de *few-shot*, e as anotações manuais utilizadas como referência. Inicialmente, apresenta-se uma avaliação global do desempenho do modelo, considerando as métricas de precisão, revocação e *F1-score* para cada uma das três classes de sentimento. Em seguida, o desempenho é analisado individualmente por vídeo musical, permitindo observar variações entre os diferentes conjuntos de comentários.

A Tabela 4 apresenta o *classification report* global do modelo. Essa avaliação considera 4.705 comentários presentes no conjunto utilizado para o cálculo das métricas. Os resultados são apresentados separadamente para as classes Negativo, Neutro e Positivo, além das médias macro e ponderada. A acurácia global é apresentada separadamente no texto, por se tratar de uma métrica calculada sobre o conjunto completo de classificações.

Tabela 4 – *Classification report* global do modelo Gemma 3 4B.

Classe	Precisão	Revocação	<i>F1-score</i>	Suporte
Negativo	0.760	0.936	0.839	955
Neutro	0.765	0.701	0.731	1.216
Positivo	0.931	0.887	0.908	2.534
Média macro	0.818	0.841	0.826	4.705
Média ponderada	0.853	0.849	0.848	4.705

Fonte: Autor

De forma global, o modelo alcançou acurácia de 0.849 e *F1-score* ponderado de 0.848. Entre as classes avaliadas, a classe Positivo apresentou o maior *F1-score* (0.908), seguida pela classe Negativo (0.839) e pela classe Neutro (0.731). A classe Positivo também apresentou a maior precisão (0.931), indicando elevada concordância com a anotação manual entre os comentários classificados pelo modelo nessa categoria.

A classe Negativo apresentou a maior revocação (0.936), indicando que o modelo identificou a maior parte dos comentários anotados manualmente nessa categoria. Entretanto, sua precisão foi de 0.760, evidenciando que parte das previsões negativas correspondeu a comentários anotados em outras classes. Já a classe Neutro apresentou o menor *F1-score* (0.731), resultado da combinação entre precisão de 0.765 e revocação de 0.701, sendo a classe com menor desempenho global entre as três categorias analisadas.

A média macro de *F1-score* foi de 0.826, enquanto a média ponderada foi de 0.848. Essa diferença deve ser considerada em conjunto com a distribuição das classes, uma vez que a classe Positivo possui 2.534 ocorrências, enquanto as classes Negativo e Neutro possuem 955 e 1.216 ocorrências, respectivamente. Como a média ponderada considera o suporte de cada classe, as classes mais frequentes exercem maior influência sobre seu valor. Por outro lado, o *F1-macro* atribui o mesmo peso às três classes, permitindo avaliar o desempenho do modelo sem privilegiar as classes mais frequentes.

Além da avaliação global, o desempenho do modelo foi analisado separadamente para cada vídeo musical. Para essa comparação, adotou-se principalmente o *F1-macro*, uma vez que essa métrica calcula o *F1-score* individualmente para cada classe e, em seguida, realiza a média aritmética entre elas. Dessa forma, todas as classes possuem o mesmo peso na avaliação, independentemente de sua frequência no conjunto de dados. Assim, valores mais elevados de *F1-macro* indicam melhor desempenho médio do modelo entre as classes, e não maior equilíbrio na quantidade de exemplos de cada categoria.


A Tabela 5 apresenta os valores de acurácia e *F1-macro* obtidos para cada vídeo analisado. Os resultados são derivados da comparação entre as classificações automáticas e as anotações manuais. Para a obtenção desses resultados, foi utilizado o modelo Gemma 3 4B com a técnica de *few-shot*, na qual cinco exemplos foram previamente selecionados como contexto.

Tabela 5 – Métricas de avaliação por vídeo musical.

Vídeo	Acurácia	<i>F1-macro</i>
Olivia Rodrigo – Obsessed	0.947	0.943
Lady Gaga & Bruno Mars – Die With a Smile	0.960	0.938
Rose & Bruno Mars – Apt.	0.953	0.934
Sabrina Carpenter – Espresso	0.933	0.918
Dua Lipa – Training Season	0.903	0.897
Taylor Swift – Fortnight (feat. Post Malone)	0.854	0.873
Tyla – Water (Official Audio)	0.888	0.842
Kendrick Lamar – Not Like Us	0.847	0.828
Charli XCX feat. Billie Eilish – Guess	0.833	0.833
SZA – Snooze (Audio)	0.850	0.796
Benson Boone – Beautiful Things	0.873	0.795
Chappell Roan – Good Luck Babe	0.820	0.790
Billie Eilish – Birds of a Feather	0.810	0.704
Artemas – I Like the Way You Kiss Me (Lyric Video)	0.696	0.669
Beyoncé – Texas Hold 'Em	0.753	0.613
Ariana Grande – We Can't Be Friends (Wait for Your Love)	0.650	0.538

Fonte: Autor

Figura 4 – Comparação de *F1-macro* entre arquivos de vídeos musicais.



Fonte: Autor

A Figura 4 permite visualizar a variação dos valores de *F1-macro* entre os vídeos analisados, destacando os conjuntos nos quais o modelo apresentou maiores e menores desempenhos médios entre as classes. As métricas, entretanto, não permitem determinar isoladamente quais características dos comentários estão relacionadas a essas diferenças. Por esse motivo, os resultados quantitativos foram utilizados como ponto de partida para uma inspeção qualitativa de alguns comentários, buscando identificar casos que possam indicar possibilidades para a investigação dos erros de classificação.

Inicialmente, são apresentados exemplos dos três vídeos que obtiveram os maiores valores de *F1-macro*. Os exemplos possuem caráter ilustrativo e não constituem, por si só, evidência de que determinadas características discursivas tenham causado o desempenho observado.

5.1 ANÁLISE QUALITATIVA DOS COMENTÁRIOS

5.1.1 Olivia Rodrigo - Obsessed

- **Comentário positivo:** *"She's got a song for almost every situation I swear! I enjoy artists who're able to be diverse and multi-facet when it comes to them being able to express themselves in their art in different ways."*

Tradução aproximada: "Ela tem uma música para quase todas as situações, eu juro! Gosto de artistas que conseguem ser diversos e multifacetados quando se trata de se expressar artisticamente de diferentes maneiras."

Justificativa: O comentário demonstra admiração pela versatilidade de Olivia Rodrigo e pela capacidade da artista de se expressar de diferentes formas em suas músicas.

- **Comentário negativo:** *"This song is annoying"*

Tradução aproximada: “Essa música é irritante.”

Justificativa: O comentário expressa diretamente uma percepção negativa sobre a música, caracterizando-a como irritante.

- **Comentário neutro:** *"The main chorus kinda sounds like telephone by Lady Gaga and Beyonce.... Just me???"*

Tradução aproximada: “A parte principal do refrão meio que parece Telephone, da Lady Gaga e Beyoncé... Só eu acho isso?”

Justificativa: O comentário estabelece uma comparação entre elementos musicais da canção e outra obra, sem apresentar uma avaliação claramente positiva ou negativa.

5.1.2 Lady Gaga & Bruno Mars - Die With a Smile

- **Comentário positivo:** *"This will go down in history as one of the best songs of all time."*

Tradução aproximada: “Isso ficará para a história como uma das melhores músicas de todos os tempos.”

Justificativa: O comentário apresenta uma avaliação positiva explícita da colaboração e dos artistas.

- **Comentário negativo:** *"This is such a boring song,"*

Tradução aproximada: “Essa é uma música muito chata.”

Justificativa: O comentário manifesta insatisfação de forma direta ao considerar a música entediante.

- **Comentário neutro:** *"The guitar is oddly similar to let go(acoustic)by ark patrol"*

Tradução aproximada: “A guitarra é estranhamente parecida com a de Let Go (Acoustic), do Ark Patrol”.

Justificativa: O comentário apenas estabelece uma semelhança entre a guitarra da música e outra canção, sem manifestar claramente uma avaliação positiva ou negativa.

5.1.3 Rose & Bruno Mars - Apt

- **Comentário positivo:** *"Love this kind of music! Very fun, catchy, and upbeat! We need more songs like this."*

Tradução aproximada: “Adoro esse tipo de música! Muito divertida, cativante e animada! Precisamos de mais músicas assim.”

Justificativa: O comentário apresenta uma avaliação positiva explícita, destacando características da música consideradas agradáveis pelo usuário.

- **Comentário negativo:** *"this is the most generic thing this year..cg.."*
Tradução aproximada: "Isso é a coisa mais genérica deste ano."
Justificativa: O comentário apresenta uma avaliação negativa ao caracterizar a música como genérica.
- **Comentário neutro:** *"This is catchy and maybe cute, but upon further listens, it lacks any substance at all. The lyrics are completely incohesive, even with translations and context."*
Tradução aproximada: "É cativante e talvez até fofa, mas, depois de ouvir mais vezes, percebe-se que não tem conteúdo algum. A letra é completamente desconexa, mesmo com traduções e contexto."
Justificativa: O comentário combina uma apreciação inicial com críticas posteriores, tendo sido categorizado como neutro.

Os exemplos apresentados ilustram diferentes formas de expressão encontradas nos comentários analisados. Em alguns casos, a avaliação é expressa de maneira direta; em outros, um mesmo comentário combina apreciações e críticas. No caso de *Rose & Bruno Mars - Apt.*, apesar da presença de alguns comentários com avaliações mistas, o conjunto apresentou *F1-macro* elevado (0.934), sendo o terceiro maior entre os vídeos analisados. Portanto, os exemplos qualitativos não permitem concluir que essas construções tenham reduzido significativamente o desempenho global do modelo nesse vídeo. De modo geral, características como clareza, ambiguidade ou presença de avaliações mistas não foram mensuradas sistematicamente e, por isso, não podem ser apontadas como causas dos maiores ou menores valores de *F1-macro*.

5.1.4 Ariana Grande - We Can't Be Friends (Wait for Your Love)

Entre os vídeos analisados, *Ariana Grande - We Can't Be Friends (Wait for Your Love)* apresentou o menor *F1-macro*, com valor de 0.538. A inspeção qualitativa de alguns comentários desse conjunto revelou casos em que expressões emocionais e avaliações da música podem coexistir no mesmo comentário, dificultando a atribuição de uma única categoria de polaridade. Alguns exemplos são:

- *"i am in love with her vocal delivery in this. she sounds exactly like someone so exhausted from being broken-hearted"*
Tradução aproximada: "Estou apaixonado pela interpretação vocal dela nesta música. Ela soa exatamente como alguém exausto de sofrer por um coração partido."
Classificação automática: Negativo.
Classificação manual: Positivo.

- *"It already feels nostalgic "*

Tradução aproximada: "Já parece nostálgico."

Classificação automática: Positivo.

Classificação manual: Neutro.

Esses casos ilustram situações em que a atribuição de uma única categoria de polaridade pode exigir maior interpretação contextual, pois uma expressão de tristeza ou uma referência a uma experiência pessoal não corresponde necessariamente a uma avaliação negativa da música. Entretanto, a frequência desse tipo de construção não foi mensurada no conjunto de comentários. Dessa forma, os exemplos permitem identificar possibilidades para a investigação dos erros, mas não estabelecer que essas características tenham causado o menor *F1-macro* observado nesse vídeo.

Também foram observados qualitativamente comentários que combinam avaliações positivas e negativas em uma mesma manifestação, como nos exemplos a seguir:

- *"I wish there was an acoustic version of this song, I love it but for me it's ruined by all the extra house music style beats (not a fan of techno or house music) "*

Tradução aproximada: "Eu queria que houvesse uma versão acústica dessa música. Eu a adoro, mas, para mim, ela é prejudicada por todas essas batidas adicionais no estilo house (não sou fã de techno ou house)."

- *"The chorus is amazing, the tune is great but verses need to be longer and production quality needs to be better, the music overpowers during the verses and the lyrics cant be heard properly."*

Tradução aproximada: "O refrão é incrível e a melodia é ótima, mas os versos precisam ser mais longos e a qualidade da produção precisa melhorar; a música se sobrepõe durante os versos e não é possível ouvir a letra adequadamente."

Esses casos indicam possibilidades a serem investigadas na análise dos erros de classificação. Contudo, como a frequência dessas características e sua relação com os erros do modelo não foram quantificadas, não é possível afirmar que tenham sido responsáveis pelas diferenças de desempenho observadas entre os vídeos.

A análise por vídeo musical complementa as métricas globais ao indicar em quais conjuntos ocorreram os maiores e menores valores de *F1-macro*, direcionando a inspeção qualitativa para casos de interesse. Enquanto o *classification report* global evidencia diferenças de desempenho entre as classes, especialmente o menor *F1-score* da classe Neutro, a avaliação por vídeo ajuda a localizar conjuntos nos quais os erros e as divergências podem ser examinados com maior atenção.

De forma geral, os resultados indicam que o Gemma 3 4B, utilizando a técnica de *few-shot*, apresentou acurácia global de 0.849 e *F1-macro* de 0.826. A inspeção

qualitativa permitiu identificar exemplos de avaliações mistas e expressões dependentes de contexto que podem orientar análises posteriores dos erros. No entanto, a influência de características como ironia, ambiguidade, intensidade emocional ou diversidade discursiva sobre o desempenho do modelo não foi avaliada quantitativamente. A investigação específica desses fatores constitui, portanto, uma possibilidade para trabalhos futuros.

6 CONCLUSÃO

Este estudo investigou os sentimentos expressos pelo público em comentários de vídeos de música popular contemporânea no YouTube, utilizando o modelo de linguagem Gemma 3 4B com a técnica de *few-shot*. Para avaliar a classificação automática, uma amostra de 4.705 comentários foi anotada manualmente nas categorias Positivo, Neutro e Negativo e utilizada como referência para o cálculo das métricas de desempenho.

Os resultados demonstraram que o modelo alcançou acurácia global de 0,849 e *F1-macro* de 0,826. Na avaliação por classe, o maior *F1-score* foi obtido para a classe Positivo (0,908), seguido pelas classes Negativo (0,839) e Neutro (0,731). Esses resultados indicam diferenças no desempenho do modelo entre as categorias avaliadas, com menor desempenho para a identificação de comentários classificados como neutros.

A análise por vídeo também revelou variação no desempenho do modelo. Os valores de *F1-macro* variaram entre 0,538 e 0,943, indicando que o desempenho da classificação automática não foi uniforme entre os diferentes conjuntos de comentários. A inspeção qualitativa de alguns exemplos permitiu identificar casos envolvendo avaliações mistas e expressões dependentes de contexto, que podem orientar investigações posteriores sobre os erros de classificação. Entretanto, características como ironia, ambiguidade, intensidade emocional ou diversidade discursiva não foram mensuradas quantitativamente neste estudo e, portanto, não podem ser apontadas como causas das diferenças de desempenho observadas.

De forma geral, os resultados indicam que o Gemma 3 4B apresenta potencial para a classificação automática de sentimentos em comentários de vídeos musicais. A comparação entre as classificações produzidas pelo modelo e as anotações manuais permitiu avaliar quantitativamente seu desempenho e identificar diferenças tanto entre as classes de sentimento quanto entre os conjuntos de comentários analisados.

Como limitação, este estudo concentrou-se em comentários de vídeos de música popular lançados em 2024 e utilizou três categorias de sentimento, além de um único modelo de linguagem com a técnica de *few-shot*. Trabalhos futuros podem ampliar o conjunto de dados, investigar outros gêneros musicais, avaliar diferentes modelos de linguagem e estratégias de classificação e realizar análises específicas das características linguísticas presentes nos erros, como ironia, ambiguidade, avaliações mistas e dependência de contexto.

Dessa forma, o estudo contribui para a aplicação de técnicas de Processamento de Linguagem Natural na análise de sentimentos em ambientes digitais, apresentando um procedimento reprodutível para coleta, classificação e avaliação de comentários

relacionados à música. A abordagem desenvolvida também pode servir como referência para estudos futuros que investiguem a aplicação de Modelos de Linguagem de Grande Porte (LLM) na análise de sentimentos em conteúdos publicados em plataformas digitais.

Todo o código-fonte, os conjuntos de dados e os scripts utilizados encontram-se disponíveis em repositório público no GitHub¹.

6.1 TRABALHOS FUTUROS

Como continuidade deste estudo, recomenda-se a realização de trabalhos futuros que aprofundem e expandam a análise aqui desenvolvida. Entre as possibilidades, destacam-se:

1. **Ampliação do corpus:** incluir músicas de gêneros distintos como rock, hip hop, R&B e música clássica a fim de testar a estabilidade das métricas em diferentes estilos musicais e examinar como características próprias de cada gênero influenciam a expressão emocional dos ouvintes.
2. **Extensão da análise para múltiplos idiomas:** explorar como fatores culturais, regionais e linguísticos impactam a forma como usuários expressam emoções em plataformas digitais, revelando possíveis padrões culturais de sentimentalidade, subjetividade e ironia.
3. **Incorporação de modelos adicionais e novas camadas de pré-processamento:** considerar técnicas como normalização de gírias, detecção de ironia e interpretação de emojis, investigando se esses recursos aumentam a concordância entre a anotação humana e a classificação automática.

Essas direções contribuem para aprimorar a robustez das classificações automáticas, ampliar o alcance do estudo e fortalecer pesquisas futuras na interseção entre emoção, música e linguagem em mídias digitais.

¹ Disponível em: <https://github.com/safelydan/TCC_FINAL>

AGRADECIMENTOS

Primeiramente, gostaria de expressar minha profunda gratidão à minha família, em especial às minhas mães Edna Carvalho e Maria Joaquina, as mulheres da minha vida, exemplos de amor, renúncia e dedicação. Desde muito cedo vocês me incentivaram e apoiaram nos estudos, mesmo quando tudo era tão difícil. O carinho, a luta e a dedicação de vocês foram fundamentais em toda a minha trajetória. É por vocês e para vocês. Sou imensamente grato aos meus estimados orientadores, Rafael Anchiêta e Rogério Sousa, por sua paciência, disponibilidade e por todo o conhecimento compartilhado ao longo do curso e durante o desenvolvimento deste trabalho. Sem suas orientações, este momento não seria possível. Aos amigos e companheiros que o curso me presenteou, deixo minha sincera gratidão, especialmente a Hilizangela Thallia, James Morais e Joyce Moura que tornaram essa jornada mais leve, com apoio, incentivo e amizade inestimáveis. Não sei o que teria feito sem vocês. Muito obrigado por tudo. Por fim, agradeço a todos que, de alguma forma, contribuíram para a realização desta conquista.

REFERÊNCIAS

AFONSO, A. R. A referenciação em textos do youtube: um estudo com vistas à análise de sentimentos. **Liinc em Revista**, Rio de Janeiro, v. 13, n. 2, p. 357–370, 2017. Citado na página 13.

AFONSO, A. R.; GOTTSCHALG-DUQUE, C. Análise de sentimentos em comentários de vídeos do YouTube utilizando aprendizagem de máquinas supervisionada. **Ciência da Informação**, Brasília, DF, v. 48, n. 3, p. 21–33, sep 2019. Disponível em: <<https://brapci.inf.br/v/261113>>. Acesso em: 21 jul. 2026. Citado na página 13.

AFONSO, A. R.; TÉ, J. Um estudo sobre referenciação e a construção da opinião a partir de um corpus textual extraído do youtube. **Domínios de Linguagem**, v. 11, n. 2, p. 339–350, 2017. Disponível em: <<https://doi.org/10.14393/DL29-v11n2a2017-4>>. Citado na página 13.

ALVES, M. R. *et al.* Sentimentos em cena: uma análise dos comentários em trailers de filmes da netflix brasil no youtube. In: INSTITUTO FEDERAL GOIANO. **Anais do Simpósio Brasileiro de Informática na Educação (SBIE)**. [S.l.], 2024. p. 1–10. Citado na página 14.

BAYM, N. K. **Playing to the Crowd: Musicians, Audiences, and the Intimate Work of Connection**. New York: NYU Press, 2018. Citado na página 16.

CICILIO, R. M.; SAQUI, D. Análise de sentimentos aplicada a vídeos educacionais do youtube em busca de padrões de engajamento. **Revista Brasileira de Educação**, v. 27, n. 2, p. 121–128, 2023. Disponível em: <<https://josif.ifsuldeminas.edu.br/ojs/index.php/anais/article/view/810/723>>. Citado na página 13.

HSIEH, H.-F.; SHANNON, S. E. Three approaches to qualitative content analysis. **Qualitative Health Research**, v. 15, n. 9, p. 1277–1288, 2005. Citado na página 17.

JUSLIN, P. N.; SLOBODA, J. **Handbook of music and emotion: Theory, research, applications**. [S.l.]: Oxford University Press, 2011. Citado na página 15.

KOELSCH, S. Brain correlates of music-evoked emotions. **Nature reviews neuroscience**, Nature Publishing Group UK London, v. 15, n. 3, p. 170–180, 2014. Citado na página 15.

KUILA, A.; SARKAR, S. Deciphering political entity sentiment in news with large language models: Zero-shot and few-shot strategies. In: **Proceedings of the Second Workshop on Natural Language Processing for Political Sciences (PoliticalNLP 2024)**. [S.l.]: ELRA Language Resource Association, 2024. p. 1–11. Citado na página 14.

LIU, B. **Sentiment analysis and opinion mining**. [S.l.]: Morgan & Claypool Publishers, 2012. Citado 2 vezes nas páginas 17 e 19.

NICHOLS, E. *et al.* Relationships between lyrics and melody in popular music. In: **ISMIR 2009-Proceedings of the 11th International Society for Music Information Retrieval Conference**. [S.l.: s.n.], 2009. p. 471–476. Citado na página 15.

PAPACHARISSI, Z. **Affective publics: Sentiment, technology, and politics**. [S.l.]: Oxford University Press, 2015. Citado na página 16.

PEDREGOSA, F. *et al.* Scikit-learn: Machine learning in python. **the Journal of machine Learning research**, JMLR. org, v. 12, p. 2825–2830, 2011. Citado 2 vezes nas páginas 21 e 22.

THELWALL, M. The heart and soul of the web? sentiment strength detection in the social web with sentistrength. **Journal of the Association for Information Science and Technology**, v. 68, n. 8, p. 1608–1623, 2017. Citado na página 17.

ZHANG, W. *et al.* Sentiment analysis in the era of large language models: A reality check. In: **Findings of the Association for Computational Linguistics: NAACL 2024**. [S.l.]: Association for Computational Linguistics, 2024. p. 3881–3906. Citado na página 17.