

**UNIVERSIDADE FEDERAL DE MINAS GERAIS**  
**Instituto de Ciências Exatas**  
**Programa de Pós-Graduação em Ciência da Computação**

Rubio Torres Castro Viana

**Análise de Padrões Temáticos e Emocionais em Letras de Músicas  
Periféricas Brasileiras Utilizando Ciência de dados**

Belo Horizonte  
2024

Rubio Torres Castro Viana

**Análise de Padrões Temáticos e Emocionais em Letras de Músicas  
Periféricas Brasileiras Utilizando Ciência de dados**

**Versão Final**

Dissertação apresentada ao Programa de Pós-Graduação em  
Ciência da Computação da Universidade Federal de Minas  
Gerais, como requisito parcial à obtenção do título de Mestre  
em Ciência da Computação.

Orientadora: Mirella Moura Moro

Belo Horizonte  
2024

Viana, Rubio Torres Castro.

V614a      Análise de padrões temáticos e emocionais em letras de  
Músicas periféricas brasileiras utilizando ciência de dados  
[recurso eletrônico] / Rubio Torres Castro Viana - 2024.  
1 recurso online (104 f. il., color.) : pdf.

Orientadora: Mirella Moura Moro.

Dissertação (Mestrado) - Universidade Federal de Minas  
Gerais, Instituto de Ciências Exatas, Departamento de  
Ciência da Computação.

Referências: f. 79-88.

1. Computação – Teses. 2. Ciência de dados – Teses  
3. Processamento de Linguagem Natural – Teses. 4. Análise  
de sentimentos – Teses. 5. Música e Tecnologia – Teses.  
6. Periferias urbanas – Teses. 6. Etnomusicologia – Brasil  
– Teses. I. Moura, Mirella Moura Moro. II. Universidade  
Federal de Minas Gerais, Instituto de Ciências Exatas,  
Departamento de Ciência da Computação. III. Título.

CDU 519.6\*82(043)



UNIVERSIDADE FEDERAL DE MINAS GERAIS  
INSTITUTO DE CIÊNCIAS EXATAS  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

## FOLHA DE APROVAÇÃO

Análise de Padrões Temáticos e Emocionais em Letras de Músicas  
Periféricas Utilizando Ciência de Dados

**RUBIO TORRES CASTRO VIANA**

Dissertação defendida e aprovada pela banca examinadora constituída pelas Senhoras:

Documento assinado digitalmente  
**gov.br** MIRELLA MOURA MORO  
Data: 26/06/2025 14:33:30-0300  
Verifique em <https://validar.iti.gov.br>

PROFA. MIRELLA MOURA MORO - Orientadora  
Departamento de Ciência da Computação - UFMG

Documento assinado digitalmente  
**gov.br** KARIN BECKER  
Data: 26/06/2025 17:37:03-0300  
Verifique em <https://validar.iti.gov.br>

Profa. KARIN BECKER  
Departamento de Informática Aplicada - UFRGS

Documento assinado digitalmente  
**gov.br** MICHELE AMARAL BRANDÃO  
Data: 26/06/2025 16:18:35-0300  
Verifique em <https://validar.iti.gov.br>

Profa. MICHELE AMARAL BRANDÃO  
Instituto Federal de Educação Ciência e Tecnologia de Minas Gerais

Belo Horizonte, 12 de dezembro de 2024.

*Dedico este trabalho aos meus pais, que, sob o sol ardente, me permitiram chegar aqui, à sombra. E à minha noiva, que, ao meu lado, me ajuda a transformar essa sombra em nosso novo lar.*

# Agradecimentos

A conclusão deste trabalho marca um ponto importante na comédia dramática que é a minha vida, iniciada por um garoto de periferia repleto de sonhos e medos. Dedico este espaço a todos que tornaram possível essa trajetória.

Agradeço à música, por sua capacidade de cura e resiliência nos momentos mais difíceis, e aos esportes e atividades extracurriculares, que me mantiveram são nos períodos mais desafiadores.

Minha gratidão à minha família, que esteve ao meu lado em cada etapa. À minha mãe, que me ensinou força diante das adversidades; ao meu pai, que mostrou que a vida segue e sempre nos prepara para novos desafios. Pelos olhos deles, aprendi a enfrentar e viver o mundo. À minha madrinha Simone, meu tio Luiz e meu primo Pablo, que me inspiraram a enxergar o tamanho das possibilidades e do meu potencial.

À minha noiva, Marina, dedico um agradecimento especial. Sua paciência, compreensão e amor foram essenciais para tornar tudo mais leve e me fortalecer nos momentos de dúvida e cansaço.

À minha primeira professora, Conceição, e seu marido, que acreditaram em mim quando eu ainda não sabia o quanto seria difícil sair da periferia e buscar meu desenvolvimento como pessoa, profissional e acadêmico.

Agradeço à UFMG, por proporcionar um ambiente de excelência acadêmica, recursos e oportunidades fundamentais para este trabalho. Cada professor, colega e funcionário contribuiu para meu crescimento e deixou lembranças marcantes nos corredores do DCC.

Minha profunda gratidão a Gabriel Oliveira e Mariana Oliveira, cujas críticas, sugestões e apoio foram indispensáveis durante o mestrado. Sua colaboração moldou este trabalho e me ajudou a alcançar meus objetivos.

Por fim, agradeço à minha orientadora, Mirella Moro. Sua sabedoria, paciência e amizade foram pilares para o desenvolvimento deste projeto. Cada conselho e reunião foram fontes de aprendizado e inspiração para buscar a excelência.

A todos que, direta ou indiretamente, contribuíram para esta realização, meu muito obrigado. Este trabalho é fruto de um esforço coletivo e do apoio de pessoas queridas. Sem vocês, nada disso seria possível.

*“‘Hoje Cedo’ não era um hit, era um pedido de socorro.”*  
(Emicida)

# Resumo

Esta dissertação investiga o uso de técnicas de Ciência de Dados na análise de letras de músicas de gêneros periféricos brasileiros. Como forma de expressão cultural, a música possui uma capacidade singular de capturar e transmitir as complexas emoções e realidades de um povo. Nesse contexto, esta dissertação analisa letras de músicas dos gêneros Funk, Rap e Samba através da Ciência de Dados para identificar sentimentos e padrões temáticos presentes nessas composições. A contribuição técnica também é ampliada com dois novos conjuntos de dados coletados a partir de fontes on-line e posteriormente tratados para fácil e eficaz utilização. Ainda, este estudo oferece novas perspectivas sobre a expressão cultural das periferias brasileiras, evidenciando como a tecnologia pode ser aplicada para compreender e interpretar dados textuais complexos. A dissertação conclui que a interseção entre música e tecnologia não apenas enriquece o campo da Ciência da Computação, mas também destaca o potencial de técnicas computacionais ampliando horizontes para investigações culturais e sociais.

**Palavras-chave:** música periférica; resiliência cultural; processamento de linguagem natural; análise de letras musicais.

# Abstract

This dissertation investigates the use of Data Science techniques for analyzing from Brazilian peripheral genres lyrics. As a form of cultural expression, music has a unique ability to capture and convey the complex emotions and realities of a people. In this context, this dissertation analyzes song lyrics from Funk, Rap and Samba through Data Science to identify emotion and thematic patterns present in such compositions. The technical contribution is also expanded with two new datasets collected from online sources and subsequently processed for easy and effective use. Furthermore, this study offers new perspectives on the cultural expression of Brazilian peripheral regions, then showing how technology can be applied to understand and interpret complex textual data. The dissertation concludes that the intersection between music and technology not only enriches the field of Computer Science, but also highlights the potential of computational techniques to broaden horizons for cultural and social investigations.

**Keywords:** marginalized music; cultural resilience; natural language processing, analysis of musical lyrics.

# Lista de Figuras

3.1	Emoções mapeadas nos domínios de ativação e valência. . . . .	36
4.1	Fluxo geral da metodologia de pesquisa . . . . .	45
4.2	Fluxo para a construção do Conjunto de Dados . . . . .	46
4.3	Metodologia de treino e aplicação . . . . .	51
5.1	Análise emocional por modelo . . . . .	60
5.2	Variação entre emoções identificadas por BERTimbau e GPT . . . . .	62
5.3	Distribuição da emoções entre os modelos . . . . .	64
5.4	Análise emocional por modelo . . . . .	66
5.5	Distribuição das emoções nas letras de músicas por gênero. . . . .	68
5.6	Tendências emocionais no samba, rap e funk. . . . .	68
5.7	Variação das emoções musicais ao longo das décadas (interpolada). . . . .	69
5.8	Nuvem de Palavras para os Gêneros Samba, Rap e Funk . . . . .	71
A.1	Samba década de 50 . . . . .	89
A.2	Samba década de 60 . . . . .	89
A.3	Samba década de 70 . . . . .	89
A.4	Samba década de 80 . . . . .	89
A.5	Samba década de 90 . . . . .	89
A.6	Samba década de 2000 . . . . .	89
A.7	Samba década de 2010 . . . . .	90
A.8	Samba década de 2020 . . . . .	90
A.9	Rap década de 90 . . . . .	91
A.10	Rap década de 2000 . . . . .	91
A.11	Rap década de 2010 . . . . .	91
A.12	Rap década de 2020 . . . . .	91
A.13	Funk década de 90 . . . . .	92
A.14	Funk década de 2000 . . . . .	92
A.15	Funk década de 2010 . . . . .	92
A.16	Funk década de 2020 . . . . .	92
B.1	Características acústicas médias positivas . . . . .	93
B.2	Característica instrumental . . . . .	93
B.3	Intensidade sonora média do conjunto de dados . . . . .	94

B.4	Ritmo e tonalidade média do conjunto de dados . . . . .	94
C.1	Parte da letra da música A Vida É Desafio . . . . .	95
C.2	Parte da letra da música Vida Loka, Pt. 1 . . . . .	96
C.3	Parte da letra da música BENÇA . . . . .	97
C.4	Parte da letra da música Meu Mundo . . . . .	98
C.5	Parte da letra da música A Vida É Tipo Roda Gigante . . . . .	99
C.6	Parte da letra da música As Rosas Não Falam . . . . .	100
C.7	Parte da letra da música Zé do Carço . . . . .	101
C.8	Parte da letra da música Todo Menino É Um Rei . . . . .	102
C.9	Parte da letra da música Papel de Pão . . . . .	103
C.10	Parte da letra da música 24 Horas Por Dia . . . . .	104

# Lista de Tabelas

3.1	Comparação de trabalhos sobre análise de letras de músicas . . . . .	33
3.2	Comparação de conjuntos de dados existentes. (* para os que incluem músicas brasileiras) . . . . .	38
3.3	Comparação de trabalhos sobre letras de músicas. . . . .	41
4.1	Quantidade de músicas por gênero para aplicação . . . . .	49
4.2	Quantidade de músicas por gênero para treinamento . . . . .	49
4.3	Descrição das colunas do conjunto de dados . . . . .	50
5.1	Comparação das Métricas de desempenho dos modelos . . . . .	59
5.2	Comparação das Métricas de desempenho dos modelos com a integração . . . .	65
5.3	Variação temática ao longo das décadas e respectiva emoção predominante . .	73
5.4	Variação temática ao longo dos quinquênios para o Rap . . . . .	74

# Lista de abreviações e siglas

AUC	Área sob a curva ( <i>Area Under the Curve</i> )
BERT	<i>Bidirectional Encoder Representations for Transformers</i>
BPM	Batidas Por Minuto
GELU	<i>Gaussian Error Linear Unit</i>
GPT	<i>Generative Pre-trained Transformer</i>
IDF	Frequência Inversa do Documento, do inglês <i>Inverse Document Frequency</i>
LDA	Alocação Latente de Dirichlet, do inglês <i>Latent Dirichlet Allocation</i>
LIP	Processamento de Informações de Letras, do inglês <i>Lyrics Information Processing</i>
LSTM	Redes de Memória de Curto Prazo Longo, do inglês <i>Long short-term memory</i>
PLN	Processamento de Linguagem Natural
ROC	Característica de Operação do Receptor, do inglês <i>Receiver Operating Characteristic</i>
TF	Frequência do Termo, do inglês <i>Term Frequency</i>

# Sumário

<b>1</b>	<b>Introdução</b>	<b>15</b>
1.1	Objetivos . . . . .	18
1.2	Organização de Texto . . . . .	19
<b>2</b>	<b>Fundamentos e Conceitos Básicos</b>	<b>20</b>
2.1	Dados e Técnicas . . . . .	20
2.2	Fundamentos Estatísticos . . . . .	22
2.3	Fundamentos de Ciência de Dados e PLN . . . . .	23
2.4	Avaliação de Desempenho do Modelo . . . . .	26
<b>3</b>	<b>Trabalhos Relacionados</b>	<b>28</b>
3.1	Aspectos Culturais Brasileiros . . . . .	30
3.2	Recursos Musicais . . . . .	31
3.2.1	Metadados . . . . .	32
3.2.2	Letras . . . . .	32
3.2.3	Identificação de Emoções em Letras de Músicas . . . . .	34
3.2.4	Conjuntos de Dados . . . . .	37
3.3	Técnicas Computacionais e Música . . . . .	40
3.4	Contribuições desta Dissertação . . . . .	42
<b>4</b>	<b>Metodologia de Pesquisa</b>	<b>44</b>
4.1	Aquisição dos Dados . . . . .	44
4.2	Descrição do Conjunto de Dados . . . . .	49
4.3	Treino e Avaliação do Modelo . . . . .	51
4.3.1	Modelo GPT . . . . .	51
4.3.1.1	Rotulação dos dados de treino e avaliação . . . . .	52
4.3.1.2	Etapa de aplicação e avaliação . . . . .	53
4.3.2	Modelo BERT . . . . .	54
4.4	Exemplos de Identificação de Sentimentos . . . . .	55
4.4.1	Exemplos Musicais de Rap . . . . .	55
4.4.2	Exemplos Musicais de Funk . . . . .	56
4.4.3	Exemplos Musicais de Samba . . . . .	57
<b>5</b>	<b>Resultados</b>	<b>58</b>

5.1	Avaliação dos Modelos . . . . .	59
5.2	Análise de Emocional individual . . . . .	60
5.2.1	Distribuição da Emoções . . . . .	64
5.3	Integração dos Modelos . . . . .	65
5.4	Análise Emocional da Integração dos Modelos . . . . .	66
5.5	Análise Temporal das Emoções . . . . .	67
5.6	Análise Temática das Letras . . . . .	70
5.7	Análise Temporal dos Temas . . . . .	72
<b>6</b>	<b>Conclusão</b>	<b>75</b>
6.1	Resultados da Pesquisa . . . . .	75
6.2	Contribuições em Relação à Literatura Atual . . . . .	76
6.3	Ameaças à Validade e Trabalhos Futuros . . . . .	77
6.4	Contribuições Técnicas . . . . .	78
	<b>Referências</b>	<b>79</b>
	<b>Apêndice A Letras ao Longo do Tempo</b>	<b>89</b>
A.1	Nuvens de Bigramas do Samba (TF-IDF) . . . . .	89
A.2	Nuvens de Bigramas do Rap (TF-IDF) . . . . .	91
A.3	Nuvens de Bigramas do Funk (TF-IDF) . . . . .	92
	<b>Apêndice B Características Acústicas</b>	<b>93</b>
	<b>Apêndice C Exemplos de Musica</b>	<b>95</b>

# Capítulo 1

## Introdução

A música é uma forma de expressão cultural profundamente enraizada na sociedade, desempenhando um papel crucial na articulação de identidade e resistência, especialmente em contextos de marginalização [53]. Nas periferias brasileiras, as letras das músicas refletem as realidades sociais, econômicas e culturais dessas comunidades, funcionando como uma voz para os silenciados [58]. Por exemplo, o Rap tem, ao longo dos anos, disseminado problemas que ocorrem dentro das periferias ou do sistema carcerário brasileiro [28].

Conforme definida por de Sá [65], a *Música Periférica Brasileira* vai além de uma simples referência às regiões de periferia ou à situação socioeconômica. Ela representa uma estética que surge das margens sociais e incorpora elementos de diversos gêneros da música popular brasileira. O diferencial está na sua capacidade de mesclar estilos e se desenvolver de forma independente, tornando-se uma forma de resistência cultural. Mais do que apenas refletir o cotidiano das periferias, a música periférica questiona as hierarquias do mercado musical, promovendo novas formas de identidade e expressão.

Essa dinâmica encontra paralelos importantes na literatura marginal-periférica, conforme analisado por [13]. Assim como a música, a literatura periférica apresenta uma estética que parte de narrativas construídas “de dentro”, oferecendo uma visão autêntica e livre de estereótipos sobre a vida nas favelas brasileiras. O estudo destaca que essa literatura opera dentro do conceito de novo realismo, que se preocupa em representar não apenas as vivências de indivíduos, mas os aspectos sociais que constituem a vida coletiva na periferia. Essa abordagem estabelece um ciclo representativo entre realidade, ficção (ou arte) e o retorno à realidade, promovendo reflexões críticas sobre as condições sociais de exclusão e violência.

A música periférica brasileira compartilha esse movimento, transcendendo os limites do entretenimento para questionar as divisões sociais e os preconceitos enraizados. Assim como a literatura marginal-periférica, a música não apenas reflete o cotidiano das periferias, mas se afirma como um instrumento de crítica e transformação social. Ambas as expressões culturais dão voz às experiências das margens e atuam como formas de resistência, fortalecendo identidades e ampliando as possibilidades de representação para além das narrativas hegemônicas.

Com as ferramentas Web disponíveis, é possível coletar grandes volumes de dados

---

online e organizá-los. Ainda assim, a análise de grandes volumes de letras musicais de forma manual é uma tarefa complexa e não escalável. Com o avanço dos serviços de *streaming* e Ciência de Dados, a geração e a análise de grandes volumes de dados tornaram-se possíveis, permitindo identificar padrões, temas e tendências sociais relevantes [22, 90]. A Ciência de Dados oferece novas ferramentas para explorar as preocupações sociais predominantes nas letras, revelando ainda a popularidade dos elementos musicais presentes no conjunto de dados, enriquecendo os metadados existentes e permitindo várias aplicações na área de mineração de dados musicais [79]. De fato, Ciência de Dados inclui técnicas que permitem gerenciar grandes volumes de dados e analisá-los, frequentemente se associando a metodologias específicas de Aprendizado de Máquina e Processamento de Linguagem Natural (PLN).

A análise automática das letras de músicas periféricas fornece um olhar profundo sobre os problemas sociais enfrentados pelas comunidades marginalizadas. Gêneros como o Funk, Rap e Samba não apenas espelham o cotidiano dessas comunidades, mas também oferecem um espaço para contestação e resistência [28, 69].

Nesse contexto, o campo de LIP (*Lyrics Information Processing*) emerge como uma área na interseção entre música e análise de dados, especialmente com o uso de técnicas de PLN. Essas técnicas têm amplas aplicações, não apenas no campo da música, mas também em áreas como análise de redes sociais, avaliação de produtos e pesquisas literárias. Assim, a capacidade de processar grandes volumes de dados textuais transforma a compreensão de fenômenos culturais e sociais, permitindo identificar tendências e mudanças temáticas muitas vezes imperceptíveis em análises tradicionais [92].

Especificamente, é possível explorar as letras de músicas de forma automatizada, analisando padrões temáticos, emocionais e estilísticos em larga escala, de forma a identificar recorrências linguísticas, explorar a coesão semântica e até inferir o impacto social das composições. Esta dissertação se enquadra nesse contexto ao utilizar métodos computacionais para processar e compreender as letras de músicas periféricas, proporcionando informações que seriam difíceis de alcançar por meio de uma análise manual tradicional.

A aplicação de PLN permite identificar padrões emocionais e temáticos nas letras, resolvendo limitações da análise manual tradicional. Com métodos como identificação de temas recorrentes, modelagem de tópicos e análises de sentimentos, torna-se possível captar automaticamente as dinâmicas culturais e sociais das comunidades [17]. Isso não só enriquece o entendimento das letras como também fornece um panorama amplo sobre as emoções e mensagens transmitidas. No contexto das músicas periféricas, a análise de sentimentos realizada por meio do PLN pode destacar a importância das emoções como elemento de conexão com as experiências de vida nas periferias brasileiras [64].

Assim, a análise das letras de músicas dos gêneros Funk, Rap e Samba busca explorar tanto as temáticas quanto as emoções predominantes presentes nessas composições. A escolha desses gêneros fundamenta-se em sua profunda conexão histórica e cultural com

---

as comunidades periféricas brasileiras, que, ao longo do tempo, utilizaram a música como uma poderosa ferramenta de expressão das suas vivências, resistências e aspirações.

O Samba, nascido no início do século XX, é fruto da confluência das tradições afro-brasileiras com influências urbanas, consolidando-se nas comunidades negras e periféricas do Rio de Janeiro. Conforme aponta Tinhorão [87], o Samba surgiu entre trabalhadores negros e descendentes de escravizados, sendo inicialmente marginalizado pela sociedade e perseguido como uma expressão da cultura das favelas e morros. Apesar das adversidades, o gênero ganhou destaque na cena cultural brasileira e foi gradativamente incorporado à identidade nacional, tornando-se um símbolo da diversidade cultural do país.

No entanto, é possível diferenciar o samba de periferia daquele que passou a ser assimilado pelas elites. O samba da periferia, ou samba de raiz, está mais próximo das tradições originais afro-brasileiras, com forte ênfase na oralidade, na improvisação e nos temas cotidianos das camadas populares, como as dificuldades econômicas, a resistência à opressão e as celebrações coletivas. É o samba das rodas em quintais e das escolas de samba nos morros, carregado de significados culturais e sociais. Já o samba de elite, que emergiu principalmente a partir da década de 1930, foi adaptado para os salões e rádios, tornando-se mais “refinado” aos olhos da classe média e alta. Como explica Severiano [76], esse processo incluiu a estilização dos arranjos e a escolha de temas menos contestadores, aproximando o samba da estética da música popular urbana, o que o tornou mais aceitável pelas elites e pelo mercado.

O Rap é parte integrante da cultura Hip Hop, que chegou ao Brasil nos anos 1980, trazendo influências das comunidades negras dos Estados Unidos, mas rapidamente adaptando-se ao contexto local. De acordo com Severiano [76], o Rap tornou-se uma forma de denúncia das desigualdades e da violência urbana, especialmente nas grandes metrópoles como São Paulo. Com uma linguagem direta e combativa, as letras de Rap refletem as dores, os desafios e as aspirações das periferias brasileiras, funcionando como uma crônica da exclusão social e do racismo estrutural.

O Funk, surgido nas favelas nos anos 1980, tem suas origens no Miami Bass e em outras vertentes da música eletrônica. Assim como o Samba em seus primórdios, o Funk enfrentou preconceitos por sua associação com as comunidades periféricas, sendo frequentemente estigmatizado como “música de favela”. Contudo, conforme ressaltado por Tinhorão [87], a música popular tem, historicamente, desempenhado um papel de resistência cultural, e o Funk não foge à regra. Com batidas marcantes e letras que narram o cotidiano das favelas, o Funk tornou-se um símbolo da criatividade e da resiliência das periferias, conquistando seu espaço no cenário cultural brasileiro.

Esses três gêneros, em diferentes momentos históricos, transcenderam suas origens periféricas para se consolidarem como expressões autênticas das lutas e conquistas das classes populares. Analisar suas letras é também compreender as dinâmicas sociais, políticas e culturais que moldaram e continuam a moldar a vida nas margens da sociedade.

## 1.1 Objetivos

No contexto da riqueza da Música Popular Periférica Brasileira e através de diferentes técnicas computacionais, agrupadas na Ciência de Dados, esta dissertação tem por objetivo responder a duas questões de pesquisa.

**Questão de Pesquisa 1 (QP1).** Como as técnicas de PLN podem ser utilizadas e ajustadas para identificar sentimentos nas letras das músicas periféricas brasileiras?

Essa questão de pesquisa busca explorar o uso de— algoritmos de PLN para analisar as emoções presentes nas letras das músicas provenientes das periferias brasileiras. Para responder a essa questão, a análise baseia-se em técnicas avançadas que incluem, principalmente, a aplicação do modelo BERTimbau, uma ferramenta pré-treinada em português baseada no BERT (*Bidirectional Encoder Representations for Transformers*) de aprendizado profundo.

Além disso, também utilizamos a tecnologia GPT (*Generative Pre-trained Transformer*) para identificar emoções. Para garantir a qualidade dessa análise, esta dissertação introduz um corpus específico, incorporando exemplos reais de letras periféricas e enriquecido com expressões características dessas comunidades. Por fim, os resultados são validados por meio de métricas como precisão, revocação e F1-score, assegurando que as técnicas aplicadas são adequadas ao contexto musical brasileiro.

**Questão de Pesquisa 2 (QP2).** É possível identificar tendências e padrões temáticos nas letras das músicas das periferias brasileiras por meio da Ciência de Dados?

Esta questão examina como técnicas de Ciência de Dados podem ser aplicadas para mapear tendências e padrões temáticos nas letras das músicas periféricas brasileiras. Para tanto, são empregadas abordagens integradas que utilizam tanto métodos quantitativos quanto qualitativos. Inicialmente, métodos como análise de frequência de palavras e TF-IDF (*Term Frequency – Inverse Document Frequency*) são aplicados para identificar os termos mais comuns e relevantes nas letras, diferenciando palavras genéricas de termos que carregam forte significado temático. Essa etapa permite compreender quais palavras ou expressões emergem como marcadores culturais ou narrativos ao longo do tempo.

Além disso, técnicas de análise temporal são utilizadas para mapear mudanças nos temas abordados pelas músicas, permitindo a identificação de tendências históricas. Por exemplo, pode-se observar se determinadas temáticas, como denúncia social ou celebração cultural, ganham maior destaque em períodos específicos. Esta dissertação também utiliza outros recursos, como nuvens de palavras, para ilustrar a presença de diferentes temas refletidos no conjunto de letras por gênero musical.

Em suma, ao combinar a identificação de emoções com modelos de linguagem como BERTimbau e GPT, e a análise de padrões temáticos com ferramentas de Ciência de Dados como TF-IDF e análise de conteúdo, esta pesquisa busca desvelar a profundidade temática e emocional das músicas periféricas brasileiras. Essas abordagens integradas permitem entender como as letras musicais expressam os desafios, as conquistas e as aspirações das comunidades periféricas, reforçando o papel da música como um poderoso instrumento de transformação social e cultural.

## 1.2 Organização de Texto

A seguir, o Capítulo 2 introduz conceitos essenciais de estatística e aprendizado de máquina, mineração de dados, e PLN. Em seguida, o Capítulo 3 explora várias dimensões da música, incluindo a resiliência cultural, diversidade musical como forma de identidade, integração interdisciplinar com políticas públicas, e métodos de aquisição de dados musicais. O Capítulo 4 descreve a metodologia de aquisição dos dados, incluindo detalhes sobre o conjunto de dados. Explica também a metodologia de treino e avaliação dos modelos específicos utilizados (BERT e GPT), proporcionando a base para entender como os dados foram processados.

O Capítulo 5 apresenta os resultados de análise do desempenho dos modelos utilizados, discutindo a combinação de diferentes modelos para melhorar os resultados. Também discute Análise de Sentimentos e Temas, examinando a integração de diferentes modelos de PLN e analisando os temas presentes nas letras. Além disso, observa-se a evolução emocional e temática ao longo das décadas, proporcionando uma visão histórica e cultural abrangente.

Finalmente, o Capítulo 6 resume os principais achados do estudo, reavalia as questões de pesquisa e os resultados alcançados, discute as limitações e possíveis ameaças à validade do estudo, sugere direções para pesquisas futuras, e lista contribuições derivadas do trabalho. Esse capítulo encerra o documento, destacando a relevância e as contribuições do estudo para a área de pesquisa.

# Capítulo 2

## Fundamentos e Conceitos Básicos

Este capítulo apresenta os conceitos necessários para entender os desafios e as soluções abordadas nesta dissertação. A Seção 2.1 apresenta técnicas de processamento para transformar grandes volumes de letras em dados analisáveis. A Seção 2.2 aborda conceitos de estatística (e.g., medidas de centralidade, dispersão, correlação e distribuição de probabilidade) que fornecem a base matemática para a análise dos dados. A Seção 2.3 explora os métodos e modelos usados para análise automática de textos (BERT e GPT), com foco na compreensão das emoções e temas nas letras das músicas periféricas. Por fim, a Seção 2.4 explora formas de avaliar os modelos de PLN para garantir eficiência. Esses fundamentos fornecem a base metodológica para os capítulos posteriores, conectando estatística, Ciências de Dados e PLN com a análise das letras musicais.

### 2.1 Dados e Técnicas

Esta seção aborda os principais tipos de dados que podem ser extraídos das músicas e utilizados para os mais variados fins. Entre essas possibilidades, esta dissertação considera, principalmente, dados **acústicos** e **metadados**.

O estudo de dados acústicos das faixas musicais tem atraído significativa atenção nos campos da musicologia e da ciência da computação. Diversos trabalhos têm sido desenvolvidos para analisar e categorizar faixas musicais com base em vários recursos acústicos [74]. Esses estudos consideram diferentes atributos da música em si para suas análises, conforme os seguintes exemplos.

**Dançabilidade.** A dançabilidade de uma música é um fator crucial para a experiência do ouvinte. A dançabilidade, medida por características como ritmo e sincopação,<sup>1</sup> influ-

---

<sup>1</sup>Sincopação: Recurso musical que consiste em acentuar notas ou sons em tempos fracos de uma compasso, ou seja, em momentos inesperados pelo ouvinte. Isso cria um ritmo que quebra as expectativas e confere uma sensação de movimento e energia à música.

encia não apenas a resposta física do ouvinte, mas também sua percepção de engajamento e prazer na música [29].

**Energia.** A energia musical está relacionada à intensidade e ao vigor da composição. A energia de uma música pode ser determinada por vários fatores, incluindo densidade instrumental, dinâmica e ornamentação [37].

**Volume.** O volume desempenha um papel importante na percepção do ouvinte. O volume percebido influencia a forma como a música é percebida e experimentada, afetando aspectos como a emoção transmitida e a imersão do ouvinte na experiência musical [30].

**Acústica.** A acústica impacta a experiência auditiva. A acústica de uma música reflete a proporção de elementos acústicos versus eletrônicos ou processados digitalmente, influenciando a atmosfera e a textura sonora percebida [83].

**Instrumentalidade.** A presença ou ausência de vocais na música é avaliada pela instrumentalidade. A instrumentalidade de uma música pode afetar sua interpretação e recepção, influenciando aspectos como a capacidade de contar histórias sem palavras e a ênfase na expressão musical pura [75].

**Valência.** A valência reflete a positividade ou negatividade da música. A valência de uma música pode ser percebida através de elementos como harmonia, timbre e letra, influenciando a emoção transmitida e a resposta afetiva do ouvinte. Além disso, alguns estudos examinaram como a valência se relaciona com a memória musical e a satisfação do ouvinte, destacando a importância da valência na formação de associações emocionais e na retenção de informações musicais [73].

**Tempo.** O ritmo da música, expresso em BPM (Batidas por Minuto), é fundamental. O tempo de uma música influencia o movimento e a energia percebida, afetando a interpretação e a expressão emocional através da variação rítmica [97].

**Assinatura de Tempo.** A assinatura de tempo (por exemplo, 4/4, 3/4) impacta a sensação rítmica. A assinatura de tempo influencia a organização e a fluidez rítmica percebida, moldando a estrutura e a sensação de movimento na composição [91].

**Metadados.** Além dos dados acústicos, também é possível considerar os metadados, que consistem em informações descritivas sobre uma música. Esses dados incluem elementos básicos, como título, autor e gênero [51], mas também podem abranger detalhes como localização do artista, popularidade, listas de *tags*, tipo de colaboração musical e mercados disponíveis para lançamento [12, 46, 77].

## 2.2 Fundamentos Estatísticos

A compreensão dos fundamentos estatísticos é essencial para a análise das letras de músicas periféricas brasileiras e para o desenvolvimento de modelos de PLN aplicados a esse contexto. Nesta seção, são apresentadas as medidas de centralidade e dispersão, distribuições de probabilidade e a correlação, conectando-as diretamente com a análise musical e o processo de modelagem. Essas métricas permitem resumir, interpretar e identificar padrões nos dados, oferecendo as ferramentas necessárias para transformar grandes conjuntos de letras em informações valiosas sobre temas, sentimentos e tendências.

As **medidas de centralidade e dispersão** são cruciais para compreender como os termos e emoções estão distribuídos nas letras. Por exemplo, ao analisar a frequência de palavras, a **média** ( $\mu$ ) indica o número médio de ocorrências de uma palavra-chave ao longo de um corpus de letras musicais. A média é calculada conforme a Equação 2.1, onde  $x_i$  representa a quantidade de vezes que a palavra aparece em cada música, e  $N$  é o número total de músicas analisadas.

$$\mu = \frac{1}{N} \sum_{i=1}^N x_i \quad (2.1)$$

A **variância** ( $\sigma^2$ ) e o **desvio padrão** ( $\sigma$ ) medem a dispersão dos dados em torno da média. No contexto musical, essas métricas são úteis para avaliar a variação de emoções entre diferentes letras. A variância e o desvio padrão são definidos pelas Equações 2.2 e 2.3, respectivamente.

$$\sigma^2 = \frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2 \quad (2.2)$$

$$\sigma = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2} \quad (2.3)$$

Além das medidas descritivas, as **distribuições de probabilidade** ajudam a modelar padrões e tendências nas letras musicais. A **distribuição normal**, por exemplo, pode ser utilizada para representar a distribuição das frequências de palavras emocionais, como “amor”, “luta” ou “festa”. A função de densidade dessa distribuição é dada pela Equação 2.4, onde a média ( $\mu$ ) representa a palavra mais frequentemente usada e o desvio padrão ( $\sigma$ ) determina a dispersão dessas frequências.

$$f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(x-\mu)^2}{2\sigma^2}} \quad (2.4)$$

Outra distribuição relevante é a **distribuição binomial**, especialmente útil para modelar a ocorrência de palavras-chave ou expressões emocionais em um conjunto de

letras. Por exemplo, pode-se estimar a probabilidade de uma palavra associada a uma emoção específica aparecer em uma determinada música. A fórmula é apresentada na Equação 2.5, onde  $n$  é o número total de letras analisadas,  $p$  é a probabilidade de ocorrência da palavra e  $k$  é o número de sucessos esperados.

$$P(X = k) = \binom{n}{k} p^k (1 - p)^{n-k} \quad (2.5)$$

Por fim, a **correlação** desempenha um papel essencial na análise de dados musicais, pois permite identificar relações entre variáveis. Por exemplo, a correlação pode ser usada para avaliar se há uma relação entre a frequência de palavras ligadas à resistência social e a época em que as músicas foram compostas, ou para entender como diferentes emoções coexistem nas letras. O coeficiente de correlação, calculado pela Equação 2.6, mede a força e a direção da relação entre duas variáveis, como palavras emocionais  $x_i$  e sentimentos identificados  $y_i$ .

$$r = \frac{\sum (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum (x_i - \bar{x})^2 \sum (y_i - \bar{y})^2}} \quad (2.6)$$

Nesse contexto, valores próximos de  $r = 1$  indicam que a presença de certos termos (por exemplo, palavras associadas à “luta” ou “celebração”) está fortemente relacionada a determinadas categorias temáticas. Já valores próximos de  $r = 0$  sugerem que não há relação linear significativa.

Em síntese, as métricas estatísticas apresentadas fornecem um arcabouço robusto para a análise das letras musicais periféricas. A média e o desvio padrão ajudam a identificar a distribuição e a variação dos temas, enquanto as distribuições de probabilidade permitem modelar a ocorrência de palavras e sentimentos. Por fim, a correlação é fundamental para investigar como variáveis linguísticas e temáticas se relacionam entre si, oferecendo uma visão mais completa e estruturada das músicas analisadas.

## 2.3 Fundamentos de Ciência de Dados e PLN

Existem muitas técnicas de Ciências de Dados que são comumente usadas em etapas de extração, limpeza e análise de dados. Nesta dissertação, as seguintes são usadas direta ou indiretamente, e mencionadas ao longo do texto.

- **Tokenização** divide um texto em unidades menores, como palavras ou frases;

- **TF-IDF** avalia a importância de uma palavra ou um termo  $t$  em um documento  $d$  em relação a uma coleção de documentos, de acordo com as seguintes equações.

$$\text{TF-IDF}(t, d) = \text{TF}(t, d) \times \text{IDF}(t) \quad (2.7)$$

onde

$$\text{TF}(t, d) = \frac{\text{Número de vezes que } t \text{ aparece em } d}{\text{Número total de palavras em } d} \quad (2.8)$$

$$\text{IDF}(t) = \log \frac{\text{Número total de documentos}}{\text{Número de documentos contendo } t} \quad (2.9)$$

- **Stemming e Lematização** reduzem as palavras às suas raízes ou formas base;
- **Análise Sintática (*Parsing*)** estrutura frases para entender a gramática;
- **Modelagem de Tópicos** resulta na descoberta de tópicos em grandes coleções de textos.

Usando algoritmos avançados, PLN permite que máquinas compreendam, interpretem e gerem textos de maneira que simule a compreensão humana. Técnicas de PLN são amplamente aplicadas em diversos domínios, como a análise de sentimentos em redes sociais, tradução automática e reconhecimento de fala. No contexto das letras de músicas, PLN pode ser aplicado para várias finalidades, como, por exemplo:

- **Análise de Sentimentos** identifica vários tipos de sentimentos expressos nas letras;
- **Extração de Temas** para descoberta de tópicos recorrentes e padrões temáticos;
- **Classificação de Gêneros** determina o gênero musical com base nas características textuais; e
- **Detecção de Tendências** resulta na análise de mudanças temporais nos temas e emoções.

A área de PLN tem avançado significativamente, resultando em ferramentas que auxiliam em diversas tarefas. Entre essas ferramentas, destacam-se o GPT e o BERTimbau, que representam inovações importantes em suas respectivas áreas de aplicação. Esta seção resume esses métodos com foco nos seus princípios, arquiteturas e impactos.

Primeiro, o BERT é um modelo baseado em transformadores que processa a linguagem de forma bidirecional, capturando o contexto de uma palavra com base nas palavras que a precedem e a seguem [1]. Ele é treinado em uma vasta quantidade de dados textuais para realizar tarefas de compreensão de linguagem com alta precisão.

Esta dissertação utiliza o modelo *Bertimbau*, uma adaptação do BERT voltada para a língua portuguesa [82]. O *Bertimbau* é um modelo de linguagem que processa texto de forma bidirecional, permitindo a análise contextual das palavras em suas relações

com outras dentro de uma frase. Por meio de aprendizado baseado em grandes corpora de textos, o modelo é capaz de identificar padrões linguísticos e semânticos de maneira sofisticada.

No contexto desta pesquisa, o *Bertimbau* é empregado para analisar emoções expressas nas letras de músicas. Essa aplicação não se limita a reconhecer emoções explícitas, mas também permite captar nuances emocionais que emergem das interações contextuais e estilísticas nas letras, explorando a riqueza semântica do texto musical.

O modelo GPT, desenvolvido pela OpenAI [68], também pertence à família de transformadores e se destaca por seu enfoque na geração de texto. Ele é treinado de maneira não supervisionada em um grande corpus de texto e pode ser ajustado para tarefas específicas. Sua principal característica é a capacidade de compreender e gerar linguagem de maneira contextual, permitindo interações que levam em conta nuances linguísticas e culturais.

Embora o GPT não seja especificamente projetado para a análise emocional de textos, sua arquitetura avançada possibilita identificar padrões contextuais e estilísticos nas letras de músicas. Isso permite analisar emoções e narrativas presentes, contribuindo para interpretações textuais sofisticadas. Essa abordagem combina a compreensão do texto com a capacidade de geração, abrindo espaço para análises críticas e criativas em contextos culturais variados.

A comparação entre diferentes modelos de PLN pode ser útil para determinar a eficácia em tarefas específicas, como a identificação de emoções em músicas periféricas brasileiras. No entanto, é importante destacar que o *Bertimbau* e o GPT não são diretamente comparáveis em termos de desempenho geral, pois possuem arquiteturas similares, mas são otimizados para finalidades distintas.

O *Bertimbau*, baseado no BERT, é especializado em tarefas de entendimento textual, sendo ideal para identificar emoções explícitas e implícitas nas letras, graças ao seu enfoque bidirecional, que analisa o contexto tanto antes quanto depois de uma palavra ou expressão. Por outro lado, o GPT é voltado para geração de texto, mas também pode ser explorado para identificar padrões emocionais, especialmente em sua capacidade de interpretar nuances estilísticas e culturais.

No contexto da análise de músicas periféricas brasileiras, a comparação entre esses modelos pode ser realizada com base em métricas específicas, como precisão, revocação e capacidade de capturar emoções contextuais ou culturais. Enquanto o *Bertimbau* pode oferecer maior precisão na identificação de padrões semânticos, o GPT pode ser mais flexível ao lidar com nuances emocionais indiretas ou criativas presentes nas letras. Essa análise ajuda a compreender não apenas as vantagens e limitações de cada modelo, mas também contribui para o desenvolvimento de abordagens híbridas que integrem suas capacidades, potencializando a análise e interpretação de textos complexos como os das músicas periféricas.

Enquanto ambos os modelos utilizam a arquitetura de transformadores, há diferenças fundamentais em sua abordagem e aplicação, conforme resumido a seguir.

- **Arquitetura:** O BERT é bidirecional, i.e., captura o contexto das palavras considerando tanto para as palavras que vêm antes quanto para as que vêm depois da palavra atual. Em contraste, o GPT é unidirecional, processando o texto de maneira sequencial e considerando apenas as palavras que vêm antes da palavra atual.
- **Objetivo de Treinamento:** O BERT é treinado para entender o texto e responder perguntas, enquanto o GPT é treinado para prever e gerar texto.
- **Aplicações:** O BERT é geralmente mais eficaz em tarefas de compreensão e análise de texto, enquanto o GPT é mais poderoso na geração de texto coerente

Finalmente, esses modelos podem ser utilizados em diferentes aplicações, e duas são de especial interesse nesta dissertação. Primeiro, buscando responder a QP1, a Classificação de Sentimentos pode ser utilizada para identificar sentimentos predominantes no texto (neste caso, em letras de música) como felicidade, tristeza, raiva, entre outros. Exemplo real no contexto musical é análise de letras de Rap para identificar temas de injustiça social. Segundo, buscando responder a QP2, a Extração de Temas visa identificar assuntos recorrentes no texto. No contexto musical, pode-se identificar temas de resistência e empoderamento nas músicas de Funk [31].

## 2.4 Avaliação de Desempenho do Modelo

A avaliação de desempenho do modelo é necessária para verificar sua eficácia. As métricas de avaliação ajudam a medir o sucesso do modelo em associar as duas principais emoções identificadas (alegria, tristeza, raiva, medo, surpresa) às faixas dos gêneros funk, rap e samba, fornecendo uma visão clara de como o modelo se comporta diante de diferentes cenários emocionais e musicais. As métricas mais comuns para essa tarefa são:

- **Acurácia** mede a proporção de predições corretas em relação ao total de predições. No contexto da identificação das emoções predominantes, isso se refere à capacidade do modelo em prever corretamente as duas principais emoções associadas a cada gênero musical.

$$\text{Acurácia} = \frac{TP + TN}{TP + TN + FP + FN} \quad (2.10)$$

onde  $TP$  (*True Positives*) são as emoções corretamente atribuídas,  $TN$  (*True Negatives*) são as predições corretas de ausência de emoção,  $FP$  (*False Positives*) são

as emoções incorretamente atribuídas a uma música, e *FN* (*False Negatives*) são as emoções não identificadas corretamente.

- **Precisão** é a proporção de predições positivas corretas. Para a tarefa de classificação emocional, isso indica a capacidade do modelo de identificar corretamente as emoções predominantes dentro de cada gênero musical.

$$\text{Precisão} = \frac{TP}{TP + FP} \quad (2.11)$$

- **Revocação** é a proporção de emoções identificadas corretamente entre todas as emoções que realmente estão presentes. Essa métrica indica a capacidade do modelo em capturar as emoções predominantes corretamente em diferentes músicas.

$$\text{Revocação} = \frac{TP}{TP + FN} \quad (2.12)$$

- **F1-score** é a média harmônica entre Precisão e Revocação. Ela proporciona um equilíbrio entre as duas métricas, sendo útil quando há a necessidade de considerar tanto a precisão quanto a abrangência da identificação das principais emoções.

$$\text{F1-score} = 2 \times \frac{\text{Precisão} \times \text{Revocação}}{\text{Precisão} + \text{Revocação}} \quad (2.13)$$

- **Matriz de Confusão** apresenta os valores de verdadeiros positivos, verdadeiros negativos, falsos positivos e falsos negativos, fornecendo uma visão detalhada sobre o desempenho do modelo, incluindo as confusões entre as emoções predominantes e os gêneros musicais.

Além dessas métricas, outras técnicas complementam a avaliação do modelo:

- **Validação cruzada** (*k-Fold Cross-Validation*) avalia a generalização do modelo, dividindo os dados em  $k$  partes e avaliando seu desempenho em diferentes subconjuntos de dados. Isso ajuda a garantir que o modelo seja robusto para diferentes amostras de músicas de funk, rap e samba.
- **Curva ROC** (*Receiver Operating Characteristic*) compara a taxa de verdadeiros positivos com a taxa de falsos positivos, permitindo avaliar o desempenho do modelo para diferentes thresholds de decisão das emoções predominantes.
- **AUC** (*Area Under the Curve*) área sob a curva ROC mede a capacidade geral do modelo em classificar as emoções corretamente, oferecendo uma avaliação mais precisa da sua performance.

A seguir, o Capítulo 3 apresenta trabalhos relacionados (vários deles mencionando aspectos cobertos até o momento), e o Capítulo 4 descreve a metodologia e como esses fundamentos se encaixam para responder às duas questões definidas nesta dissertação.

## Capítulo 3

# Trabalhos Relacionados

Esta dissertação foca em três gêneros de música brasileira que tendem ao popular. Mas o que seria música popular? Aqui considera-se a definição do grande especialista Tinhorão [87, p.5]:<sup>1</sup>

Por oposição à música folclórica (de autor desconhecido, transmitida oralmente de geração a geração), a música popular (composta por autores conhecidos e divulgada por meios gráficos, como partituras, ou através da gravação de discos, fitas, filmes ou videotapes) constitui uma criação contemporânea do aparecimento de cidades com um certo grau de diversidade social. No Brasil isso equivale a dizer que a música popular surge nas duas principais cidades coloniais - Salvador e Rio de Janeiro - no correr do século XVIII, quando o ouro das Minas Gerais desloca o eixo econômico do nordeste para o centro-sul

Desde o primeiro samba (carioca) lançado (1916, atingindo sucesso no carnaval de 1917), a música popular brasileira periférica exhibe característica singular de crítica social e resistência: “[...] divulgada a novidade musical através do sucesso do samba *Pelo telefone* (onde a intromissão da classe média ficava clara a partir da letra ironizando a repressão policial à jogatina)” [85, pp.124-125]. Nesta dissertação, explora-se justamente gêneros de música produzida nas periferias brasileiras, sendo necessário formalizar tais gêneros em uma mesma categoria ou movimento musical. Assim, para melhor definir “música popular brasileira periférica”, consideramos o seguinte trecho [19]:

Diversos autores no Brasil denominam o segundo conjunto sob o rótulo de *música popular periférica*, a fim de destacar as tensões que essa nomeação traz à discussão. Pois, tratam-se, como já apontamos, de gêneros que, para além da diversidade sonora, melódica e rítmica, carregam o estigma de “música sem qualidade”, “de mau gosto”, “comercial” ou “sem conteúdo”, ao serem avaliadas pelo crivo da crítica oriunda da MPB; e que trazem marcas de sua origem territorial ligadas às periferias e/ou interior do país.

---

<sup>1</sup>Nota: não se deve confundir o termo “música popular” com o gênero musical “Música Popular Brasileira”, ou simplesmente MPB, a qual teve origem na década de 1960 e foi usada como bandeira da cultura contra o golpe militar da mesma década.

---

Gêneros periféricos brasileiros, como Funk, Rap e Samba, não apenas refletem a rica diversidade cultural do país, mas também desempenham um papel crucial na expressão de resistências sociais e na construção de identidades dentro de comunidades marginalizadas. Compreender essas manifestações musicais exige uma investigação das letras, que carregam narrativas de resistência, pertencimento e identidade cultural. Esta dissertação se insere nesse contexto, aplicando técnicas de PLN para analisar as letras dessas músicas.

Existem pesquisas que ilustram como a análise automatizada pode fornecer novas perspectivas sobre as emoções e narrativas expressas nas músicas. Entre os estudos interessantes, Song and Back [80] modelam dinâmicas emocionais em letras de músicas, e Palomeque e de Lucio [63] investigam a relação entre sentimentos nas letras. Trabalhos como os de Ferreira et al. [27] enfatizam a importância de identificar características líricas para a categorização musical, um olhar mais técnico e detalhado sobre as letras.

Ao situar esta dissertação no emergente campo de LIP, conforme discutido por Hernandez-Lorenzo et al. [32], fica evidente como a análise automatizada de letras, apoiada por modelos como BERT e GPT, pode contribuir para a preservação e valorização da música periférica brasileira. LIP foca especificamente nas letras de músicas, que carregam tanto características linguísticas quanto musicais, oferecendo uma perspectiva única na compreensão cultural e social dessas composições.

Pesquisas sobre emoções, humor e a identificação de emoções em letras de músicas também desempenham um papel fundamental em LIP. Por exemplo, Naseri et al. [55] estudaram a associação entre letras de músicas e estados emocionais através de modelos de linguagem baseados em transformadores, mostrando como as letras podem prever estados de humor de forma altamente precisa. Ogino e Yamashita [57] desenvolveram um sistema de recuperação de informações musicais baseado em emoções expressas nas letras, destacando a importância de palavras-chave na transmissão de sentimentos. Além disso, Huang e Yao [34] exploraram a composição algorítmica de músicas populares baseada na recuperação de emoções das letras, demonstrando como essas técnicas podem ser aplicadas na criação de novas composições.

Este capítulo explora aspectos que sustentam a dissertação. A Seção 3.1 aborda a diversidade musical e a resiliência cultural na música brasileira. Na Seção 3.2, são discutidos os dados acústicos, metadados e letras musicais, bem como técnicas de identificação de emoções em letras e conjuntos de dados, essenciais para as análises com PLN. A Seção 3.3 detalha os modelos utilizados para identificar padrões emocionais nas letras, como BERT e GPT, que são centrais à metodologia da dissertação. Por fim, a Seção 3.4 conecta os trabalhos prévios à pesquisa, destacando as inovações trazidas pela análise de letras de músicas periféricas com PLN. Essas seções, juntas, estabelecem a relevância cultural e técnica da pesquisa.

## 3.1 Aspectos Culturais Brasileiros

A resiliência cultural é uma característica essencial das comunidades periféricas, onde a música serve como um veículo vital de expressão e preservação cultural. Herschmann e Fernandes [33] exploram a importância dos espaços urbanos no Rio de Janeiro para a perpetuação da música negra, destacando como a análise das letras dessas músicas pode revelar narrativas de resistência cultural. Barbio [9] investiga como o hip hop contribui para a construção de identidades sociais entre jovens suburbanos. A pesquisa incluiu a análise manual de letras de Rap, destacando como esses textos são usados pelos artistas para expressar lutas e aspirações sociais. Ao examinar as letras, Barbio identificou temas recorrentes de resistência e identidade cultural, demonstrando como as palavras escolhidas pelos artistas refletem diretamente suas realidades e desafios.

Outro estudo relevante é o de Menezes [48], que analisa a relação entre a vida cotidiana e a arte musical dentro do coletivo Lado B em Fortaleza. As letras de músicas produzidas por esse coletivo foram coletadas manualmente e analisadas para entender como refletem as tensões entre a rotina diária e o desejo de liberdade criativa. Menezes destaca como as letras desempenham um papel central na expressão da resiliência cultural, servindo tanto como um registro da vida nas periferias quanto como uma forma de arte.

Finalmente, Lima [43] também enfatiza a conexão entre composição musical e perspectivas culturais no contexto baiano. Em seu estudo, as letras das músicas foram analisadas manualmente para compreender como as estratégias líricas representam a distância entre culturas e como influenciam a produção de significado na música. A análise detalhada das letras revelou a complexidade das identidades culturais em jogo.

A análise das letras de Rap, como as de Djonga, mencionada por Fernandes et al. [26], demonstra como essas letras não apenas refletem a resistência cultural, mas também desempenham um papel ativo na luta por direitos e reconhecimento da população negra no Brasil. No entanto, a aplicação de técnicas de PLN para a análise dessas letras, como feito nesta dissertação, oferece uma perspectiva adicional ao evidenciar a relevância cultural e social que as letras carregam de forma automática e em grande escala.

Dessa forma, a diversidade musical nas periferias brasileiras reflete a riqueza cultural das comunidades, onde múltiplas influências convergem para criar gêneros únicos. Brasil [15] e Andrade [7] exploram como a música nas periferias transcende o simples entretenimento, atuando como uma forma de educação cognitiva e resistência cultural. Em ambos os estudos, cerca de dezenas de letras das músicas foram coletadas e analisadas manualmente para compreender como diferentes influências culturais se manifestam nas composições musicais.

Doring [23] destaca o Brega Funk como um movimento cultural significativo nas periferias de Recife. A pesquisa envolveu a coleta manual e análise de dezenas de letras

de Brega Funk, revelando como essas músicas incorporam elementos culturais locais e expressam a identidade coletiva das comunidades. A análise das letras mostrou como o gênero reflete as experiências diárias e as aspirações dos moradores, tornando-se uma forma de expressão cultural rica e diversificada.

A aplicação de técnicas de PLN para analisar as letras também é uma alternativa para compreender a diversidade musical e sua relação com a construção de identidades culturais. Ao investigar como a diversidade musical é representada nas plataformas digitais e na produção cultural das periferias, esses estudos contribuem para a construção e afirmação da identidade dessas comunidades. Porém, ainda há espaço para explorar tais técnicas em volumes de música maiores e abrangendo décadas diferentes dos movimentos culturais. Esta dissertação foca nessa oportunidade pouco explorada de pesquisa.

## 3.2 Recursos Musicais

As tecnologias de *streaming* têm transformado profundamente a forma como a música periférica brasileira é distribuída e consumida. Estudos como os de Oliveira et al. [60, 61] mostram como essas plataformas aumentam a visibilidade das músicas, permitindo que artistas independentes das periferias alcancem um público mais amplo. Marchi [45] aborda os desafios financeiros enfrentados por esses artistas na era digital, destacando tanto as oportunidades quanto as dificuldades apresentadas pelo *streaming*.

Além de ampliar a distribuição, a pesquisa atual explora como o *streaming* está redefinindo a percepção cultural das músicas periféricas, posicionando-as como agentes de inclusão social. Trabalhos como os de Agrawal et al. [2] demonstram que o uso de modelos baseados em transformadores, como o XLNet, pode melhorar a recomendação de músicas com base nas emoções das letras, oferecendo uma compreensão mais rica sobre como as músicas se conectam emocionalmente com seus ouvintes. Essa abordagem permite não apenas democratizar o acesso à música, mas também criar novas formas de interação e engajamento cultural através das plataformas digitais.

Nesta seção, são abordados os recursos musicais que sustentam a análise baseada em PLN, com foco em características acústicas, metadados e letras. Esses elementos são aplicados em diferentes contextos, especialmente na relação entre dados acústicos e a expressão emocional. Também foi explorado o papel dos metadados na organização e recuperação de informações musicais, assim como a importância das letras na compreensão das emoções e narrativas culturais expressas nas músicas periféricas brasileiras.

### 3.2.1 Metadados

Os metadados desempenham um papel crucial na organização e recuperação de informações musicais, sendo fundamentais para a eficiência de plataformas de *streaming* e sistemas de recomendação musical. Segundo Rospocher [71], o uso de *embeddings* de palavras pode automatizar a detecção de conteúdo explícito em letras de músicas, uma funcionalidade essencial para garantir o controle parental e adequação de conteúdo para diferentes públicos. Além disso, o estudo de Wang et al. [98], que investiga a transcrição automática de letras e o alinhamento de áudio em músicas multilíngues, evidencia como os metadados podem ser usados para analisar e categorizar músicas em diversos idiomas e contextos culturais, facilitando o acesso a músicas de diferentes regiões e gêneros.

### 3.2.2 Letras

As letras de músicas são elementos fundamentais para a análise emocional e cultural, especialmente em gêneros onde a narrativa e a mensagem têm papéis centrais. Na Tabela 3.1, destacam-se estudos como os de Naseri et al. [55], que utilizam letras para prever estados emocionais, enquanto Song e Beck [81] aplicam modelos de espaço de estado para analisar dinâmicas emocionais ao longo das composições. A aplicação dessas técnicas às letras de músicas periféricas brasileiras nesta dissertação amplia as possibilidades de identificar padrões emocionais e temáticos, revelando com maior profundidade as narrativas presentes nas composições.

Além disso, a dissertação recorre à modelagem de tópicos, conforme discutido por Hernandez-Lorenzo et al. [32], para extrair temas predominantes nas letras, oferecendo uma visão mais profunda das narrativas culturais presentes nas músicas. Trabalhos como os de Davi e Saharia [21] também são relevantes ao aplicarem modelagem de tópicos para classificar emoções em letras, demonstrando a diversidade de sentimentos expressos nas músicas analisadas.

Em outros contextos, as letras de músicas também têm sido exploradas para traduzir e analisar as características líricas em gêneros como o K-pop. Por exemplo, Kim et al. [39] introduziram um novo conjunto de dados para a tradução de letras de K-pop, revelando as particularidades e desafios na tradução de letras que precisam manter sua cantabilidade e significado cultural. De forma similar, Wang et al. [98] desenvolveram o MIR-MLPop, um conjunto de dados multilíngue de músicas pop, que permite a transcrição automática e o alinhamento de letras em vários idiomas, destacando a importância

Tabela 3.1: Comparação de trabalhos sobre análise de letras de músicas

Referência	Qtde Língua	Objetivo	Técnicas Utilizadas
Rojas [70]	18 Português	Analisar tópicos em letras musicais	LLM, BERTopic
Rojas [100]	100 Português	Analisar tópicos em letras de Funk	LLM, BERTopic
Song e Beck [81]	100 Inglês	Modelar a dinâmica emocional em letras de músicas	Modelos de Espaço de Estado, técnicas de séries temporais
Kim et al. [39]	982 Coreano/Inglês	Traduzir letras de K-pop e analisar aspectos culturais	Redes Neurais, Modelagem Neural, Tradução Automática
Keenan-Kroff et al. [38]	1.908 Inglês	Explorar associações entre letras de músicas sexualizadas e <i>sexting</i> em adolescentes	Análise de conteúdo, estudos comportamentais
Baruah et al. [10]	10.000 Hindi	Detectar letras explícitas em músicas indianas	LSTM, PLN
Wang et al. [98]	60.000 Multilíngue	Criar um dataset multilinguístico de músicas pop com letras e áudio alinhados	Extração de letras, alinhamento de áudio, aprendizado multimodal
Hernandez-Lorenzo et al. [32]	100.000 Espanhol	Analisar letras de músicas espanholas contemporâneas através de métodos de Humanidades Digitais	Análise temática e estrutural, métodos de Humanidades Digitais
Betti et al. [11]	377.808 Inglês	Analisar em larga escala o viés de gênero e o sexismo nas letras de músicas	Modelos de linguagem, Análise de viés, PLN
Naseri et al. [55]	1.000.000 Inglês	Explorar a contribuição das letras e da acústica para a compreensão do humor	Modelos colaborativos para a análise de humor

de considerar a diversidade linguística na análise de letras.

Além das análises emocionais e culturais, letras de músicas também têm sido usadas para examinar conteúdos explícitos e seus impactos sociais. Por exemplo, Baruah et al. [10] aplicaram redes neurais como as LSTM (*Long Short-Term Memory*) para detectar letras explícitas em músicas Hindi, uma abordagem que pode ser usada para filtrar conteúdo inadequado em plataformas de *streaming*. Outro exemplo é o trabalho de Keenan-Kroff et al. [38], que analisou a relação entre letras de músicas com conteúdo sexual e comportamentos de *sexting* entre adolescentes, ressaltando o impacto potencial das letras na formação de comportamentos sociais. Zhang et al. [102] fornecem um conjunto de dados com anotações emocionais contínuas de 794 músicas globais, útil para a identificação de emoções em músicas.

Estudos como os de Betti et al. [11] sobre o viés de gênero e sexismo nas letras de músicas em inglês destacam o potencial do PLN para revelar preconceitos enraizados nas narrativas musicais. Esses trabalhos demonstram que as letras podem ser analisadas não apenas como expressão artística, mas também como reflexos das dinâmicas sociais e culturais que as influenciam e são por elas influenciadas.

No contexto de modelagem de tópicos em letras musicais, Rojas et al. [100] apresentam uma abordagem inovadora que combina modelos de linguagem com *BERTopic*

para analisar letras de Funk brasileiro. A metodologia, chamada *LLMusic*, utiliza *prompts zero-shot* e aprendizado não supervisionado para identificar e agrupar temas, revelando tópicos sociais complexos como relações familiares, violência e amor, muitas vezes ignorados por métodos tradicionais como o LDA (*Latent Dirichlet Allocation*). Já em Rojas e Becker [70], é proposto um *framework* que utiliza Modelos de Linguagem de Grande Escala, como o GPT, e a técnica *BERTopic*<sup>2</sup> para análises não supervisionadas de letras musicais.

Dessa forma, a análise de emoções nas letras de músicas tem se beneficiado de abordagens inovadoras que combinam técnicas de PLN. Por exemplo, Du [24] propõe o uso de técnicas de PLN para realizar reconhecimento de temas nas letras, destacando a complexidade da interação entre linguagem, emoção e expressão artística nas composições líricas. Além disso, Lee e Mahmud [41] enfatizam a importância de integrar características das letras e do áudio para a classificação de emoções musicais. Eles identificam características-chave que influenciam a emoção na música, sugerindo que uma abordagem multimodal pode aprimorar a precisão na identificação de emoções. No contexto de músicas em Bengali et al. [50] apresentam um sistema de análise de emoções baseado em versos que utiliza aprendizado de máquina e classificadores de redes neurais para identificar emoções específicas a partir de dados textuais. Essa abordagem destaca a eficácia de técnicas de aprendizado profundo na análise emocional de letras de músicas em diferentes idiomas.

### 3.2.3 Identificação de Emoções em Letras de Músicas

A análise de emoções nas letras de músicas é um campo de pesquisa com terminologia variada, frequentemente sobrepondo termos como “emoções”, “humor”, “identificação de emoções”, “recuperação de emoções” e “dinâmicas emocionais”. Embora essas expressões possam parecer distintas, elas frequentemente se referem a aspectos inter-relacionados do processamento e análise das emoções em músicas, especialmente no contexto de processamento de letras musicais assim como em todo PLN.

As palavras “emoções” e “humor” são frequentemente utilizadas na literatura, mas há nuances importantes. “Emoções” geralmente se referem a estados afetivos específicos, enquanto “humor” pode denotar estados emocionais mais duradouros e menos intensos. A identificação de emoções (“*Emotion Identification*”) e a recuperação de emoções (“*Emotion Retrieval*”) são processos que envolvem a análise de letras e dados acústicos para classificar ou recuperar músicas com base em seu conteúdo emocional. Trabalhos como o

---

<sup>2</sup>Técnica de modelagem de tópicos que emprega *embeddings* e *clustering* para identificar e descrever os temas subjacentes em um conjunto de documentos.

de Ogino e Yamashita [57] demonstram a aplicação de sistemas que utilizam informações líricas para recomendar músicas que correspondem ao estado emocional do ouvinte.

Outro exemplo é o trabalho de Naseri et al. [55], que utiliza modelos avançados de PLN para associar letras de músicas a humores derivados de listas de reprodução do Spotify. Tal estudo destaca a capacidade dos modelos de transformadores de captar associações complexas entre letras e humores, oferecendo uma compreensão refinada sobre como as emoções são comunicadas através das letras. A comparação entre a predição de humores usando letras e características acústicas também revela a importância relativa das letras na determinação do humor, variando de acordo com o tipo de emoção.

A dinâmica emocional (“*Emotion Dynamics*”) refere-se à variação e evolução das emoções ao longo de uma música. Song e Beck [80] abordam esse conceito modelando as emoções em letras de músicas como uma série temporal, permitindo a análise de como as emoções mudam à medida que a música progride. Essa abordagem oferece uma visão detalhada e contínua das emoções dentro de uma música, ao contrário da classificação tradicional que normalmente atribui uma única etiqueta emocional para toda a canção.

A tarefa de reconhecimento de emoções musicais vai além das aplicações tradicionais de recuperação de informações musicais, destacando as funções sociais e psicológicas presentes nas gravações [94]. Um dos modelos amplamente utilizados para mapear o espectro emocional é o modelo VAD, que analisa as emoções em três dimensões principais: valência, ativação e dominância. A valência mede o grau de positividade ou negatividade de uma emoção, variando de estados desagradáveis, como tristeza ou raiva, a estados agradáveis, como alegria ou satisfação. A ativação, por sua vez, representa o nível de energia ou excitação da emoção, indo de estados calmos e relaxados a intensos e energéticos. Já a dominância reflete o grau de controle ou influência percebida em uma emoção, diferenciando estados mais passivos daqueles mais assertivos e dominantes.

De acordo com Posner et al. [67], a análise dos valores de valência e ativação permite mapear as emoções em um espaço bidimensional, facilitando a representação de estados emocionais expressos. Além disso, como apontado por Ogihara e Kim [56], essas dimensões podem ser associadas a rótulos emocionais qualitativos, como felicidade, raiva ou satisfação, proporcionando uma abordagem complementar que une representações contínuas e categóricas. Essa metodologia, ilustrada na Figura 3.1, amplia as possibilidades de análise das emoções em músicas e facilita a interpretação das expressões emocionais presentes, especialmente no contexto cultural e psicológico do reconhecimento de emoções musicais.

A combinação de dados acústicos e líricos para a análise de emoções é uma tendência crescente no campo. Delbouys et al. [20] demonstram o uso de redes neurais profundas para detectar o humor com base em ambas as modalidades. A pesquisa de Xiong et al. [99] propõe um método multimodal para a classificação automática do humor musical, explorando a relevância entre áudio e letras para capturar as características intrínsecas

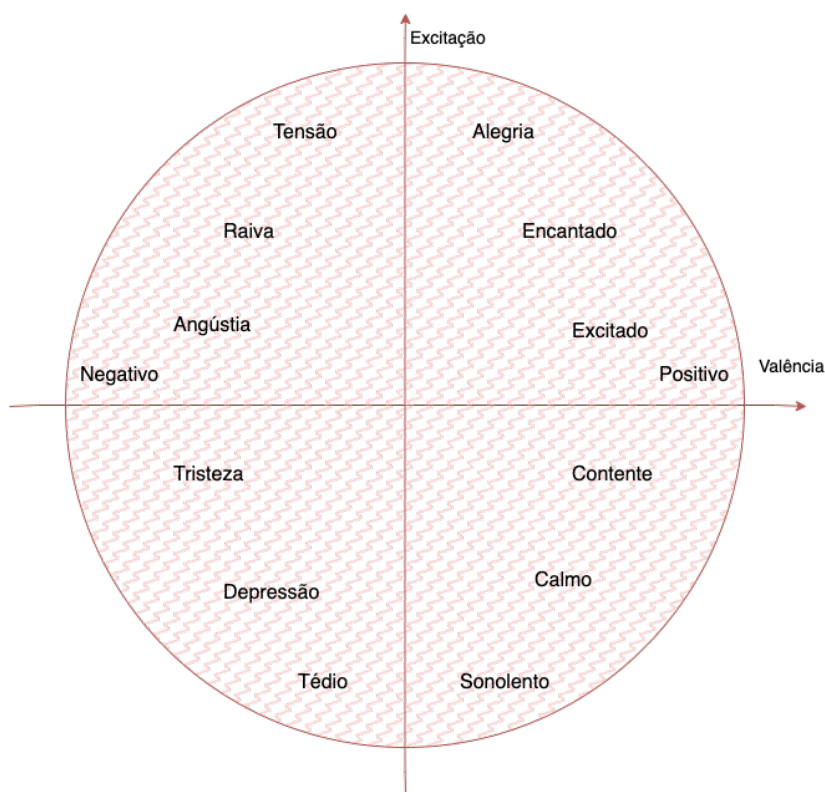


Figura 3.1: Emoções mapeadas nos domínios de ativação e valência.

de um humor específico.

Embora as terminologias variem, os estudos que utilizam termos como “emoções”, “humor”, “identificação de emoções”, “recuperação de emoções” e “dinâmicas emocionais” compartilham o objetivo comum de compreender e modelar como a música afeta o estado emocional dos ouvintes. A diversidade de termos reflete as diferentes ênfases metodológicas e contextuais, mas converge na busca por compreender emoções expressas pela música.

Finalmente, a pesquisa em identificação e recuperação de emoções em músicas evoluiu para integrar técnicas avançadas de aprendizado de máquina e PLN, como mostrado por Huang e Yao [34], que utilizam recuperação de emoções de letras para compor música de forma algorítmica. Essa abordagem não só classifica emoções, mas também usa a correspondência entre emoção e estética musical para criar novas composições, demonstrando a aplicação prática dessas técnicas.

### 3.2.4 Conjuntos de Dados

As características acústicas, como dançabilidade, energia e volume, desempenham um papel importante na maneira como as músicas evocam emoções. Pesquisas como as de Askin e Mauskapf [8] exploram a relação entre essas características e a preferência do público, enquanto Juslin [36] investiga como a energia musical influencia a resposta emocional dos ouvintes. Além disso, estudos como os de Melheiro et al. [44] combinam características acústicas e textuais para prever as emoções que uma música pode evocar.

Dados sobre os artistas que executam a música também podem ser explorados para compreender melhor a recepção das músicas e sua correlação com emoções específicas [34]. As mídias sociais têm incluído dados sobre ouvintes para prever estados emocionais e preferências musicais, como discutido em Naseri et al. [55]. Finalmente, como a maioria dos estudos encontrados abrange dados acústicos e metadados, esta seção segue com mais explicações sobre os mesmos, encerrando com estudos que utilizam letras de música (objeto de estudo desta dissertação).

A aquisição e o uso de conjuntos de dados são essenciais para analisar letras musicais. O *WASABI Dataset* [16], por exemplo, oferece uma coleção de metadados, letras e informações de áudio para mais de dois milhões de músicas. Além disso, conjuntos de dados multilingues, como o MIR-MLPop, destacam a importância de considerar a diversidade linguística na análise de música [98]. A Tabela 3.2 compara diferentes conjuntos de dados existentes, destacando suas características e aplicações. Esta dissertação propõe um novo conjunto de dados focado em músicas brasileiras de gêneros periféricos, que inclui atributos variados como metadados, características acústicas e letras.

A diversidade dos conjuntos de dados musicais disponíveis reflete a variedade de abordagens de pesquisa no campo da análise musical. Cada conjunto de dados oferece um enfoque particular, atendendo a diferentes necessidades e possibilitando análises variadas, conforme resumido a seguir.

**DALI.** É um conjunto de dados com uma grande coleção de áudio sincronizado, letras e notas musicais. Tal conjunto de dados é particularmente útil para análises que requerem a correspondência precisa entre as letras de uma música e seu conteúdo musical [49].

**MusicOSet.** Contém uma ampla gama de dados, como letras, metadados e características acústicas, abrangendo músicas de várias origens e estilos. Sua versatilidade permite comparações entre diferentes gêneros e regiões, oferecendo uma visão global da música e facilitando análises mais diversificadas [79].

Tabela 3.2: Comparação de conjuntos de dados existentes. (\* para os que incluem músicas brasileiras)

<i>Dataset</i>	<i>Ref</i>	<i>Qtde.</i>	<i>Artista</i>	<i>Gênero</i>	<i>Letra</i>	<i>Metadados</i>	<i>Cobertura geográfica</i>
DALI	[49]	5.358	✓		✓	✓	Internacional*
MusicOSet	[79]	20.405	✓	✓	✓	✓	EUA
MUHSIC	[59]	22.635	✓	✓		✓	Internacional*
Song Interpretation	[103]	27.834	✓		✓		Hemisfério Norte
MIR-MLPop	[98]	60.000	✓		✓	✓	Internacional
MuSe	[3]	90.408	✓			✓	Hemisfério Norte
4MuLA	[18]	96.458	✓	✓			EUA, Europa, Am. Latina*
MGD	[62]	126.213	✓	✓		✓	Internacional*
Explicit Lyrics Dataset	[71]	800.000	✓	✓	✓		Internacional*
Hit Song Prediction	[101]	1.000.000	✓				EUA
WASABI Song Corpus	[25]	1.410.000	✓	✓	✓	✓	Internacional*
WASABI Dataset	[16]	2.000.000	✓	✓	✓	✓	Internacional*
Spotify Playlists	[66]	2.036.738	✓				Hemisfério Norte
<b><i>Desta Dissertação</i></b>		<b>54.000</b>	✓	✓	✓	✓	<b>Brasil*</b>

**MUHSIC.** Fornece informações temporais sobre as músicas, permitindo análises da evolução musical ao longo do tempo. Este conjunto é particularmente útil para estudos que investigam tendências musicais e a dinâmica de mudanças no cenário musical, com um enfoque especial em músicas brasileiras [59].

**Song Interpretation Dataset.** Auxilia na interpretação de músicas, fornecendo informações sobre diferentes aspectos musicais e suas interpretações. Este conjunto é ideal para estudos focados na percepção e interpretação musical pelos ouvintes, permitindo análises detalhadas sobre como as músicas são compreendidas e apreciadas [103].

**MIR-MLPop.** Conjunto de dados multilíngue focado em músicas pop, abrangendo faixas em Mandarim, Cantonês e Hokkien Taiwanês. Este conjunto de dados inclui letras de músicas alinhadas no tempo e anotadas manualmente, com etiquetas tanto de caracteres quanto de pronúncia. O MIR-MLPop é o primeiro dataset deste tipo para Cantonês e Hokkien Taiwanês, e foi projetado para facilitar tarefas como transcrição automática de letras e alinhamento de letras com áudio, especialmente em línguas que possuem poucos recursos no treinamento de modelos de linguagem [98].

**MuSe.** Foca nas emoções transmitidas por diferentes músicas, sendo relevante para estudos que examinam a relação entre características musicais e as emoções evocadas nos ouvintes. Este conjunto de dados é particularmente útil para pesquisas em psicologia da música e estudos de emoção musical [3].

**4MuLA.** Caracterizado por sua abrangência geográfica, inclui letras de músicas e características de áudio em diversas línguas e modalidades. Este conjunto é valioso para análises que consideram tanto o conteúdo textual quanto as propriedades acústicas das músicas. No entanto, por não ser específico para um único gênero ou origem, ele oferece uma abordagem mais generalista [18].

**MGD.** Se concentra na classificação de gêneros musicais, fornecendo informações sobre características que distinguem diferentes gêneros musicais e sua popularidade no mercado. Este conjunto de dados é valioso para estudos que investigam a categorização musical e a dinâmica de popularidade entre diferentes estilos [62].

**Explicit Lyrics Dataset.** Criado para a tarefa de detecção automática de conteúdo explícito em letras de músicas. Com mais de 800 mil músicas anotadas, é uma das maiores coleções dedicadas a identificar se uma letra pode ser ofensiva ou inadequada para crianças. Utilizando representações de texto enriquecidas com subpalavras e o classificador *fastText*, o conjunto de dados é uma ferramenta poderosa para melhorar os sistemas de recomendação e filtros de conteúdo em plataformas de *streaming* [71].

**Hit Song Prediction.** É especializado na previsão do sucesso de músicas utilizando características de áudio. Este conjunto de dados é essencial para estudos que buscam identificar padrões e características que predizem o sucesso comercial das músicas, oferecendo informações valiosas sobre os fatores que contribuem para a popularidade das músicas no mercado musical [101].

**WASABI Song Corpus.** Complementa o *WASABI Dataset*, focando na anotação detalhada de letras de músicas. Este corpus contém 1,73 milhões de músicas com letras, das quais 1,41 milhões são únicas, anotadas em diferentes níveis, incluindo estrutura das letras, tópicos, conteúdo explícito, passagens salientes e emoções transmitidas. O corpus foi projetado para ajudar profissionais da música e cientistas a navegarem, categorizarem e segmentarem grandes coleções de letras de maneira inteligente, contribuindo para um entendimento mais profundo das composições musicais [25].

**WASABI Dataset.** Recurso abrangente que oferece metadados culturais, análise de letras e dados de áudio para mais de 2 milhões de músicas comerciais lançadas. Criado com o objetivo de construir um grafo de conhecimento que liga informações sobre artistas, discografias, produtores, datas e análises de letras e áudio, o WASABI é valioso para jornalistas, apresentadores de rádio, professores de música e cientistas interessados em explorar músicas populares publicadas desde 1950 [16].

**Spotify Playlists Dataset.** Fornece uma visão abrangente das preferências musicais dos usuários e dos padrões de agrupamento de músicas em *playlists*. Este conjunto é útil para entender as tendências de consumo musical na plataforma *Spotify*, oferecendo dados sobre como os usuários interagem com a música e formam suas preferências [66].

**Coleção Atual.** Esta dissertação propõe um novo conjunto de dados que se destaca por sua especificidade, focando exclusivamente em músicas brasileiras dos gêneros de periferia. Incluindo uma variedade de atributos, desde metadados básicos até características acústicas, letras e dados do *Spotify*, esta coleção proporciona uma visão detalhada e contextualizada dessas músicas. Ela possibilita análises aprofundadas sobre os aspectos musicais, contextuais e históricos das músicas de protesto brasileiras.

### 3.3 Técnicas Computacionais e Música

Esta seção discute as principais técnicas computacionais aplicadas à análise musical, com ênfase nas abordagens de PLN. A discussão inclui estudos que utilizam modelos avançados, como transformadores, para a detecção de emoções e conteúdo explícito em letras, destacando a evolução dessas abordagens no campo da música.

O uso de técnicas de PLN para a análise musical tem se tornado cada vez mais sofisticado, como evidenciado por diversos estudos na área. A Tabela 3.3 fornece uma visão comparativa dos principais trabalhos acadêmicos que aplicam técnicas de PLN à análise de letras de músicas. Esses estudos abordam desde a identificação de emoções até a análise de temas sociais em músicas de diferentes nacionalidades, demonstrando a diversidade de abordagens metodológicas e o alcance das pesquisas nesse campo.

A análise de letras de músicas em diferentes idiomas, como o estudo de Kim et al. [39] sobre a tradução de letras de K-pop, destaca a importância de ferramentas multilíngues e técnicas de PLN avançadas para a compreensão das letras em contextos globais. Estudos como os de Rospocher [72] demonstram o uso de modelos baseados em transformadores para detectar conteúdo explícito em letras de músicas, evidenciando a capacidade dessas tecnologias de lidar com nuances linguísticas complexas. Outro exemplo relevante é o trabalho de An et al. [5], que aplica algoritmos de Naive Bayes para a classificação de emoções em músicas chinesas, mostrando como diferentes abordagens de PLN podem ser empregadas para compreender a dimensão emocional das letras.

A abordagem utilizada nesta pesquisa também dialoga com estudos como os de Martínez-Plumed et al. [47], que discutem a evolução dos processos de mineração de dados para trajetórias de Ciência de Dados, e com o trabalho de Silva Jr. et al. [35], que

Tabela 3.3: Comparação de trabalhos sobre letras de músicas.

Referência	Emoções	Temas	Temas Sociais	Técnica	Língua
An et al. [5]	✓			Naive Bayes	Chinês
Baruah et al. [10]				Redes Neurais LSTM	Hindi
Delbouys et al. [20]	✓			Redes Neurais Profundas	
Keenan-Kroff et al. [38]	✓			Redes Neurais	Inglês
Betti et al. [11]	✓		✓	PLN	Inglês
Kim et al. [39]				Tradução de Letras	Coreano
Hernandez-Lorenzo et al. [32]		✓	✓	Modelagem de Tópicos	Inglês
Devi e Saharia [21]	✓	✓	✓	Modelagem de Tópicos	Hindi
Martínez-Plumed et al. [47]				Mineração de Dados	
Xiong et al. [99]	✓			Multimodal	
Rospocher et al. [72]				Transformadores	
Naseri et al. [55]	✓		✓	Transformadores	Inglês
Vivou et al. [96]	✓			ChatGPT	
Liao et al. [42]	✓			BERT	Chinês
Ogino e Yamashita [57]	✓			Sistemas Recomendadores	Japonês
Wang et al. [98]				Multilíngue	Várias
Song e Beck [81]	✓			Modelos de espaço gaussiano linear	Inglês
Junior et al. [35]		✓		Análise de Letras	Brasileiro
Vieira et al. [95]		✓	✓	Visualização	
Rojas e Becker [70]		✓	✓	LLM, BERTopic	Brasileiro
Rojas et al. [100]		✓	✓	LLM, BERTopic	Brasileiro
<b>Esta Dissertação</b>	✓	✓	✓	<b>BERTimbau, GPT</b>	<b>Brasileiro</b>

aplica análise de letras para o conhecimento da música brasileira. Estes estudos reforçam a importância de modelos como o BERTimbau e GPT, que são utilizados para captar a complexidade e as nuances das letras musicais.

Estudos como os de Liao et al. [42] utilizam BERT para a classificação emocional de letras chinesas, enquanto Virvou et al. [96] investigam como o ChatGPT pode ser utilizado para interpretar e analisar letras de músicas no contexto da herança cultural.

Os trabalhos de Rojas et al. [70, 100] exploram a análise temática de letras de Funk brasileiro, destacando tópicos como consumo, sedução, violência e a vida nas favelas. Utilizando técnicas avançadas de PLN, como LLM e BERTopic, os estudos associam esses temas a emoções predominantes, como frustração e revolta, especialmente em contextos de violência e desigualdade. Essas análises evidenciam as letras como reflexos das vivências e sentimentos das comunidades periféricas, contribuindo para uma compreensão mais ampla

das dinâmicas sociais e culturais retratadas nesse gênero musical.

Esta dissertação também se alinha com as pesquisas de Silva e Gomes [78], que exploram a classificação de gêneros musicais populares na Amazônia, e de do Carmo et al. [4], que investigam representações textuais para identificação de subgêneros musicais. A análise da rede de gêneros musicais global, como demonstrado por Mondelli et al. [52], oferece um contexto relevante para compreender as influências culturais nas músicas periféricas brasileiras. De fato, aqui se complementa esses estudos ao expandir a análise para um contexto cultural específico, utilizando técnicas de PLN para explorar as emoções e temas presentes nas músicas de gêneros periféricos brasileiros.

A prática de utilizar modelos de linguagem, como o GPT, para o treinamento ou ajuste fino de outros modelos já é uma estratégia amplamente explorada na literatura. Estudos recentes, como o de Anand [6], investigaram os impactos da utilização de textos gerados pelo ChatGPT no pré-treinamento de modelos de linguagem, concluindo que não há efeitos significativos no desempenho em tarefas *downstream* ou em viés de gênero. Koptyra et al. [40] exploraram a anotação de emoções usando o ChatGPT, destacando a eficácia da anotação automática, embora reconhecendo a superioridade da anotação humana para dados de alta qualidade. Além disso, Tan et al. [84] demonstraram o uso de ajuste fino (*fine tuning*) em *chatbots* na área de oftalmologia, utilizando o GPT-4 para avaliar modelos previamente treinados em outras línguas, mostrando a aplicabilidade dessa técnica em domínios especializados.

### 3.4 Contribuições desta Dissertação

Esta dissertação contribui para a análise de letras de músicas, com foco especial no contexto brasileiro. Ao investigar três gêneros periféricos (Funk, Rap e Samba), o estudo amplia o escopo da pesquisa existente bem como destaca a importância cultural e social das músicas criadas nas periferias.

Para fundamentar essa discussão, foi realizada uma revisão abrangente de estudos que analisam como a diversidade musical nas periferias reflete a riqueza cultural dessas comunidades. Esses trabalhos sublinham a importância das letras de músicas como veículos de resistência cultural e preservação de identidades, especialmente em comunidades marginalizadas.

Ao abordar a literatura sobre a análise de emoções e temas nas letras de músicas, esta dissertação também demonstra como as técnicas de PLN corroboram para identificar informações implícitas nessas composições. Embora estudos anteriores discutam a importância de identificar emoções e dinâmicas emocionais nas letras, esta dissertação

avança a discussão ao aplicar essas técnicas a um corpus específico de músicas periféricas brasileiras, revelando nuances particulares à realidade social dessas comunidades.

Outro ponto relevante desta dissertação é a análise automatizada das letras, que possibilita a identificação de temas centrais. Ao empregar modelos de PLN, é possível realizar uma análise mais abrangente das letras, revelando como essas músicas capturam de forma complexa as emoções e realidades brasileiras. Essa abordagem automatizada não apenas amplia a compreensão dos temas, mas também oferece uma perspectiva inovadora sobre a interseção entre tecnologia e expressão cultural. Em suma, esta dissertação se alinha aos estudos existentes ao validar métodos prévios de análise, mas avança ao aplicar esses métodos para investigar como a diversidade cultural se manifesta nas letras de músicas periféricas, integrando perspectivas culturais e sociais à análise computacional.

## Capítulo 4

# Metodologia de Pesquisa

De modo geral, esta dissertação busca responder duas questões de pesquisa que tratam da identificação de sentimentos nas letras de músicas periféricas brasileiras (QP1) e da detecção de padrões temáticos nessas composições (QP2). Para respondê-las, adotamos uma abordagem metodológica integrada que combina técnicas de PLN e Ciência de Dados. É importante notar que as duas questões são complementares: a primeira captura a dimensão emocional expressa nas letras, e a segunda concentra-se na dimensão temática e narrativa desses textos. Então, a metodologia foi concebida para permitir análises paralelas e, posteriormente, uma análise cruzada, com o objetivo de compreender como emoções e temas se inter-relacionam no contexto musical das periferias brasileiras. Essa integração possibilita, por exemplo, verificar se determinados sentimentos estão associados a temas recorrentes, como violência, resistência, identidade cultural ou esperança.

Este capítulo segue em seções que abordam as fases da metodologia desta dissertação, conforme resumido na Figura 4.1. Inicialmente, a Seção 4.1 descreve o processo de coleta e organização das letras de músicas periféricas brasileiras, ou seja, o conjunto objeto de estudo desta dissertação. A seguir, a Seção 4.2 detalha as características e estrutura dos dados obtidos, incluindo a organização das colunas e variáveis. A Seção 4.3 apresenta a metodologia utilizada para treinar os modelos de PLN, como BERT e GPT, adaptados para análise temática e emocional das letras. Por fim, a Seção 4.4 ilustra a aplicação prática dos modelos treinados, demonstrando a análise emocional das letras de diferentes gêneros musicais como Funk, Rap e Samba. Essas etapas fornecem a base metodológica para a análise e compreensão dos dados musicais abordados nesta pesquisa.

### 4.1 Aquisição dos Dados

Os dados utilizados nesta dissertação foram obtidos de fontes distintas, incluindo plataformas de *streaming* e bases de letras musicais, com um foco particular nos gêneros musicais Funk, Rap e Samba. Após a coleta, as letras passaram por pré-processamento



Figura 4.1: Fluxo geral da metodologia de pesquisa

para garantir que estivessem adequadas para a análise por meio de técnicas de PLN. Primeiramente, foi realizada a remoção de caracteres especiais e pontuações excessivas, além de qualquer *emoji* presente nas letras, de modo a eliminar ruídos que poderiam interferir nos resultados. Em seguida, todas as letras foram convertidas para minúsculas, a fim de evitar a distinção indevida entre palavras com diferentes capitalizações. Também foi feita a remoção de *stopwords*, ou seja, palavras comuns de baixo valor informativo (e.g., preposições e conjunções) para focar nas palavras de maior relevância sem comprometer o significado.

Os dados foram divididos em *treino* e *aplicação*. Os dados de treino consistem em um subconjunto utilizado para ajustar e otimizar os modelos de PLN. Esses dados ajudam os modelos a aprenderem padrões linguísticos e emocionais presentes nas letras. Por outro lado, os dados de aplicação são utilizados após o treinamento dos modelos, para testar e avaliar o desempenho dos algoritmos com dados novos, que não foram previamente vistos durante o processo de treino. Ao realizar essa divisão, garante-se que o modelo treinado possa identificar corretamente padrões e emoções em novas letras, o que corrobora para o fortalecimento dos resultados da pesquisa.

A fase de construção do conjunto de dados, ilustrada na Figura 4.2, é composta por seis etapas principais, cada uma projetada visando qualidade, consistência e integridade dos dados, conforme detalhado a seguir.



Figura 4.2: Fluxo para a construção do Conjunto de Dados

**Identificação de *playlists* editoriais por gênero musical.** *Playlists* editoriais são coleções de músicas curadas por especialistas ou editores de plataformas de *streaming*. Elas são criadas para proporcionar a clientes da plataforma uma experiência musical coesa e temática, muitas vezes baseada em gêneros específicos, estados de espírito, ocasiões especiais ou tendências atuais. Diferentemente das *playlists* geradas por algoritmos, as *playlists* editoriais refletem o conhecimento e a sensibilidade de curadores musicais, que selecionam as faixas para criar uma jornada auditiva envolvente e de alta qualidade.

Como fonte de coleta de tais *playlists*, foi escolhida a plataforma *Spotify*. Apesar de ser frequentemente associada a públicos urbanos e de classes sociais com maior acesso à tecnologia e infraestrutura digital, sua ampla base de dados e popularidade no Brasil a tornam uma ferramenta relevante para pesquisas musicais. Em particular, sua capacidade de agregar conteúdos de artistas periféricos e independentes, que ganharam espaço na plataforma ao longo dos anos, contribui para representar a música periférica brasileira em contextos contemporâneos. Ainda, o uso do *Spotify* nesta pesquisa é justificado por sua abrangência e pelo alcance global que possibilita a disseminação e análise de músicas de diferentes períodos e contextos.

Também é necessário definir um recorte temporal para buscar uma perspectiva histórica e ao mesmo tempo contemporânea sobre a evolução da música brasileira, incluindo sua dimensão periférica e de resistência cultural. Então, o processo de identificação das *playlists* editoriais do *Spotify* concentrou-se em músicas lançadas entre 1950 e 2024 através da ferramenta *Spotify Web*. Esse período foi escolhido para abranger o desenvolvimento e a evolução da música brasileira ao longo de mais de sete décadas, permitindo a inclusão de diferentes estilos, tendências e movimentos culturais que marcaram cada época. O procedimento foi realizado manualmente, garantindo uma curadoria cuidadosa e diversificada.

Dessa forma o processo ocorreu em duas partes. Para uso na etapa de aplicação, a

identificação das *playlists* no *Spotify* abrangeu os gêneros Funk, Samba e Rap, aplicando palavras-chave específicas para cada gênero musical a fim de assegurar que as *playlists* refletissem exclusivamente a produção musical brasileira. Exemplos de busca incluem “Funk Brasil”, “Samba de raiz,” e “Rap Nacional”. Além disso, palavras-chave como “clássico”, “antigo” e “*das antigas*” foram empregadas para capturar músicas representativas de décadas passadas; enquanto termos como “Funk 2023”, “Samba atual”, e “Rap 2024” foram usados para identificar lançamentos mais recentes.

Para a cobertura temporal, também se adotou uma estrutura de pesquisa baseada no formato “*gênero Brasil ano*” (e.g. “Funk Brasil 2024”, “Samba Brasil 2020”, e “Rap Brasil 2021”), permitindo a identificação de *playlists* específicas para cada ano. A curadoria incluiu uma filtragem rigorosa para assegurar que todas as *playlists* selecionadas contivessem exclusivamente músicas brasileiras, independentemente da data de criação da *playlist*, levando em consideração o metadado de lançamento das músicas nelas contidas.

Adicionalmente, foram incluídos termos emergentes como “Funk Brasil” e “Funk do momento” que sinalizam subgêneros e movimentos contemporâneos. Essa abordagem permitiu não apenas a identificação de grandes sucessos, mas também a descoberta de novas revelações e tendências, proporcionando uma visão atualizada da música brasileira nesses três gêneros ao longo do período analisado.

Ao total foram coletadas 55 *playlists* para cada gênero musical, feitas por curadores de conteúdo ou equipes de edição. Dessas, “No princípio era o verso”<sup>1</sup> é uma *playlist* editorial que tem como objetivo concentrar Rap histórico brasileiro; “Samba de raiz”<sup>2</sup> é equivalente para o Samba; e “Clássicos do Funk”<sup>3</sup> para o Funk.

Do mesmo modo, para a etapa de treinamento, foram selecionadas *playlists* editoriais de maneira ampla e diversificada, com o objetivo de obter uma base de dados robusta para realizar o *fine tuning*.<sup>4</sup> Foram escolhidos diversos gêneros brasileiros, garantindo uma diversidade cultural e linguística adequada ao treinamento do modelo. No total, foram selecionadas 151 *playlists*, abrangendo uma vasta gama de faixas para cobrir amplamente cada gênero e fornecer uma base sólida para o ajuste do modelo.

Finalmente, é importante ressaltar que o objetivo é coletar um conjunto diverso de *playlists* editoriais com foco na música brasileira; e não coletar todas as *playlists* existentes desse tipo na plataforma. Essa decisão foi influenciada pelas limitações inerentes à curadoria do *Spotify*, já que as *playlists* editoriais refletem critérios de seleção adotados por suas equipes de curadores e podem priorizar músicas populares ou comerciais, afetando a representatividade de expressões culturais periféricas.

<sup>1</sup>No princípio era o verso: <https://open.spotify.com/playlist/37i9dQZF1DWYoltNfXbIx8>

<sup>2</sup>Samba de raiz: <https://open.spotify.com/playlist/37i9dQZF1DWTUHOvJwQIMp>

<sup>3</sup>Clássicos do Funk: <https://open.spotify.com/playlist/37i9dQZF1DX6qtBDSfhRrH>

<sup>4</sup>*Fine tuning* é o processo de ajustar um modelo de linguagem pré-treinado para que ele se especialize em uma tarefa específica; neste caso, a identificação de emoções em músicas brasileiras, conforme o objetivo desta dissertação.

**Extração de títulos e intérpretes das músicas.** Após a seleção das *playlists*, a extração dos títulos das músicas e dos nomes de seus respectivos intérpretes foi realizada automaticamente por meio de um *script*. Esse processo automatizado foi fundamental para garantir uma identificação precisa das músicas de interesse em cada gênero e período investigado. Por “músicas de interesse” entendem-se aquelas relacionadas ao objetivo da pesquisa, ou seja, músicas que contribuam para a identificação e análise de emoções no contexto da música periférica brasileira.

**Extração dos meta-dados de cada música.** Utilizando a API fornecida pelo *Spotify*,<sup>5</sup> foram coletados dados sobre cada faixa musical. Esses metadados incluíram detalhes como título da música, nome do intérprete, álbum de origem, duração da faixa, popularidade e características musicais específicas, como gênero, ritmo e tom. Os dados sobre os intérpretes, em particular, são valiosos para identificar padrões de popularidade e preferências culturais, além de prover maior entendimento sobre as trajetórias artísticas associadas às músicas periféricas.

**Extração da letra de cada música.** Posteriormente, as letras das músicas foram obtidas através da API da *Vagalume*.<sup>6</sup> Essa etapa envolveu uma correspondência exata entre os nomes das faixas obtidas do *Spotify* e as letras disponíveis na plataforma da *Vagalume*, assegurando assim a integridade dos dados textuais associados a cada música analisada.

**Seleção e transformação dos dados do *Spotify*.** Após a coleta, foram aplicadas técnicas de seleção e transformação para refinar o conjunto de dados do *Spotify*. Essa etapa incluiu a remoção de dados redundantes, irrelevantes ou de músicas para as quais não foi possível encontrar informações úteis ao objetivo da pesquisa. A verificação de valores extremos, eliminação de registros duplicados e a validação dos dados foram realizadas para assegurar a consistência e a integridade das informações. Adicionalmente, técnicas de normalização e padronização foram aplicadas, como a uniformização de nomes de artistas e gêneros para evitar variações ortográficas ou semânticas. Essas medidas garantem que os dados sejam consistentes e comparáveis, melhorando sua usabilidade e precisão analítica.

**Pré-processamento das letras musicais.** Após a aquisição das letras das músicas, foi realizado um pré-processamento para preparar o texto para análises subsequentes. Isso envolveu a padronização do formato e codificação do texto, a remoção de caracteres especiais, eventuais ruídos ou elementos indesejados que poderiam interferir na análise semântica. Essas etapas garantiram que as letras estivessem em um formato uniforme

<sup>5</sup>Spotify Api: <https://developer.spotify.com/documentation/web-api>

<sup>6</sup>Vagalume Api: <https://api.vagalume.com.br>

Tabela 4.1: Quantidade de músicas por gênero para aplicação

Gênero	Qtde.
Funk	489
Samba	643
Rap	1.052

Tabela 4.2: Quantidade de músicas por gênero para treinamento

Gênero	Qtde.
Funk	442
Trilha Sonora	1.224
Samba	1.482
Pagode	1.815
Forró	2.702
Sertanejo	3.774
MPB	4.111
Axé	5.759
Rap	6.066
Romântico	7.538
Pop	8.921
Rock	12.679
Gospel/Religioso	17.174

e limpo, prontas para serem exploradas em estudos de análise de sentimentos, temas e outras abordagens de pesquisa.

No total, foram obtidas 2.184 músicas para a etapa de aplicação, com as estatísticas apresentadas na Tabela 4.1. Além disso, foram adquiridas mais de 51 mil músicas para a fase de treinamento, conforme mostrado na Tabela 4.2. Os gêneros incluídos nesse conjunto são Axé, Forró, Funk, Gospel/Religioso, MPB, Pagode, Pop, Rap, Rock, Romântico, Samba, Sertanejo e Trilha Sonora. Essas músicas foram utilizadas para treinar o modelo *BERTimbau* e avaliar ambos os modelos. Ao término do processo, os dados foram salvos no formato *CSV* e estão disponíveis no Zenodo [88].<sup>7</sup>

## 4.2 Descrição do Conjunto de Dados

A Tabela 4.3 apresenta as principais colunas que compõem o conjunto de dados. Cada coluna descreve aspectos específicos das músicas e seus contextos associados, incluindo identificadores, intérpretes, títulos de faixas e álbuns, duração da música em milissegundos, além de medidas como popularidade, dançabilidade, energia, tonalidade e intensidade sonora. As características musicais como modo musical, intensidade vocal, acústica e instrumentalidade são importantes para entender a estrutura e o estilo das composições. Ainda, essa descrição é complementada com a visualização de suas médias no Apêndice B.

<sup>7</sup>Séries Temporais de Músicas Brasileiras: <https://doi.org/10.5281/zenodo.12733931>

Tabela 4.3: Descrição das colunas do conjunto de dados

Coluna	Descrição
Acústica	Grau de presença de elementos acústicos na música.
Dançabilidade	Quão adequada a música é para dançar, baseado em características musicais.
Década	Década de lançamento da música.
Duração (ms)	Duração da música em milissegundos.
Energia	Representa a intensidade e atividade percebida da música.
Frequência de Palavras	Frequência das palavras usadas nas letras da música.
Gênero	Gênero musical.
ID do <i>Spotify</i>	Identificador único para cada música na plataforma <i>Spotify</i> .
IDs de Artistas	Identificadores exclusivos dos artistas relacionados à música.
Intensidade Sonora	Volume percebido da música.
Intensidade Vocal	Grau de presença de palavras faladas na música.
Instrumental	Grau de presença de elementos instrumentais na música.
Letra	Conteúdo das letras da música.
Modo Musical	Se a música está em modo maior ou menor.
Nome da Música	Título da música.
Nome do Álbum	Título do álbum ao qual a música pertence.
Nome do(s) Artista(s)	Lista dos artistas associados à música.
Popularidade	Medida de popularidade da música determinada pelo algoritmo do <i>Spotify</i> .
Ritmo	Andamento da música em batidas por minuto.
Tonalidade	Tonalidade da música.
Valência	Medida que indica a positividade da música.
Vivacidade	Presença de elementos ao vivo na gravação da música.

Além disso, o conteúdo lírico das músicas foi analisado utilizando a técnica de TF-IDF, que avalia a relevância de palavras específicas dentro de um conjunto de documentos, neste caso, as letras das músicas. Esse processo forneceu uma perspectiva quantitativa sobre os temas e sentimentos abordados nas letras. Cada entrada também foi categorizada por gênero musical e década de lançamento, contextualizando as músicas dentro de movimentos artísticos e períodos históricos específicos. Essa categorização foi baseada nos metadados coletados através da API do *Spotify*, complementada pela análise das letras para validar associações culturais ou estilísticas específicas.

Esse conjunto de dados detalhado, composto por frequências de palavras, valores de valência, gêneros musicais e períodos históricos, possibilitou uma exploração aprofundada das características musicais. Ele também facilitou estudos comparativos e analíticos, permitindo estudar a evolução da música popular brasileira e suas implicações culturais, especialmente no contexto da música periférica.

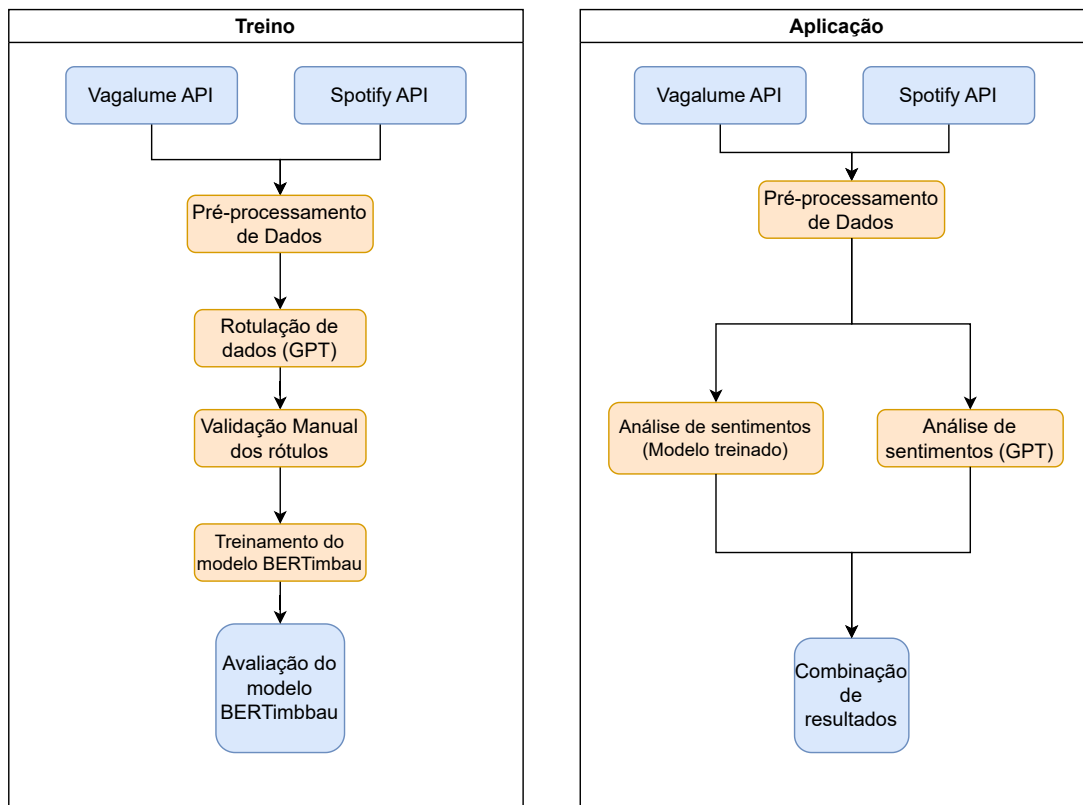


Figura 4.3: Metodologia de treino e aplicação

## 4.3 Treino e Avaliação do Modelo

Esta seção apresenta os procedimentos para treino e avaliação da API GPT (Seção 4.3.1) e do modelo BERT (Seção 4.3.2).

### 4.3.1 Modelo GPT

Nesta dissertação, o modelo GPT é empregado tanto para a rotulação dos dados de treino e avaliação quanto para a análise e aplicação. Reconhecido por sua capacidade de compreender e gerar linguagem natural, o GPT é integrado à API da OpenAI, possibilitando uma análise robusta de sentimentos e temas em letras de músicas periféricas brasileiras. A implementação descrita abrange desde a configuração inicial até a avaliação de desempenho, com destaque para a escalabilidade e a precisão proporcionadas pela abordagem.

### 4.3.1.1 Rotulação dos dados de treino e avaliação

Após a coleta dos dados (Seção 4.2), as músicas são rotuladas com porcentagens que representam as emoções presentes nas letras. A Figura 4.3 ilustra os processos de treino e aplicação, onde as letras das músicas, dados acústicos e metadados são submetidos à API GPT do OpenAI de forma integrada e estruturada. Usou-se o modelo GPT para o *prompts zero-shot*,<sup>8</sup> que permitiu que o modelo identificasse as nuances emocionais das letras com base no conteúdo textual e metadados, combinando diferentes tipos de informações para uma análise mais abrangente das emoções. A API GPT do OpenAI<sup>9</sup> recebeu uma consulta para cada música do conjunto de dados. Neste caso, o *prompt* inclui instruções adicionais para enriquecer a classificação emocional e temática:

“Classifique a letra desta música nas seguintes emoções: alegria, tristeza, raiva, medo e surpresa, atribuindo uma porcentagem de intensidade a cada emoção. Além disso, considere os metadados disponíveis da música e justifique cada classificação com base nos temas e nas expressões emocionais presentes na letra.”

Junto do *prompt* foram enviados os metadados em formato JSON estruturados de forma a simplificar a distribuição de informações à API, como pode ser visto no exemplo.

Listing 4.1: Exemplo de enviado para a API GPT

```
{
  'ID do Spotify': 'spotify:track:id',
  'IDs dos Artistas': ['id'],
  'Nome do Album': '(exemplo)',
  'Data de Lançamento': '2017-03-03',
  'Duracao(ms)': 263400,
  'Dancabilidade': 0.825,
  'Energia': 0.652,
  'Tom': 1,
  'Volume Sonoro': -3.183,
  'Modo': 0,
  'Expressividade': 0.0802,
  'Acustica': 0.581,
  'Instrumentalidade': 0,
  'Vivacidade': 0.0931,
  'Valencia': 0.931,
  'Tempo': 95.977,
  'Assinatura de Tempo': 4,
  'Letra': '...',
  'Genero Selecionado': 'Funk',
  'Nome da Faixa': '..',
  'Nomes dos Artistas': ['...']
}
```

<sup>8</sup>Técnica em que um modelo de linguagem é solicitado a realizar uma tarefa sem ter sido previamente treinado especificamente para essa tarefa, fornecendo apenas uma breve instrução ou exemplo no *prompt*.

<sup>9</sup>OpenAI API: <https://openai.com/index/openai-api>

```
    ‘‘Decada’’: ‘‘2010’’,  
}
```

O resultado dessa consulta são as porcentagens das emoções alegria, tristeza, medo, raiva e surpresa, assim como um texto detalhando o motivo pelo qual foi atribuída aquela rotulação. Esse texto é utilizado depois em uma auditoria manual das saídas para validar a precisão das classificações de emoções. Tal processo envolveu a revisão de alguns resultados gerados pelo modelo para confirmar se as porcentagens atribuídas a cada emoção correspondiam adequadamente ao conteúdo emocional das letras de música analisadas, com base na literatura vigente e nas classificações feitas previamente por empresas de *streaming*, como o *Spotify*.

#### 4.3.1.2 Etapa de aplicação e avaliação

Após a definição do processo de rotulação, a etapa de aplicação operacionaliza o uso do modelo para análise das letras. Dessa forma, a análise explicável de sentimentos nas letras de músicas requer a definição de parâmetros específicos. As consultas são formuladas solicitando respostas gerais sobre o conteúdo emocional das letras e as porcentagens de diferentes emoções identificadas. Essa abordagem permite uma compreensão mais estruturada dos temas emocionais abordados nas músicas.

**Processamento e Armazenamento dos Dados** As letras das músicas são processadas pelo modelo GPT usando a API da OpenAI, aplicando a técnica de *prompts zero-shot*. Neste caso, o *prompt* especificado tem como dado somente a letra da música, como o exemplo a seguir.

“Classifique a letra desta música nas seguintes emoções: alegria, tristeza, raiva, medo e surpresa, atribuindo uma porcentagem de intensidade a cada emoção, e justifique cada classificação com base nos temas e expressões emocionais encontrados na letra.”

Esse *prompt* visa extrair informações contextuais e qualitativas, com justificativa para as classificações baseadas em palavras-chave, temas específicos e contextos emocionais da letra. Após, retornam-se as porcentagens emocionais, e as justificativas são então processadas e armazenadas para facilitar análises posteriores. Esse armazenamento possibilita uma extração rica de informações sobre as emoções predominantes e a natureza dos temas.

**Avaliação do Modelo** A avaliação do desempenho do modelo GPT inclui parâmetros como acurácia, precisão, revocação, F1-score e AUC, utilizando exclusivamente letras musicais. Essas avaliações demonstram a capacidade do GPT em identificar e classificar corretamente as emoções presentes nas letras das músicas.

### 4.3.2 Modelo BERT

Após a rotulação inicial realizada pelo modelo GPT (Seção 4.3.1), em um processo de co-anotação, as porcentagens emocionais obtidas são utilizadas como rótulos para treinar o modelo BERTimbau. Este modelo complementa a análise, oferecendo uma abordagem supervisionada para a classificação das emoções nas letras das músicas. O processo de treinamento, conhecido como *fine-tuning*, ajusta os hiperparâmetros do BERTimbau para melhorar sua precisão e especialização na tarefa de classificação emocional.

Durante o *fine-tuning*, as porcentagens emocionais fornecidas previamente pelo GPT são empregadas como rótulos de treinamento, permitindo que o BERTimbau desenvolva maior sensibilidade às nuances emocionais das letras musicais. O formato dos dados enviados ao modelo consiste em pares de entradas e rótulos, onde as entradas correspondem às letras das músicas, e os rótulos representam as intensidades emocionais atribuídas (alegria, tristeza, medo, raiva e surpresa). Esses valores são normalizados em uma escala de 0 a 100%, garantindo consistência na avaliação e no treinamento.

O modelo utilizado é baseado na arquitetura BERT, com o BERTimbau, que foi previamente treinado em textos em português [82], proporcionando um ponto de partida sólido para a tarefa de análise emocional no contexto da música brasileira. É utilizada a função de ativação GELU (*Gaussian Error Linear Unit*)<sup>10</sup> nas camadas ocultas para aprender representações complexas. Além disso, uma probabilidade de *dropout*<sup>11</sup> de 0,1 foi aplicada para evitar sobre-ajuste (*overfitting*), garantindo que o modelo generalize bem para novos dados.

Após o processo de treinamento e ajuste do modelo BERTimbau para a identificação das emoções nas letras das músicas, a avaliação do desempenho é realizada contrapondo a emoção com a maior porcentagem identificada e seu rótulo previamente atribuído. Primeiramente, usa-se a técnica de validação cruzada *10-fold*, que ajuda a

---

<sup>10</sup>GELU é função de ativação que aplica uma transformação probabilística suave aos dados de entrada, combinando características de funções lineares e não lineares, para melhorar o desempenho de redes neurais.

<sup>11</sup>A probabilidade de *dropout* é um parâmetro em redes neurais que determina a fração de unidades a serem desativadas aleatoriamente durante o treinamento, ajudando a prevenir o *overfitting* e a melhorar a generalização do modelo.

garantir a robustez e a generalização do modelo. Neste método, o conjunto de dados é dividido em 10 partes iguais, onde cada parte é usada como conjunto de dados de teste, enquanto as outras partes são usadas como conjunto de treinamento. Esse processo é repetido 10 vezes, alternando a parte de teste em cada iteração, garantindo que o modelo seja avaliado em várias combinações de dados de treinamento e teste. Além disso, são calculadas curvas ROC e AUC, que são métricas amplamente utilizadas para avaliar a capacidade de discriminação de um modelo de classificação. Essas escolhas também são amplamente adotadas na literatura como padrão para garantir uma boa estimativa de desempenho generalizado de modelos preditivos.

A abordagem enfrenta algumas limitações. A precisão na identificação emocional depende da capacidade da *API GPT* em reconhecer corretamente as emoções nas letras, o que, ao incorporar dados acústicos e metadados, pode introduzir viés. Além disso, a diversidade cultural e linguística das músicas brasileiras torna desafiadora a generalização do modelo *BERTimbau* para diferentes gêneros e estilos. No entanto, mesmo com essas restrições, a abordagem apresenta um potencial significativo, podendo ser adaptada de forma eficaz a diversos contextos musicais e culturais.

## 4.4 Exemplos de Identificação de Sentimentos

As técnicas de PLN oferecem possibilidades para a análise de grandes volumes de texto, permitindo identificar temas e sentimentos nas letras de músicas. Esta seção apresenta exemplos de músicas dos gêneros Rap, Funk e Samba, que foram analisadas pelos modelos, buscando ilustrar como cada estilo pode expressar diferentes sentimentos e temas. Para facilitar a leitura, as letras completas dessas músicas estão no Apêndice C.

### 4.4.1 Exemplos Musicais de Rap

O Rap, caracterizado por suas letras densas e complexas, é aqui exemplificado por três músicas. Na música **Vida é um Desafio**, dos Racionais, pode-se observar uma variedade de emoções. A raiva surge em versos que apresentam crítica social, como em “A nossa luta é todo dia / Somos filhos da rua, não da burguesia”, sugerindo insatisfação em relação à desigualdade social. O medo é sugerido em trechos como “A violência está do nosso lado / Cada esquina é um campo minado”, que podem evocar uma sensação

de perigo. A alegria, por sua vez, é apontada em versos como “A força da comunidade é nossa esperança / No sorriso da criança, nossa aliança”, o que poderia representar a esperança encontrada na união comunitária. A tristeza é sugerida nos desafios descritos em “Cada lágrima é uma batalha perdida / Mas não deixamos a guerra da vida”, talvez refletindo resiliência diante das dificuldades.

Na música **Vida Loka Pt. 1**, também dos Racionais, a raiva pode ser notada em “Bandido mau, inimigo migue”, que parece trazer uma carga de frustração em relação aos conflitos nas ruas. O medo é expresso em versos como “Fiquei mó neurose irmão, não sei quem é quem”, que podem indicar insegurança e desconfiança. A tristeza, por sua vez, é evocada na expressão de perda, como em “Pai morreu e a vida ficou sem rumo”, sugerindo a vulnerabilidade emocional que uma perda significativa pode causar.

Na música **Bença**, de Djonga, as letras podem ser interpretadas como uma expressão de indignação em relação a injustiças, como no verso “Viúva daquela cor só serve pra abusada”, que aponta para questões de discriminação racial e de gênero. O medo é indicado em “Medo tá vivo, respeito tá morto”, o que poderia sugerir insegurança e tensão nas ruas. A alegria parece estar presente na celebração da ancestralidade, como em “Ganha mundo, olhar pra trás vai, só não esquece de voltar”, que pode transmitir uma valorização das raízes culturais e da memória coletiva.

#### 4.4.2 Exemplos Musicais de Funk

O Funk, com letras que frequentemente celebram a energia e a vivacidade, também pode ser analisado para identificação de sentimentos variados, conforme exemplificado no exemplo a seguir.

Na música **Meu Mundo**, de WC no Beat, a alegria parece evidente na celebração da vida noturna, como em “A noite é uma criança e a festa não tem fim”, sugerindo um espírito festivo. A raiva pode ser percebida na atitude desafiadora de “Ninguém vai dizer o que eu devo fazer”, expressando possivelmente uma resistência a imposições. A tristeza surge na sensação de vazio, sugerida no verso “Busco prazer, mas no fundo me sinto só”, que pode indicar uma reflexão sobre a busca por felicidade.

Na música **Quando o DJ Mandar** de Dennis com participação de MC Tarapí e Neblina a alegria se manifesta no ritmo animado que celebra a dança e a euforia coletiva, como em “Menina você desce, desce ou desce”, criando uma atmosfera de celebração. Embora a tristeza não seja abordada diretamente, pode ser subentendida na tentativa de “esquecer o resto” ao se concentrar na batida, sugerindo um possível alívio momentâneo de preocupações pessoais.

Na música **A vida é tipo roda gigante**, de MC Andrezinho Shock, diferentes emoções estão presentes. A raiva aparece na indignação com situações difíceis, como em “Humilhar, ferir, mas não vou desistir”, o que sugere determinação diante de obstáculos. O medo aparece no temor de falhar após o sucesso, como em “Quanto maior a altura, mais dolorosa a queda”, o que remete às consequências dos altos e baixos da vida.

### 4.4.3 Exemplos Musicais de Samba

O Samba, reconhecido por suas letras carregadas de emoções e histórias, oferece material para interpretações ricas de sentimentos demonstrados nos três exemplos a seguir.

Na música **As Rosas Não Falam**, de Cartola, há indícios de tristeza e melancolia. A saudade e a ausência do ser amado são sugeridas em “Queixo-me às rosas, mas que bobagem, as rosas não falam”, trazendo à tona a melancolia que permeia a letra. Por outro lado, a alegria também está presente em “Vem do meu coração essa alegria de viver”, sugerindo uma dualidade emocional na obra.

Na música **Zé do Caroco**, interpretada por Seu Jorge, a alegria parece ser capturada na celebração da união comunitária, como em “E toda comunidade canta”. Esse verso sugere orgulho pela liderança e união dentro da comunidade. A tristeza, no entanto, é sugerida nas condições sociais difíceis retratadas em “Favela, lugar de gente sofrida”, que traz à tona a realidade vivida por muitos.

A música **Todo Menino é um Rei**, de Roberto Ribeiro, reflete uma mistura de emoções. A alegria parece evidente em “Todo menino é um rei”, exaltando a inocência e o potencial das crianças, indicando esperança no futuro. Contudo, a tristeza é sugerida na reflexão sobre a perda da inocência, como em “Mas quando a vida lhe cobra o preço”, o que pode remeter aos desafios enfrentados na vida adulta.

# Capítulo 5

## Resultados

Este capítulo apresenta os achados da pesquisa, organizados em seções que analisam os aspectos emocionais e temáticos das letras de músicas periféricas brasileiras a fim de responder às duas questões de pesquisa desta dissertação. A primeira questão (QP1) busca identificar os sentimentos predominantes nas letras das músicas periféricas brasileiras, por meio de técnicas de Processamento de Linguagem Natural e os modelos de linguagem BERTimbau e GPT. A segunda (QP2), por sua vez, investiga os padrões temáticos presentes nessas letras, explorando sua evolução ao longo do tempo e suas variações por gênero musical. Embora essas questões sejam trabalhadas separadamente nas seções subsequentes, elas estão conectadas: os sentimentos expressos nas músicas geralmente emergem em diálogo com os temas abordados, e vice-versa. Assim, os resultados aqui apresentados devem ser compreendidos de forma integrada, contribuindo para uma leitura mais ampla e contextualizada da produção musical das periferias brasileiras.

Este capítulo segue então com a Seção 5.1, na qual discutimos a avaliação de desempenho dos modelos de PLN utilizados, com foco em métricas de precisão e eficácia. Na Seção 5.2, exploramos a análise emocional individual, destacando a distribuição das emoções identificadas nos diferentes gêneros musicais. Na Seção 5.3, integramos os resultados dos modelos, proporcionando uma visão combinada das emoções identificadas pelos modelos. A seguir, na Seção 5.4, realizamos a análise emocional dos modelos integrados, aprofundando a compreensão das emoções capturadas. Na Seção 5.5, conduzimos uma análise temporal das emoções, permitindo observar como elas evoluíram ao longo das décadas. A Seção 5.6 aborda a análise temática das letras, revelando padrões e tendências. Finalmente, na Seção 5.7, realizamos uma análise temporal dos temas, oferecendo uma visão detalhada das transformações temáticas refletidas nas músicas ao longo dos anos.

Tabela 5.1: Comparação das Métricas de desempenho dos modelos

Métrica	BERTimbau	GPT
<b>Acurácia</b>	88%	86%
<b>Precisão</b>	85%	83%
<b>Revocação</b>	89%	87%
<b>F1-score</b>	86,8%	80%
<b>AUC</b>	0,92	0,90

## 5.1 Avaliação dos Modelos

A Tabela 5.1 apresenta o comparativo entre BERTimbau e GPT para as métricas estudadas. O modelo BERTimbau, ajustado para o reconhecimento de emoções em letras de músicas, obteve uma acurácia de 88%, indicando um desempenho geral muito bom na classificação das emoções presentes nas letras. A escolha da acurácia como métrica reflete a necessidade de avaliar o percentual de classificações corretas em relação ao total de previsões realizadas, sendo útil como uma medida geral de desempenho, embora ignore desbalanceamento de classes.

O modelo de emoções utilizado é baseado no modelo dimensional VAD (valência, ativação e dominância), com categorias emocionais específicas como alegria, tristeza, medo, raiva e surpresa, extraídas de frequências relativas em cada dimensão. A precisão, com valor de 85%, refere-se à *macro-precision*, ou seja, a média da proporção de previsões corretas para cada classe emocional, independentemente do desbalanceamento entre as classes. Já a revocação, que atingiu 89%, indica a capacidade do modelo de identificar corretamente instâncias de emoções relevantes para cada classe, também calculada de maneira macro.

O F1-score de 86,8% oferece uma medida equilibrada entre precisão e revocação, sugerindo que o modelo consegue capturar as emoções específicas sem sacrificar a precisão das classificações. Além disso, o AUC (Área Sob a Curva ROC) de 0,92 reflete a habilidade do BERTimbau de distinguir entre as diferentes classes emocionais, apontando para sua robustez e potencial confiabilidade em analisar emoções em gêneros musicais distintos.

Em conjunto, esses resultados indicam que o BERTimbau é aplicável na análise de sentimentos e emoções em letras de músicas. Ele oferece uma base inicial para explorar como as emoções são representadas nos diferentes gêneros musicais, com possibilidade de extensão para estudos culturais e artísticos.

O modelo GPT da OpenAI foi avaliado nas mesmas tarefas com dados exclusivamente compostos por letras musicais. Seus resultados (ainda na Tabela 5.1) indicam que o modelo também apresenta desempenho bom para a análise de letras musicais. No entanto, embora os resultados tenham sido próximos aos do BERTimbau, eles foram ligeiramente




Figura 5.1: Análise emocional por modelo

inferiores, o que pode sugerir uma vantagem do BERTimbau, que é especificamente ajustado para o processamento da língua portuguesa.

## 5.2 Análise de Emocional individual

Esta seção aborda a aplicação de técnicas de PLN para identificar temas e sentimentos nas letras de músicas. O objetivo é destacar como as ferramentas de PLN podem contribuir para a análise das letras, permitindo uma compreensão mais ampla das músicas das periferias brasileiras.

A análise das emoções em letras de músicas é uma tarefa complexa, principalmente devido à subjetividade das composições. Letras frequentemente apresentam metáforas, simbolismos e nuances linguísticas que variam amplamente entre gêneros musicais e artistas. As emoções raramente são explicitamente expressas, sendo comunicadas através de conotações, tons e contextos culturais específicos.

A interpretação emocional de uma letra depende profundamente do contexto em que a música foi criada e do estado emocional do ouvinte. Essa dependência adiciona desafios ao processo de análise, exigindo que o modelo capture nuances emocionais subjacentes, mesmo em meio a ambiguidade linguística, contextos culturais e históricos variados, sutilezas emocionais e multimodalidade.<sup>1</sup> Embora as emoções sejam transmitidas também pela melodia e pelo ritmo, a presente análise foca exclusivamente nas letras [14].

Para enfrentar esses desafios, a análise das emoções nas letras musicais recorre a técnicas de PLN. O estudo de letras de gêneros como Funk, Rap e Samba revela padrões emocionais específicos, identificados pelos modelos BERTimbau e GPT. A Figura 5.1 apresenta a média das emoções detectadas em cada gênero musical por ambos os modelos.

<sup>1</sup>Multimodalidade refere-se à integração de múltiplos tipos de informação, como texto, som e imagem, para uma compreensão mais abrangente de conteúdos complexos.

Os resultados mostram que o modelo BERT identificou uma maior variação na classificação das emoções em comparação ao GPT. A seguir, destacam-se as principais emoções associadas a cada gênero musical.

- Raiva: o gênero Rap apresenta a maior média para a emoção de “raiva”, especialmente no modelo GPT, potencializando devido à presença de crítica social e protesto em suas letras. Isso reflete a natureza do rap brasileiro, que frequentemente aborda temas como desigualdade e injustiça social.
- Alegria: o Samba e o Funk destacam-se com as maiores médias para “alegria”, particularmente no GPT. Esse resultado evidencia a conexão desses gêneros com celebrações e festividades, características que são parte essencial de sua tradição cultural.
- Medo: ambos os modelos mostram que os três gêneros têm médias semelhantes para “medo”. Essa emoção pode estar relacionada às experiências desafiadoras e realidades difíceis enfrentadas pelas comunidades que esses gêneros representam, refletindo um senso comum de vulnerabilidade.
- Tristeza: o gênero Rap também apresenta uma média significativa para “tristeza”, sugerindo uma profundidade emocional nas suas letras que aborda perdas e sofrimentos. O Samba e o Funk, embora menos destacados nessa emoção, ainda refletem momentos de melancolia, possivelmente ligados às histórias de luta e superação. O BERTimbau identificou uma prevalência maior de tristeza nas letras, enquanto o GPT detectou níveis mais baixos dessa emoção. Essa diferença pode ser atribuída às metodologias distintas utilizadas pelos modelos na interpretação das emoções. O BERTimbau baseia-se em padrões estatísticos e grandes conjuntos de dados, enquanto o GPT utiliza uma abordagem mais interativa e contextual, o que pode resultar em uma sensibilidade diferente às nuances emocionais das letras [93].

Para ilustrar essas diferenças, analisamos as letras das músicas **“Papel de Pão”** de Jorge Aragão e **“24 Horas por Dia”** de Ludmilla. **“Papel de Pão”** é uma canção de Samba que retrata de forma poética e melancólica a dor e a tristeza resultantes de um amor perdido. Suas letras transbordam emoções intensas e diretas, exemplificadas por versos como “Eu nem sei dizer o que senti / Quando eu acordei e não lhe vi / Confesso que chorei / Não suportei a dor / É doloroso se perder um grande amor”. Essa composição lírica mergulha nas profundezas da tristeza, transmitindo um sentimento de desolação e melancolia que ressoa com muitos ouvintes. O contexto lírico e a melodia suave do Samba contribuem para criar uma atmosfera emocionalmente carregada, onde a tristeza é manifestada direta.

Por outro lado, a canção **“24 Horas por Dia”** pertence ao gênero Funk e aborda a obsessão de alguém pela cantora. A letra apresenta versos como “Tu não tem nada

pra fazer / E fica nessa agonia / Fala de mim, pensa em mim / Vinte e quatro horas por dia”. Embora não expresse tristeza de maneira direta, a ênfase na obsessão e na intensidade emocional pode ser interpretada como uma expressão de inquietação e desejo, em contraste com a melancolia e a resignação presentes em “Papel de Pão”.

Com base nos dados, para “Papel de Pão”, o GPT detecta cerca de 45% de tristeza, refletindo a melancolia das letras, enquanto BERTimbau identifica em torno de 60%, devido à sua sensibilidade a padrões emocionais diretos. Em contraste, “24 Horas por Dia” apresenta 15% de tristeza segundo o GPT, destacando a obsessão e inquietação nas letras, enquanto o BERTimbau detecta cerca de 35%. Ao comparar os dois modelos de identificação de emoções, observa-se que eles apresentam abordagens distintas na interpretação das letras de músicas. O BERTimbau tende a detectar uma maior presença de tristeza em todos os gêneros, enquanto o GPT apresenta níveis menores dessa emoção, possivelmente devido à sua abordagem mais contextualizada, que capta outras nuances emocionais.

A Figura 5.2 ilustra as distribuições das emoções detectadas pelos modelos BERTimbau e GPT, permitindo observar comportamentos distintos e convergentes entre as duas abordagens. Na categoria raiva, ambas as distribuições mostram uma concentração similar em valores baixos e intermediários, com predominância entre 0,1 e 0,3. Esse comportamento revela uma estabilidade na detecção dessa emoção entre os dois modelos, sugerindo que a raiva, embora presente, se manifesta de forma controlada e sem extremos nos dados analisados. As distribuições indicam que os modelos concordam amplamente nesse aspecto, sem apresentar grandes discrepâncias.




Figura 5.2: Variação entre emoções identificadas por BERTimbau e GPT

Para a emoção medo, as distribuições são concentradas em valores próximos a 0,1. O modelo BERTimbau demonstra uma leve variação, enquanto o GPT mantém uma distribuição mais uniforme e próxima do mínimo. Esse padrão sugere que o medo é identificado de maneira pouco expressiva, o que pode indicar uma baixa intensidade dessa emoção nos dados analisados ou uma dificuldade dos modelos em captar suas nuances.

A emoção “alegria” apresenta as distribuições mais amplas e intensas em comparação com as demais. Tanto o BERTimbau quanto o GPT mostram concentração significativa no intervalo entre 0,2 e 0,6, com BERTimbau exibindo uma leve tendência a valores extremos mais elevados. Esse comportamento destaca a predominância de alegria nos textos analisados, com maior intensidade em relação às outras emoções. A presença dessa emoção de maneira tão ampla é um dado relevante, uma vez que contrasta com as distribuições mais contidas de raiva e medo.

Na categoria tristeza, observa-se uma assimetria marcante, principalmente no modelo BERTimbau, que apresenta uma distribuição estendida e valores que ultrapassam 0,6, sugerindo detecção de casos extremos dessa emoção. Já o modelo GPT revela uma distribuição muito mais baixa e contida, concentrada entre 0,0 e 0,2. Essa discrepância indica que há divergência entre os modelos na detecção de tristeza, com o BERTimbau sendo mais sensível à presença de textos que expressam essa emoção.

Por fim, a emoção surpresa apresenta um comportamento mais controlado, com distribuições moderadas e concentradas entre 0,1 e 0,3 para ambos os modelos. O BERTimbau exibe uma leve concentração em valores mais altos, enquanto o GPT mantém uma distribuição mais uniforme. Esse padrão sugere que a surpresa é detectada de forma pontual, sem grandes variações ou extremos.

Os padrões observados no gráfico indicam que as emoções alegria e tristeza apresentam maior amplitude e variabilidade. A identificação de alegria e tristeza é geralmente mais “fácil” para modelos de linguagem devido à natureza mais explícita e frequente dessas emoções no uso cotidiano da linguagem. Palavras e expressões que representam alegria, como “feliz”, “sorriso” e “amor”, ou tristeza, como “chorar”, “dor” e “solidão”, possuem significados mais diretos e menos ambíguos, facilitando a detecção automática. Em contraste, emoções como medo, raiva e surpresa são frequentemente expressas de maneira mais sutil, figurativa ou contextualmente dependente, tornando sua identificação mais desafiadora para os modelos, que podem ter dificuldade em captar nuances ou duplas interpretações. Além disso, a representação dessas emoções nos textos analisados tende a ser mais equilibrada e contida, resultando em distribuições mais moderadas no gráfico.

Dessa forma, as emoções raiva, medo e surpresa tendem a ser mais concentradas e moderadas. A discrepância entre os modelos, especialmente em relação à tristeza, sugere que BERTimbau possui maior sensibilidade na identificação de intensidades elevadas, enquanto o GPT apresenta uma detecção mais contida e homogênea.

### 5.2.1 Distribuição da Emoções

A Figura 5.3 mostra como cada modelo, GPT e BERT, reconhece diferentes emoções nas letras de músicas. Esta comparação destaca as forças e limitações específicas de cada modelo na detecção de emoções positivas e negativas, conforme resumido a seguir.

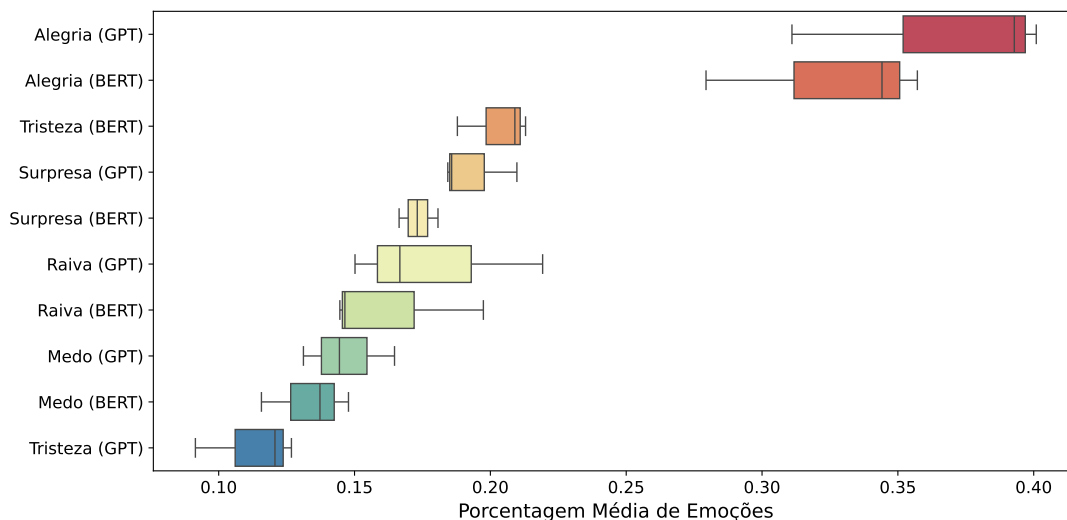


Figura 5.3: Distribuição da emoções entre os modelos

Nessa figura, alegria é a emoção mais frequentemente identificada pelos dois modelos, GPT e BERTimbau, com o GPT apresentando uma média ligeiramente superior em comparação ao BERTimbau. Isso indica que ambos os modelos têm alta sensibilidade para captar expressões relacionadas a sentimentos positivos e de celebração, mas o GPT possui uma leve vantagem nesse aspecto. Em relação às emoções medo e raiva, os modelos apresentam desempenhos similares, com o GPT registrando médias levemente superiores em ambas. Isso sugere que o GPT tem uma sensibilidade marginalmente maior para captar sentimentos associados ao temor e à agressividade, frequentemente presentes em narrativas de conflito e vulnerabilidade. Por outro lado, na identificação de surpresa, o modelo BERTimbau demonstra uma leve vantagem, indicando sua eficiência em detectar elementos inesperados ou reviravoltas expressivas presentes nas letras musicais.

O gráfico evidencia uma diferença significativa na identificação da tristeza entre os modelos GPT e BERTimbau. O BERT apresenta uma média consideravelmente mais alta para essa emoção em comparação ao GPT, sugerindo uma maior capacidade do modelo para detectar conteúdos melancólicos e de sofrimento nas letras musicais. Essa diferença pode indicar que o BERTimbau é mais sensível a palavras e contextos associados à tristeza, como perdas, adversidades e expressões de dor, características comuns em músicas que exploram temas de vulnerabilidade e dificuldades emocionais.

Por outro lado, o GPT registra uma média mais baixa para a tristeza, o que

Tabela 5.2: Comparação das Métricas de desempenho dos modelos com a integração

Métrica	BERTimbau	GPT	Integração
<b>Acurácia</b>	88%	86%	89%
<b>Precisão</b>	85%	83%	86%
<b>Revocação</b>	89%	87%	90%
<b>F1-score</b>	86,8%	80%	87,5%
<b>AUC</b>	0,92	0,90	0,93

sugere uma abordagem menos sensível ou menos explícita desse modelo na captura dessa emoção. Isso pode ocorrer devido à maneira como o GPT interpreta o contexto geral das letras, priorizando outros aspectos mais dominantes, como alegria ou emoções neutras, em detrimento de nuances mais sutis de melancolia.

Portanto, a análise revela que os modelos diferem sutilmente em suas capacidades de detecção emocional, com o GPT se destacando em emoções positivas como alegria e emoções negativas como raiva e medo, enquanto o BERTimbau apresenta melhores resultados para tristeza e surpresa. Essa distinção sugere que ambos os modelos, embora eficientes, possuem abordagens ligeiramente diferentes, o que pode ser explorado de forma complementar para análises emocionais mais robustas e equilibradas.

### 5.3 Integração dos Modelos

A utilização da combinação dos resultados de ambos os modelos, BERT e GPT, na análise das emoções expressas em letras de músicas visa melhorar a compreensão contextual. O BERT, com sua habilidade de identificar emoções de maneira direta e explícita, complementa a sensibilidade do GPT às nuances emocionais e culturais [68]. Ao integrar os resultados, é possível obter uma visão mais equilibrada, que considera tanto os aspectos estatísticos quanto os contextuais e específicos das letras de músicas. Essa combinação mitiga as limitações individuais de cada modelo, aumentando a precisão na identificação das emoções [93]. O BERT é eficaz na detecção de emoções explícitas devido ao seu treinamento em grandes conjuntos de dados, mas pode falhar em capturar sutilezas culturais e contextuais que o GPT consegue identificar [68]. Unindo os resultados, as deficiências de um modelo são compensadas pelas forças do outro, resultando em uma análise mais completa e precisa.

Então, propomos a utilização da Equação 5.1 para combinar os resultados dos dois métodos, ponderando as porcentagens de cada emoção identificada por ambos os modelos. Considerando  $E_B$  como a porcentagem de emoção identificada pelo BERTimbau e  $E_C$  como a porcentagem de emoção identificada pelo GPT, a combinação dos resultados é




Figura 5.4: Análise emocional por modelo

dada pela média ponderada das porcentagens.

$$E_{\text{final}} = \frac{w_B \cdot E_B + w_C \cdot E_C}{w_B + w_C} \quad (5.1)$$

Foi realizado um conjunto de testes com variações de pesos até se alcançar uma configuração que maximizasse o desempenho. Após avaliações das pontuações F1, foi definida a atribuição de um peso maior a  $w_B$ , que representa o BERTimbau, de modo a valorizar seu desempenho superior. Os pesos finais recomendados foram  $w_B = 0,9$  e  $w_C = 0,8$ . A combinação dos resultados dos modelos apresentada na Tabela 5.2, mostrou uma ligeira melhoria no desempenho na identificação das emoções musicais. Essa abordagem híbrida melhorou em um ponto percentual em relação ao BERTimbau.

## 5.4 Análise Emocional da Integração dos Modelos

A análise dos modelos BERTimbau e GPT evidencia que a integração desses sistemas pode potencializar a detecção e a representação emocional em gêneros musicais. Esta seção examina como cada aspecto da fusão dos modelos contribui para uma análise emocional mais completa, equilibrada e consistente.

A Figura 5.4 apresenta os resultados dos modelos integrados para os gêneros musicais Funk, Rap e Samba. Nos gráficos, é possível ver que BERTimbau (linha azul) e GPT (linha vermelha) apresentam diferentes níveis de sensibilidade a certas emoções. Por exemplo, BERTimbau tende a ser mais preciso na detecção de emoções como tristeza e surpresa, enquanto GPT demonstra maior sensibilidade a emoções como alegria e raiva. A linha amarela representa a integração dos modelos, que combina as forças de ambos, resultando em uma análise emocional mais equilibrada e abrangente. Para o gênero Funk, a integração mostra-se eficaz em capturar nuances de alegria e medo. No Rap, a combinação

dos modelos destaca-se na identificação de raiva e surpresa. Já no Samba, a integração melhora a detecção de alegria e tristeza, evidenciando a eficácia do modelo integrado na análise emocional de diferentes gêneros musicais.

A fusão dos modelos tenta proporcionar uma visão mais equilibrada das emoções predominantes, sem enfatizar uma emoção específica como alegria ou raiva para qualquer gênero em particular. Dessa forma, a análise destaca a tentativa de capturar a diversidade emocional presente nas letras, mas sem afirmar com precisão a predominância de emoções específicas para cada gênero musical.

## 5.5 Análise Temporal das Emoções

A música periférica brasileira possui uma história marcada pela resistência e pela expressão cultural das comunidades marginalizadas. Desde o samba nos morros cariocas no início do século XX até o rap e o funk nas periferias urbanas, esses gêneros sempre refletiram as condições sociais e as lutas por justiça. O movimento hip-hop, que emergiu nas décadas de 1980 e 1990, trouxe questões de violência, desigualdade e identidade racial para o centro do debate cultural. Atualmente, gêneros como o funk e o rap continuam como veículos de resistência, conquistando visibilidade internacional e influenciando a cultura *mainstream*, evidenciando a capacidade de reinvenção e adaptação das periferias brasileiras [54, 86]. Esta seção analisa o perfil emocional das letras de músicas periféricas, buscando identificar como as emoções expressas evoluíram ao longo do tempo.

A Figura 5.5 apresenta a distribuição das emoções predominantes nos gêneros Samba, Rap e Funk, de 1950 a 2020. Observa-se que o Samba mantém predominância de alegria ao longo das décadas, embora com flutuações em menor escala. O Rap exibe uma maior presença de raiva, especialmente após a década de 1980, enquanto o Funk apresenta maior equilíbrio entre alegria e raiva, com variações mais intensas em emoções como medo e surpresa nas décadas recentes. Essa análise destaca como as diferentes emoções se manifestam em cada gênero, refletindo seus contextos de criação e recepção.

A Figura 5.6 contextualiza historicamente as mudanças emocionais identificadas na Figura 5.5, analisando como eventos sociopolíticos brasileiros influenciaram os gêneros Samba, Rap e Funk.

O Samba, na década de 1950, era marcado por uma predominância de alegria, como evidenciado na Figura 5.5, refletindo um período de otimismo cultural. Contudo, com a ditadura militar nas décadas de 1960 e 1970, a alegria declinou, enquanto tristeza e raiva aumentaram, em resposta ao contexto de repressão política. Essa transformação destaca a resiliência do Samba como uma ferramenta de resistência cultural.




Figura 5.5: Distribuição das emoções nas letras de músicas por gênero.

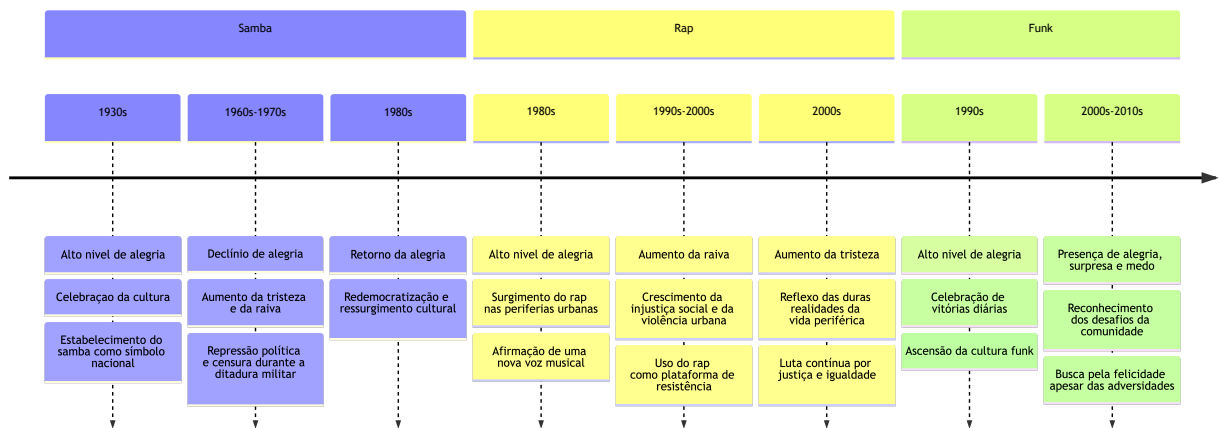


Figura 5.6: Tendências emocionais no samba, rap e funk.

Nos anos 1980, com a redemocratização, observa-se um retorno à alegria nas letras de Samba, alinhado à renovação do cenário político e cultural. Esse período também marca o surgimento do Rap, que, como mostrado na Figura 5.5, apresentou uma ampla gama de emoções, com destaque para a raiva, representando as desigualdades sociais e as lutas das periferias urbanas. Nos anos 1990, o Rap consolidou sua identidade como um gênero de crítica, mantendo a raiva como emoção predominante.




Figura 5.7: Variação das emoções musicais ao longo das décadas (interpolada).

O Funk, que emergiu na mesma década, exibiu uma mistura de emoções. Conforme observado na Figura 5.5, predominavam alegria e raiva, refletindo tanto celebrações quanto desafios da vida nas periferias. Nos anos 2000 e 2010, o Funk intensificou a presença de emoções como medo e surpresa, destacando as dificuldades crescentes nas periferias urbanas, enquanto o Rap continuou a incorporar tristeza e raiva em suas letras, representando os efeitos de uma desigualdade social persistente. Dessa forma, as mudanças emocionais capturadas na Figura 5.5 podem ter sido influenciadas por transformações históricas e sociopolíticas, como evidenciado na Figura 5.6, reforçando a relação intrínseca entre música periférica e os contextos em que é produzida.

A Figura 5.7 apresenta uma visão consolidada da variação das emoções ao longo das décadas nos gêneros Samba, Rap e Funk. Utilizando uma interpolação cúbica, o gráfico suaviza as flutuações nos dados, permitindo identificar tendências gerais nas emoções predominantes. No Samba, a curva de alegria mostra picos nas décadas de 1950 e 1980, alinhados aos momentos de otimismo cultural e redemocratização, respectivamente. Contudo, observa-se um leve aumento de tristeza durante os anos 1960 e 1970, refletindo o impacto do regime militar. Esse padrão destaca como o Samba manteve sua essência alegre, mas incorporou nuances emocionais em resposta a contextos desafiadores.

O Rap, por sua vez, apresenta uma ascensão marcante na raiva a partir dos anos 1990, consolidando essa emoção como central ao gênero. Além disso, a tristeza ganha relevância ao longo dos anos 2000, refletindo a complexidade das questões abordadas em suas letras. A interpolação evidencia a estabilidade dessas emoções, indicando uma forte conexão com a realidade das periferias.

O Funk, comparativamente, exibe uma trajetória mais diversificada. Embora a alegria seja consistente ao longo das décadas, o gráfico revela picos de medo e surpresa nas décadas de 2000 e 2010, evidenciando uma maior variação emocional. Essas emoções refletem os desafios contemporâneos enfrentados nas periferias urbanas e a constante reinvenção do gênero.

A análise da Figura 5.7 complementa as discussões das Figuras 5.5 e 5.6, mostrando

como cada gênero evoluiu emocionalmente em paralelo aos contextos históricos e sociais, consolidando-se como uma ferramenta de resistência e expressão das periferias brasileiras.

## 5.6 Análise Temática das Letras


A análise temática das letras de músicas de Samba, Rap e Funk revela narrativas e valores culturais presentes nas periferias brasileiras. Como pode ser visto na Figura 5.8, é possível identificar as palavras mais frequentes em cada gênero musical, permitindo uma compreensão ampla dos temas predominantes e da forma como eles refletem a vida e as experiências das comunidades marginalizadas.

A formação de nuvens de palavras utilizando a métrica TF-IDF possibilita a identificação de termos mais relevantes em cada gênero musical, revelando temas e narrativas predominantes nas letras. No samba, destacam-se palavras como “saudade”, “paixão” e “malandro”, que evidenciam uma temática recorrente de romantismo e melancolia, misturada à celebração da malandragem como um traço identitário. Esse gênero frequentemente aborda questões relacionadas ao amor, às perdas e à resistência cotidiana, transformando o sofrimento em poesia. A palavra “saudade”, por exemplo, é central no samba, simbolizando uma forte ligação com a memória afetiva e com experiências de ausência ou distanciamento, enquanto “malandro” remete à figura culturalmente emblemática que representa a esperteza e a resistência frente às adversidades do dia a dia.


No caso do funk, termos como “favela”, “bumbum” e “dançar” refletem a celebração da cultura local e a exaltação de elementos como a sensualidade, a festa e a liberdade corporal e social. O destaque de palavras como “favela” indica uma reafirmação identitária das periferias, que transformam suas vivências em um espaço de orgulho e resistência. Já “bumbum” e “dançar” revelam a importância da dança e da música como meios de expressão e valorização da cultura periférica. O funk, portanto, emerge como um gênero que não apenas promove a diversão e a sensualidade, mas também afirma as dinâmicas sociais e culturais das comunidades em um tom positivo e de celebração, colocando em destaque a alegria e a autonomia dos corpos marginalizados.

Por sua vez, o rap apresenta palavras como “favela”, “guerra” e “dinheiro”, o que aponta para uma abordagem mais crítica e politizada. Esses termos refletem as desigualdades sociais, as tensões urbanas e a busca por respeito e ascensão em contextos marcados pela exclusão. A recorrência de “favela” no rap, assim como no funk, reforça a centralidade desse espaço nas narrativas periféricas. Contudo, enquanto o funk tende a exaltar a favela como um lugar de celebração cultural, o rap a aborda como um cenário de luta, violência e resistência. Termos como “guerra” e “dinheiro” evidenciam conflitos

diários, tanto no enfrentamento das adversidades quanto no desejo de superação social e econômica. O rap, assim, se constitui como um poderoso instrumento de denúncia e reivindicação, utilizando a palavra como arma para questionar injustiças e transformar a indignação em ação.



(a) Samba



(b) Rap



(c) Funk

Figura 5.8: Nuvem de Palavras para os Gêneros Samba, Rap e Funk

Essas nuvens de palavras não apenas destacam os temas centrais de cada gênero, mas também evidenciam como o samba, o funk e o rap funcionam como instrumentos de expressão das realidades periféricas. Cada gênero, à sua maneira, dá voz às comunidades marginalizadas, articulando emoções e narrativas que dialogam com suas vivências cotidianas. O samba, ao abordar o amor e a melancolia, sublima o sofrimento em arte; o funk, com sua ênfase na celebração, transforma o corpo e a dança em atos de resistência e liberdade; enquanto o rap, com seu tom crítico, denuncia as desigualdades e clama por mudança social.

Os resultados desta pesquisa convergem com estudos anteriores como o de Rojas et al. [70, 100], que aponta para a predominância de temas como consumo, sedução, violência e vida nas favelas nas letras de Funk. Ao associar esses temas a emoções como frustração e revolta, frequentemente presentes em narrativas sobre violência e desigualdade, esta pesquisa contribui para uma análise complementar das músicas como expressão das vivências e sentimentos, revelando um potencial para corroborar com a compreensão das dinâmicas sociais e culturais presentes nesse contexto.

## 5.7 Análise Temporal dos Temas

A análise da evolução temática nas letras de músicas das periferias brasileiras revela mudanças nas preocupações e expressões culturais ao longo das décadas. Utilizando técnicas de PLN, foram identificadas palavras-chave representativas dos principais temas abordados em diferentes períodos e gêneros musicais, conforme informado na Tabela 5.3. Essa tabela destaca as variações temáticas nas letras dos gêneros Samba, Funk e Rap ao longo das décadas, revelando as emoções predominantes em cada período.

No Samba, a emoção predominante de alegria reflete uma celebração contínua da cultura e dos laços comunitários ao longo das décadas. Nos anos 1950, bigramas como “danado separei” e “feitio oracao” sugerem a influência da religiosidade e da convivência em comunidade. Essa temática persiste com variações nos anos 1960, com bigramas como “inteiro chorar” e “abraçei chorava”, que refletem uma expressão emocional mais introspectiva, mas ainda permeada pela celebração e resiliência. Entre os anos 1970 e 1990, bigramas como “cadencia refrao”, “sacode poeira”, e “prazer saudade” indicam uma conexão com as dinâmicas do cotidiano e uma reafirmação da alegria em meio aos desafios. Nos anos 2000 e 2010, os bigramas “consigo esquecer” e “paixao sonhos” mantêm o foco na esperança e nos vínculos afetivos. Finalmente, em 2020, bigramas como “dormir conchinha” e “sorriso grande” reafirmam a celebração da vida em suas diversas formas, mesmo em um cenário de incertezas.

Gênero	Década	Top 5 Bigramas	Emoção
funk	1990	debaixo cordinha; hipocrisia tchururu; mentira hipocrisia; agitar escutar; repete refrao	alegria
funk	2000	patrao agradar; gatinha conquistar; mulheres perdem; tigrão mulheres; pronto invadir	alegria
funk	2010	jogando bumbum; jogando bundao; quadradinho sensacional; sentando quicando; safada bumbum	alegria
funk	2020	camarote novinha; sorrir chorar; favela venceu; correr perigo; balanca consegue	alegria
rap	1990	calibre pesados; preste atencao; pronto atirar; estoura violencia; jornal revista	raiva
rap	2000	trilha sonora; milhoes apenas; lagrimas escorrem; palavra sagrada; ataque epiletico	raiva
rap	2010	presta atencao; ganhar dinheiro; luccas carlos; dinheiro mulher; querer crescer	alegria
rap	2020	favela venceu; historia contar; dinheiro gastar; sabendo dinheiro; compromisso correr	alegria
samba	1950	danado separei; feitio oracao; cabeça doente; doente danado; separei sujeito	alegria
samba	1960	inteiro chorar; abracei chorava; perguntar paciencia; queimar destruir; paisagem coragem	alegria
samba	1970	cadencia refrao; cansei avisar; comprar feijao; dormindo comecar; escuto correria	alegria
samba	1980	apertar acender; gostam caroco; gritar ladrao; revolver rebolando; chamou candengo	alegria
samba	1990	sacode poeira; prazer saudade; consegue acreditar; delicia gostoso; esconde timidez	alegria
samba	2000	consigo esquecer; beijar infinito; barracao goiabada; amizade permanecer; apesar sonhos	alegria
samba	2010	consigo esquecer; paixao sonhos; alguem historia; desesperar jamais; esperar chegando	alegria
samba	2020	dormir conchinha; querer morrer; sorriso grande; estandarte sanatorio; sanatorio passar	alegria

Tabela 5.3: Variação temática ao longo das décadas e respectiva emoção predominante

No Funk, a emoção predominante também é alegria, representando a celebração da vida cotidiana e a resiliência das comunidades periféricas. Nos anos 1990, bigramas como “debaixo cordinha” e “hipocrisia tchururu” enfatizam o caráter festivo e irreverente típico do gênero. Na década de 2000, bigramas como “patrao agradar” e “gatinha conquistar” refletem um tom mais leve e voltado para as relações interpessoais. Nos anos 2010, bigramas como “jogando bumbum” e “quadradinho sensacional” indicam uma celebração mais explícita da sensualidade e do corpo, uma característica que permanece na década de 2020, como evidenciado por “camarote novinha” e “favela venceu”, que também trazem um tom de vitória e superação.

No Rap, a análise revela uma trajetória emocional mais diversificada, alternando entre raiva e alegria. Nos anos 1990, a raiva predomina, com bigramas como “calibre pesados” e “pronto atirar” refletindo críticas sociais e a realidade de violência nas periferias. Essa emoção permanece nos anos 2000, com bigramas como “milhoes apenas” e “lagrimas escorrem” destacando as dificuldades enfrentadas pelas comunidades. No entanto, nos anos 2010, o Rap apresenta um retorno à alegria, com bigramas como “ganhar dinheiro” e “querer crescer” indicando otimismo e aspirações de melhoria de vida. Esse tom positivo persiste nos anos 2020, com bigramas como “favela venceu” e “historia contar”, que celebram conquistas individuais e coletivas.

Assim, enquanto o Samba e o Funk mantêm a alegria como emoção predominante em todas as décadas analisadas, o Rap reflete uma alternância entre alegria e raiva, evidenciando uma maior complexidade emocional em resposta às transformações sociais e às realidades vividas nas periferias. Essa análise destaca como as emoções e os temas das músicas periféricas brasileiras são profundamente influenciados pelos contextos culturais e históricos de cada período.

A Tabela 5.4 revela variações temáticas no Rap ao longo de cada quinquênio, destacando as emoções predominantes em cada período. Nos anos 1990, a emoção pre-

Quinquenio	Top Bigramas	Emoção Principal
1990	cheiro sangue; preserve gloria; estoura violencia; abencoe camaradas; mentira acreditar	Raiva
2000	caminho sozinho; milhoes apenas; adianta querer; caixao descendo; entender refrao	Raiva
2005	trilha sonora; cabeça erguida; dinheiro mulher; mulher dinheiro; aumenta volume	Raiva
2010	dificil entender; importa caminho; querer crescer; querem cabeça; resolver problema	Alegria
2015	ganhar dinheiro; atende telefone; deixou passando; provem descaso; querendo guerra	Alegria
2020	favela venceu; sabendo dinheiro; alguem contigo; dinheiro gastar; assaltar porsche	Alegria

Tabela 5.4: Variação temática ao longo dos quinquênios para o Rap

dominante é a raiva, com bigramas como “cheiro sangue”, “preserve gloria” e “estoura violencia”, que indicam a indignação e as dificuldades enfrentadas nas periferias. Esse sentimento persiste no quinquênio de 2000, com bigramas como “caminho sozinho”, “milhoes apenas” e “caixao descendo”, reafirmando a crítica social diante da marginalização e desigualdade.

Entre 2005 e 2009, o Rap continua dominado pela raiva, com bigramas como “trilha sonora”, “cabeça erguida” e “dinheiro mulher”, que refletem uma visão crítica das condições socioeconômicas e das lutas vividas pelas comunidades. Contudo, a partir de 2010, observa-se uma mudança significativa, com a emoção predominante passando a ser a alegria. No quinquênio de 2010-2014, bigramas como “dificil entender” e “importa caminho” sugerem um sentimento de esperança e transformação social, enquanto nos anos de 2015-2019, bigramas como “ganhar dinheiro” e “atende telefone” reforçam uma visão otimista e orientada para o futuro.

A partir de 2020, o Rap mantém a alegria como emoção predominante, com bigramas como “favela venceu”, “sabendo dinheiro” e “alguem contigo”, que apontam para uma busca por estabilidade e progresso. Esses temas refletem a adaptabilidade do Rap às mudanças sociais, mantendo-se como uma forma de expressão das aspirações e lutas das comunidades periféricas ao longo do tempo.

# Capítulo 6

## Conclusão

Este capítulo final resume os principais achados da pesquisa e oferece uma reavaliação crítica dos resultados alcançados. Estruturado em seções, este capítulo inicia com uma síntese dos objetivos da pesquisa e dos resultados obtidos, e de uma comparação com a literatura existente. Em seguida, discutimos as limitações do estudo, sugerindo direções para trabalhos futuros que possam expandir as descobertas apresentadas. Por fim, apresentamos as contribuições derivadas, destacando a sua relevância para o campo de estudo da música periférica e do PLN.

### 6.1 Resultados da Pesquisa

O objetivo principal desta dissertação foi explorar como as técnicas de PLN podem ser aplicadas para identificar temas específicos e nuances emocionais nas letras das músicas provenientes das periferias brasileiras. Os modelos utilizados (BERTimbau e GPT) demonstraram bom desempenho na identificação de sentimentos e padrões temáticos, tanto de forma isolada quanto combinada.

Este estudo, ao alinhar-se às questões de pesquisa propostas, responde à QP1 ao adaptar técnicas de PLN para captar sentimentos e temas recorrentes, explorando métodos como análise de sentimentos, modelagem de tópicos e extração de informações. Para a QP2, demonstra que a aplicação de ferramentas de análise e visualização de dados permite identificar padrões e tendências, bem como mapear evoluções nas narrativas das músicas ao longo do tempo.

A análise das letras de músicas nas periferias brasileiras, utilizando técnicas de PLN, permitiu identificar temas específicos e nuances de sentimentos com boa precisão. Essas técnicas facilitaram a extração de palavras-chave e a análise semântica das letras, destacando tópicos recorrentes como desigualdade social, violência, racismo e busca por justiça. A aplicação de métodos de mineração de texto e análise de frequência de termos revelou padrões temáticos significativos, evidenciando como a música reflete as experiências

e a resiliência das comunidades periféricas.

Os resultados indicam que os gêneros musicais Funk, Rap e Samba apresentam perfis emocionais distintos. O Rap destaca-se pela predominância de raiva e tristeza, evidenciando um caráter expressivo que reflete tensões e introspecções. O Funk exibe uma variabilidade emocional notável, com ênfase em alegria e surpresa, sugerindo uma estética dinâmica e versátil. O Samba, por sua vez, é marcado principalmente por alegria.

No recorte temporal, observa-se uma evolução nos padrões emocionais. Durante a década de 1990, o Rap apresenta altos índices de raiva, enquanto nas décadas seguintes ocorrem aumentos graduais de tristeza e outros tons mais contemplativos. O Funk, inicialmente associado a emoções predominantemente alegres, passa a incorporar maior complexidade emocional em anos recentes. O Samba mantém uma consistência nas emoções predominantes ao longo do período analisado, reforçando sua identidade estética e sua expressividade singular.

Ainda, os resultados revelam os temas predominantes: desigualdade social, violência, racismo e busca por justiça. Termos como “favela”, “resistência”, “injustiça” e “paz” foram frequentemente mencionados, destacando a relevância desses tópicos. O Samba, com sua origem nos morros e quilombos, carrega a herança africana e a celebração da vida, mesmo em meio à dificuldade. O Rap, emergindo das periferias urbanas, se tornou um veículo para protesto social, dando voz às lutas contra a desigualdade e a injustiça. Já o Funk representa tanto a celebração da cultura periférica quanto uma crítica às dificuldades enfrentadas por essas comunidades.

O uso de técnicas de PLN, como BERTimbau e GPT, mostrou-se fundamental para esta pesquisa. A aplicação automatizada viabilizou a análise de um grande volume de letras em escalas temporais e quantitativas inviáveis por métodos manuais. Enquanto análises manuais estão sujeitas a limitações, como vieses interpretativos e dificuldades na consistência e no tratamento de grandes dados, as técnicas de PLN ampliaram as possibilidades analíticas. Recursos como visualizações gráficas e temporais facilitaram a interpretação das tendências emocionais e temáticas observadas.

## 6.2 Contribuições em Relação à Literatura Atual

Os achados desta dissertação corroboram com a literatura, como o de Ferreira *et al* [27], que também utilizou técnicas de PLN para analisar letras de músicas e identificou temas recorrentes nas composições musicais. No entanto, esta dissertação vai além ao aplicar uma combinação de modelos como BERTimbau e GPT, o que permitiu diferentes análises das emoções e temas presentes nas músicas, inclusive em décadas distintas.

Vale mencionar o trabalho de Palomeque e de Lucio [63], que discute a relação entre características musicais e emoções nas letras, focando em métodos tradicionais de análise de texto. Diferentemente, esta dissertação utiliza técnicas de PLN para capturar diferentes emoções, oferecendo um melhor entendimento das dinâmicas emocionais nas composições periféricas.

Além disso, a análise emocional realizada por Song e Beck [81] (utilizando modelos de estado) ressoa com a abordagem desta dissertação ao explorar dinâmicas emocionais complexas nas composições musicais. Entretanto, a integração de dados acústicos e metadados junto com as letras, como realizada aqui, representa uma inovação significativa. Essa abordagem multidimensional permitiu a identificação de padrões que estudos anteriores não conseguiram detectar, fornecendo uma visão mais completa e holística das músicas periféricas.

Ainda, ao combinar técnicas de PLN, análise multidimensional de dados e o foco na tecnologia de *streaming*, esta dissertação não apenas valida os achados anteriores, mas também amplia significativamente a compreensão da resiliência cultural e da expressão musical nas periferias brasileiras, oferecendo novas perspectivas e métodos que podem ser aplicados em futuras pesquisas na área.

## 6.3 Ameaças à Validade e Trabalhos Futuros

O estudo realizado nesta dissertação possui algumas limitações que podem ser abordadas em pesquisas futuras. Primeiramente, a análise enfoca principalmente gêneros musicais como Rap, Funk e Samba, limitando assim a abrangência dos resultados. Emoções como alegria e tristeza podem ser mais facilmente reconhecidas devido à sua presença frequente e explícita nas letras musicais, enquanto emoções mais complexas, como medo ou raiva, apresentam maior dificuldade de interpretação pelos modelos.

Outra limitação é o ajuste do modelo BERTimbau com emoções rotuladas previamente pelo GPT, utilizando dados acústicos e metadados além das letras das músicas. Isso pode introduzir vieses na identificação emocional, pois os dados utilizados podem não capturar totalmente a complexidade emocional presente nas músicas das periferias. Além disso, embora parte das classificações geradas pelo GPT seja auditada manualmente, a proporção revisada pode não garantir a correção de todos os possíveis erros. Isso implica que algumas classificações errôneas podem permanecer nos resultados, especialmente em categorias de emoções mais sutis ou culturalmente específicas.

Apesar dessas limitações, os resultados do estudo permanecem válidos e importantes, abrindo caminho para futuras pesquisas que podem abordar essas lacunas e aprofun-

dar o entendimento sobre a resiliência cultural nas periferias brasileiras. A importância da música como ferramenta de resistência e expressão cultural nas periferias é evidente, e este estudo contribui para a valorização dessas manifestações artísticas.

Futuras pesquisas podem explorar regiões distintas do Brasil, comparando e contrastando as expressões musicais de diferentes periferias, além de estudar outros gêneros musicais presentes nessas áreas para compreender como contribuem para a resiliência cultural. Isso permitirá uma visão mais completa e representativa da diversidade musical e cultural das periferias brasileiras. Estudos de caso que acompanhem ao longo do tempo a evolução da música nas periferias e seu impacto nas comunidades também podem proporcionar aos algoritmos de identificação de interrupção ou de recomendação mais informações para entender melhor o mercado e o perfil dos moradores na periferia, além de proporcionar uma maior visibilidade desses movimentos que surgem no Brasil.

Portanto, as limitações identificadas neste estudo não apenas destacam áreas de melhoria, mas também indicam direções promissoras para pesquisas futuras, que poderão contribuir de maneira significativa para o entendimento e a valorização da cultura e resiliência nas periferias brasileiras.

## 6.4 Contribuições Técnicas

Além desta dissertação de mestrado, a pesquisa gerou dois conjuntos de dados valiosos, que estão disponíveis publicamente, com informações detalhadas sobre as letras de diferentes gêneros musicais. São eles: o Conjunto de Dados de Séries Temporais de Músicas Brasileiras [88] e o MGPB: Conjunto de Dados de Séries Temporais de Músicas de Gênero de Protesto Brasileiras [89].

## Referências

- [1] Shreyas Agrawal, Sumanto Dutta, and Bidyut Kr. Patra. Sentiment Analysis of Short Informal Text by Tuning BERT - Bi-LSTM Model. In *19th IEEE International Conference on Smart Technologies*, pages 98–102. IEEE, 2021.
- [2] Yudhik Agrawal, Ramaguru Guru Ravi Shanker, and Vinoo Alluri. Transformer-based approach towards music emotion recognition from lyrics. In *Advances in Information Retrieval*, pages 167–175, Cham, 2021. Springer International Publishing.
- [3] Christopher Akiki and Manuel Burghardt. Toward a Musical Sentiment (MuSe) Dataset for Affective Distant Hearing. In *Proceedings of the Workshop on Computational Humanities Research*, volume 2723 of *CEUR Workshop Proceedings*, pages 225–235. CEUR-WS.org, 2020.
- [4] Fabrício Almeida do Carmo, Jorge Luiz Figueira da Silva Junior, Rafael Geraldeli Rossi, and Fábio Manoel França Lobato. Text representations for lyric-based identification of musical subgenres. *IEEE Latin America Transactions*, 21(6):737–744, Jun. 2023.
- [5] Yunjing An, Shutao Sun, and Shujuan Wang. Naive bayes classifiers for music emotion classification based on lyrics. In *2017 IEEE/ACIS 16th International Conference on Computer and Information Science (ICIS)*, pages 635–638, 2017.
- [6] Sarthak Anand. Studying the impacts of pre-training using ChatGPT-generated text on downstream tasks. *CoRR*, abs/2309.05668, 2023.
- [7] João Andrade. O Reconhecimento do Brega Funk como Movimento Cultural do Recife: Cultura do movimento popular. *Revista Caboré*, 1(6):87–95, mar. 2023.
- [8] Noah Askin and Michael Mauskopf. What makes popular culture popular? product features and optimal differentiation in music. *American Sociological Review*, 82(5):910–944, 2017.
- [9] Leda Barbio. Jovens (sub)urbanos: O impacto do hip hop na produção de identidades sociais. *Forum Sociológico*, 21:75–83, 11 2011.
- [10] Nomi Baruah, Amlan Jyoti Kalita, Anugya Gogoi, Madhuzya Bezbaruah, Nikesh Prasad, Vishma Pratim Das, and Rituraj Phukan. Detection of explicit lyrics in

- hindi music using lstm. In *International Conference on Computing Communication and Networking Technologies*, pages 1–5, 2023.
- [11] Lorenzo Betti, Carlo Abrate, and Andreas Kaltenbrunner. Large scale analysis of gender bias and sexism in song lyrics. *EPJ Data Science*, 12(1):10, 2023.
- [12] Kerstin Bischoff, Claudiu S. Firan, Mihai Georgescu, Wolfgang Nejdl, and Raluca Paiu. Social Knowledge-Driven Music Hit Prediction. In *International Conference Advanced Data Mining and Applications, 5th*, volume 5678 of *Lecture Notes in Computer Science*, pages 43–54. Springer, 2009.
- [13] Botton, André Natã Mello . Realismo e violência em romances da literatura marginal-periférica brasileira : a representação da favela. Master’s thesis, Programa de Pós-Graduação em Letras, 2019. Escola de Humanidades.
- [14] Charlotte O. Brand, Alberto Acerbi, and Alex Mesoudi. Cultural evolution of emotional expression in 50 years of song lyrics. *Evolutionary Human Sciences*, 1:e11, 2019.
- [15] Anderson Brasil. *Música e periferia: o sonho e o real em um mundo negro chamado Bahia*. Editora Appris, 2020.
- [16] Michel Buffa, Elena Cabrio, Michael Fell, Fabien Gandon, Alain Giboin, Romain Hennequin, Franck Michel, Johan Pauwels, Guillaume Pellerin, Maroua Tikat, and Marco Winckler. The wasabi dataset: Cultural, lyrics and audio analysis metadata about 2 million popular commercially released songs. In *The Semantic Web*, pages 515–531, Cham, 2021. Springer International Publishing.
- [17] Raphael R. Campos and Marcos André Gonçalves. BERT: melhorando classificação de texto com árvores extremamente aleatórias, bagging e boosting. In *Simpósio Brasileiro de Banco de Dados*, pages 127–132. SBC, 2016.
- [18] Angelo Cesar Mendes da Silva, Diego Furtado Silva, and Ricardo Marcondes Marcacini. 4MuLA: A Multitask, Multimodal, and Multilingual Dataset of Music Lyrics and Audio Features. In *WebMedia '20: Brazillian Symposium on Multimedia and the Web*, pages 145–148. ACM, 2020.
- [19] Simone Pereira de Sá. Cultura digital, videoclipes e a consolidação da Rede de Música Brasileira Pop Periférica. *Fronteiras - estudos midiáticos*, 21(2):21–32, 2019.
- [20] Rémi Delbouys, Romain Hennequin, Francesco Piccoli, Jimena Royo-Letelier, and Manuel Moussallam. Music mood detection based on audio and lyrics with deep neural net. In *Proceedings of the 19th International Society for Music Information Retrieval Conference*, pages 370–375, 2018.

- [21] Maibam Debina Devi and Navanath Saharia. Exploiting topic modelling to classify sentiment from lyrics. In *Machine Learning, Image Processing, Network Security and Data Sciences*, pages 411–423, Singapore, 2020. Springer Singapore.
- [22] Marcelo Dias and Karin Becker. Detecção semi-supervisionada de posicionamento em tweets baseada em regras de sentimento. In *Simpósio Brasileiro de Bancos de Dados*, pages 40–51. SBC, 2016.
- [23] Katharina Doring. Ouvindo a diversidade musical do mundo para uma educação musical cognitiva ”além das fronteiras“. *Revista da FAEEBA: Educação e Contemporaneidade*, 26, 04 2017.
- [24] Juan Du. Sentiment analysis and lyrics theme recognition of music lyrics based on natural language processing. *Journal of Electrical Systems*, 20(9s):315–321, 2024.
- [25] Michael Fell, Elena Cabrio, Elmahdi Korfed, Michel Buffa, and Fabien Gandon. Love me, love me, say (and write!) that you love me: Enriching the WASABI song corpus with lyrics annotations. In *Proceedings of the Twelfth Language Resources and Evaluation Conference*, pages 2138–2147, Marseille, France, 2020. European Language Resources Association.
- [26] Gilson Fernandes, Núbia Azevedo, Solange Santos, and Nair PRATA. O rap como ferramenta de resistência: A influência da musicalidade de Djonga para a construção de sentido da luta negra no País. In *Anais do 24<sup>o</sup> Congresso de Ciência da Comunicação na Região Sudeste*, pages 3–5, 2019.
- [27] Barbara P. J. M. Ferreira, Daniel Hasan Dalip, and Ismael S. Silva. Análise e classificação de gêneros musicais com base em letras de músicas. In *Proceedings of the 38th Brazilian Symposium on Databases*, pages 39–50. SBC, 2023.
- [28] Celso Frederico. Da periferia ao centro: cultura e política em tempos pós-modernos. *Estudos Avançados*, 27(79):239–255, jan 2013.
- [29] Tak-chung Fu. A review on time series data mining. *Engineering Applications of Artificial Intelligence*, 24(1):164–181, feb 2011.
- [30] Sandra Garrido and Jennifer Macritchie. Audience engagement with community music performances: Emotional contagion in audiences of a ‘pro-am’ orchestra in suburban sydney. *Musicae Scientiae*, 24(2):155–167, 2020.
- [31] Hall, Beth and Khan, Roxanne and Eslea, Mike. Criminalising black trauma: Grime and drill lyrics as a form of ethnographic data to understand “gangs” and serious youth violence. *Genealogy*, 7(1), 2023.

- [32] Laura Hernández-Lorenzo, Aitor Diaz, Alvaro Perez, Salvador Ros, and Elena González-Blanco. Exploring Spanish contemporary song lyrics through Digital Humanities methods: Some thematic and structural properties. *Digital Scholarship in the Humanities*, 37(3):738–746, 2021.
- [33] Micael Herschmann and Cíntia Sanmartin Fernandes. Resiliência e polinização da música negra que vem ocupando os espaços urbanos do rio de janeiro. *Galáxia (São Paulo)*, 46:e48336, 2021.
- [34] Chih-Fang Huang and Shu-Huan Yao. Algorithmic composition for pop songs based on lyrics emotion retrieval. *Multimedia Tools and Applications*, 81(9):12421–12440, April 2022.
- [35] Jorge Silva Junior, Rafael Rossi, and Fabio Lobato. Uma abordagem baseada em letras para a descoberta de conhecimento da música brasileira: o sertanejo como um estudo de caso. In *Anais do XVI Encontro Nacional de Inteligência Artificial e Computacional*, pages 949–960, Porto Alegre, RS, Brasil, 2019. SBC.
- [36] Patrik N. Juslin. Five facets of musical expression: A psychologist’s perspective on music performance. *Psychology of Music*, 31(3):273–302, 2003.
- [37] Patrik N Juslin and Daniel Västfjäll. Emotional responses to music: the need to consider underlying mechanisms. *The Behavioral and Brain Sciences*, 31(5):559–575, Oct 2008.
- [38] Savannah L. Keenan-Kroff, Sarah M. Coyne, Jane Shawcroft, J. Andan Sheppard, Spencer L. James, Samuel E. Ehrenreich, and Marion Underwood. Associations between sexual music lyrics and sexting across adolescence. *Computers in Human Behavior*, 140:107562, 2023.
- [39] Haven Kim, Jongmin Jung, Dasaem Jeong, and Juhan Nam. K-pop lyric translation: Dataset, analysis, and neural-modelling. In *Proceedings of the 2024 Joint International Conference on Computational Linguistics, Language Resources and Evaluation (LREC-COLING 2024)*, pages 9974–9987, Torino, Italia, May 2024. ELRA and ICCL.
- [40] Bartłomiej Koptyra, Anh Ngo, Łukasz Radliński, and Jan Kocoń. Clarin-emo: Training emotion recognition models using human annotation and chatgpt. In *Computational Science*, pages 365–379, Cham, 2023. Springer Nature Switzerland.
- [41] Quoc Le and Tomas Mikolov. Distributed representations of sentences and documents. In *Proceedings of the 31st International Conference on Machine Learning - Volume 32*, pages II–1188–II–1196. JMLR.org, 2014.

- [42] Jia-Yi Liao, Ya-Hsuan Lin, Kuan-Cheng Lin, and Jia-Wei Chang. A study on using transfer learning to improve BERT model for emotional classification of Chinese lyrics. In *Proceedings of the 33rd Conference on Computational Linguistics and Speech Processing*, pages 13–17, Taoyuan, Taiwan, October 2021. The Association for Computational Linguistics and Chinese Language Processing (ACLCLP).
- [43] Paulo Costa Lima. Perspectivas culturais em música contemporânea: O caso do movimento de composição na bahia. *Orfeu*, 5(1), out. 2020.
- [44] Ricardo Malheiro, Renato Panda, Paulo Gomes, and Rui Pedro Paiva. Emotionally-relevant features for classification and regression of music lyrics. *IEEE Transactions on Affective Computing*, 9(2):240–254, 2018.
- [45] Leonardo De Marchi. The digitalisation of the music industry in brazil: A new productive structure, the legal framework and challenges for peripheral music in the digital age. *Journal of Legal Anthropology*, 7(2):87 – 103, 2023.
- [46] David Martín-Gutiérrez, Gustavo Hernández Peñaloza, Alberto Belmonte-Hernández, and Federico Álvarez García. A multimodal end-to-end deep learning architecture for music popularity prediction. *IEEE Access*, 8:39361–39374, 2020.
- [47] Fernando Martínez-Plumed, Lidia Contreras-Ochando, Cèsar Ferri, José Hernández-Orallo, Meelis Kull, Nicolas Lachiche, María José Ramírez-Quintana, and Peter Flach. Crisp-dm twenty years later: From data mining processes to data science trajectories. *IEEE Transactions on Knowledge and Data Engineering*, 33(8):3048–3061, 2021.
- [48] P Menezes. Music between work and leisure: The case of a collective from fortaleza, brazil. *Journal of Cultural Analysis and Social Change*, 8(2):12, 2023.
- [49] Gabriel Meseguer-Brocal, Alice Cohen-Hadria, and Geoffroy Peeters. Creating dali, a large dataset of synchronized audio, lyrics, and notes. *Transactions of the International Society for Music Information Retrieval*, 3(1):55–67, 2020.
- [50] Maraz Mia, Pulock Das, and Ahsan Habib. Verse-based emotion analysis of bengali music from lyrics using machine learning and neural network classifiers. *International Journal of Computing and Digital Systems*, 15(1):359–370, 2024.
- [51] Kai Middlebrook and Kian Sheik. Song hit prediction: Predicting billboard hits using spotify data. *CoRR*, abs/1908.08609, 2019.
- [52] Maria Luiza Botelho Mondelli, Luiz M. R. Gadelha Jr., and Artur Ziviani. O que os países escutam: Analisando a rede de gêneros musicais ao redor do mundo. In

- Anais do VII Brazilian Workshop on Social Network Analysis and Mining*, Porto Alegre, RS, Brasil, 2018. SBC.
- [53] Henrique da Rosa Müller and Lucas Lazzarotto Vasconcelos Costa. “combinaram de nos matar, combinamos de ficar vivos”: racismo e resistência negra no rap brasileiro contemporâneo. *Afro-Ásia*, 65:607–647, 2022.
- [54] Marcos Napolitano. A invenção da música popular brasileira: Um campo de reflexão para a história social. *Latin American Music Review / Revista de Música Latinoamericana*, 19(1):92–105, 1998.
- [55] Shahrzad Naseri, Sravana Reddy, Joana Correia, Jussi Karlgren, and Rosie Jones. The contribution of lyrics and acoustics to collaborative understanding of mood. *Proceedings of the International AAAI Conference on Web and Social Media*, 16(1):687–698, May 2022.
- [56] Mitsunori Ogihara and Youngmoo Kim. *Mood and Emotional Classification*, pages 135–167. CRC Press, 07 2011.
- [57] Akihiro Ogino and Yuko Yamashita. Emotion-based music information retrieval using lyrics. In *Computer Information Systems and Industrial Management*, pages 613–622, Cham, 2015. Springer International Publishing.
- [58] Celina Oliveira and Monique Angélica Sampaio Flaquer. O rap brasileiro como manifestação e representação da identidade negra e periférica no espaço cultural da música no Brasil. *Portuguese Language Journal*, 17, Dec. 2023.
- [59] Gabriel P. Oliveira, Gabriel R. G. Barbosa, Bruna C. Melo, Mariana O. Silva, Danilo B. Seufitelli, Anisio Lacerda, and Mirella M. Moro. MUHSIC: An Open Dataset with Temporal Musical Success Information, October 2021. doi: 10.5281/zenodo.5591015.
- [60] Gabriel P. Oliveira, Ana Paula Couto da Silva, and Mirella M. Moro. What makes a viral song? unraveling music virality factors. In *Proceedings of the 16th ACM Web Science Conference*, pages 181–190. ACM, 2024.
- [61] Gabriel P. Oliveira, Mariana O. Silva, Danilo B. Seufitelli, Gabriel R. G. Barbosa, Bruna C. Melo, and Mirella M. Moro. Hot streaks in the music industry: identifying and characterizing above-average success periods in artists’ careers. *Scientometrics*, 128(11):6029–6046, 2023.
- [62] Gabriel P. Oliveira, Mariana O. Silva, Danilo B. Seufitelli, Anisio Lacerda, and Mirella M. Moro. Mgd: Music genre dataset, May 2021. doi: 10.5281/zenodo.4778563.

- [63] Marco Palomeque and Juan de Lucio. El sentimiento de las letras de las canciones y su relación con las características musicales. *Proces. del Leng. Natural*, 67:95–102, 2021.
- [64] Ronilson Pereira, André Alves, Douglas Vidal, Flávio Moura, Laura Cabral, Rita Paulino, Marcos Serrufo, and Karla Figueiredo. Análise de sentimento de postagens de usuários no twitter combinando gpt-3 e aprendizado de máquina: Um estudo de caso sobre o 2º turno das eleições presidências brasileiras. In *Anais do XIV Workshop sobre Aspectos da Interação Humano-Computador para a Web Social*, pages 20–27. SBC, 2023.
- [65] Pereira de Sá, Simone. *Música Pop-Periférica Brasileira: Videoclipes, Performances e Tretas na Cultura Digital*. Editora Appris, 2021.
- [66] Martin Pichl and Eva Zangerle. Spotify playlists dataset, March 2019. doi: 10.5281/zenodo.2594557.
- [67] Jonathan Posner, James A Russell, and Bradley S Peterson. The circumplex model of affect: an integrative approach to affective neuroscience, cognitive development, and psychopathology. *Development and psychopathology*, 17(3):715–734, 2005.
- [68] Alec Radford, Jeff Wu, Rewon Child, David Luan, Dario Amodei, and Ilya Sutskever. Language models are unsupervised multitask learners. *OpenAI Blog*, 1(8), 2019.
- [69] Isadora Almeida Rodrigues and Roniere Menezes. Cultura negra e sobrevivência: samba, rap, funk e o racismo sintomático. *Aletria: Revista de Estudos de Literatura*, 28(4):137–154, dez. 2018.
- [70] Jesus Rojas and Karin Becker. Llmusic: Modelagem de tópicos em letras de músicas combinando llm, engenharia de prompt e bertopic. In *Anais Estendidos do XXXIX Simpósio Brasileiro de Bancos de Dados*, pages 158–164, Porto Alegre, RS, Brasil, 2024. SBC.
- [71] Marco Rospocher. Explicit song lyrics detection with subword-enriched word embeddings. *Expert Systems with Applications*, 163:113749, 2021.
- [72] Marco Rospocher. On exploiting transformers for detecting explicit song lyrics. *Entertainment Computing*, 43:100508, 2022.
- [73] James Russell and Geraldine Pratt. A description of the affective quality attributed to environments. *Journal of Personality and Social Psychology*, 38:311–322, 02 1980.

- [74] Danilo B. Seufitelli, Gabriel P. Oliveira, Mariana O. Silva, Clarisse Scofield, and Mirella M. Moro. Hit song science: a comprehensive survey and research directions. *Journal of New Music Research*, 52(1):41–72, 2023.
- [75] Danilo Boechat Seufitelli. *Understanding musical success beyond hit songs: characterization and analyses of musical careers*. PhD thesis, Universidade Federal de Minas Gerais, 2023.
- [76] Jairo Severiano. *Uma história da música popular brasileira: das Origens à Modernidade*. Editora 34, São Paulo, Brasil, 3<sup>a</sup> edition, 2013.
- [77] Seungkyu Shin and Juyong Park. On-chart success dynamics of popular songs. *Adv. Complex Syst.*, 21(3-4):1850008:1–1850008:18, 2018.
- [78] Douglas Silva and Cláudio Gomes. Modelo de aprendizado de máquina para classificação de gêneros musicais populares da região amazônica legal internacional. *Revista Eletrônica de Iniciação Científica em Computação*, 20(4), dez. 2022.
- [79] Mariana O. Silva et al. MusicOSet: An enhanced open dataset for music data mining. In *Brazilian Symposium on Databases Dataset Showcase Workshop*, pages 8–17, Porto Alegre, RS, Brasil, 2019. SBC.
- [80] Yingjin Song and Daniel Beck. Modeling Emotion Dynamics in Song Lyrics with State Space Models. *Transactions of the Association for Computational Linguistics*, 11:157–175, 02 2023.
- [81] Yingjin Song and Daniel Beck. Modelling emotion dynamics in song lyrics with state space models. *Trans. Assoc. Comput. Linguistics*, 11:157–175, 2023.
- [82] Fábio Souza, Rodrigo Frassetto Nogueira, and Roberto de Alencar Lotufo. Bertimbau: Pretrained BERT models for brazilian portuguese. In *Intelligent Systems - 9th Brazilian Conference*, volume 12319 of *Lecture Notes in Computer Science*, pages 403–417. Springer, 2020.
- [83] Teppo Särkämö, Mari Tervaniemi, Sari Laitinen, Anita Forsblom, Seppo Soynila, Mikko Mikkonen, Taina Autti, Heli Silvennoinen, Jaakko Erkkilä, Matti Laine, Isabelle Peretz, and Marja Hietanen. Music listening enhances cognitive recovery and mood after cerebral artery stroke. *Brain : a journal of neurology*, 131:866–76, 04 2008. DOI:10.1093/brain/awn013.
- [84] Ting Fang Tan, Kabilan Elangovan, Liyuan Jin, Yao Jie, Li Yong, Joshua Lim, Stanley Poh, Wei Yan Ng, Daniel Yan Zheng Lim, Yuhe Ke, Nan Liu, and Daniel Shu Wei Ting. Fine-tuning large language model (LLM) artificial intelligence chatbots in

- ophthalmology and llm-based evaluation using GPT-4. *CoRR*, abs/2402.10083, 2024.
- [85] José Ramos Tinhorão. *Pequena história da música popular*. Editora Vozes, 1974.
- [86] José Ramos Tinhorão. *Música e Cultura Popular Brasileira*. Editora 34, 1999.
- [87] José Ramos Tinhorão. *Pequena história da música popular*. Editora 34, São Paulo, SP, Brasi, 7 edition, 2013.
- [88] Rubio Torres Castro Viana and Mirella Moro. Conjunto de Dados de Séries Temporais de Músicas Brasileiras, July 2024. DOI: 10.5281/zenodo.12733931.
- [89] Rubio Torres Castro Viana and Mirella Moro. MGPB: Conjunto de Dados de Séries Temporais de Músicas de Gênero de Protesto Brasileiras, June 2024.
- [90] Diego Tumitan and Karin Becker. Tracking sentiment evolution on user-generated content: A case study on the brazilian political scene. In *Brazilian Symposium on Databases (Short Papers)*, pages 24:1–24:6. Brazilian Symposium on Databases, 2013.
- [91] Christian Uhle and Juergen Herre. Estimation of tempo, micro time and time signature from percussive music. In *Proc. Int. Conference on Digital Audio Effects (DAFx)*. Citeseer, 2003.
- [92] Danny Suarez Vargas et al. Unsupervised aspect term extraction for sentiment analysis through automatic labeling. In *International Conference on Web Information Systems and Technologies*, pages 344–354. SCITEPRESS, 2022.
- [93] Ashish Vaswani, Noam Shazeer, Niki Parmar, Jakob Uszkoreit, Llion Jones, Aidan N Gomez, Lukasz Kaiser, and Illia Polosukhin. Attention is all you need. In *Advances in neural information processing systems*, pages 5998–6008, 2017.
- [94] Igor Vatolkin, Günther Rötter, and Claus Weihs. Music genre prediction by low-level and high-level characteristics. In *Data Analysis, Machine Learning and Knowledge Discovery - Proceedings of the 36th Annual Conference of the Gesellschaft für Klassifikation e. V., Hildesheim, Germany, August 2012*, Studies in Classification, Data Analysis, and Knowledge Organization, pages 427–434. Springer, 2012.
- [95] Carolina C. Vieira, Túlio Corrêa Loures, Pedro O. S. Vaz de Melo, and Renato Martins Assunção. The times they are a-changin’ (or not): song lyrics analysis over the years. In *Proceedings of the 25th Brazillian Symposium on Multimedia and the Web*, page 237–244, New York, NY, USA, 2019. ACM.

- [96] Maria Virvou, George A. Tsihrintzis, Dionisios N. Sotiropoulos, Konstantina Chrysafiadi, Evangelos Sakkopoulos, and Evangelia-Aikaterini Tsihrintzi. Chatgpt in artificial intelligence-empowered e-learning for cultural heritage: The case of lyrics and poems. In *2023 14th International Conference on Information, Intelligence, Systems and Applications (IISA)*, pages 1–9, July 2023. DOI:10.1109/IISA59645.2023.10345878.
- [97] R. Wallaschek. On the difference of time and rhythm in music. *Mind*, 4(13):28–35, 1895.
- [98] Jun-You Wang, Chung-Che Wang, Chon-In Leong, and Jyh-Shing Roger Jang. Mirmlpop: A multilingual pop music dataset with time-aligned lyrics and audio. In *IEEE International Conference on Acoustics, Speech and Signal Processing*, pages 1366–1370, 2024.
- [99] Yu Xiong, Feng Su, and Qianqian Wang. Automatic music mood classification by learning cross-media relevance between audio and lyrics. In *IEEE International Conference on Multimedia and Expo*, pages 961–966, July 2017.
- [100] Jesus Yopez, Bruno Tavares, Fabíola Peres, and Karin Becker. Na batida do funk: modelagem de tópicos combinando llm, engenharia de prompt e bertopic. In *Anais do XXXIX Simpósio Brasileiro de Bancos de Dados*, pages 613–625, Porto Alegre, RS, Brasil, 2024. SBC.
- [101] Eva Zangerle, Michael Vötter, Ramona Huber, and Yi-Hsuan Yang. Hit song prediction: Leveraging low- and high-level audio features. In Arthur Flexer, Geoffroy Peeters, Julián Urbano, and Anja Volk, editors, *Proceedings of the 20th International Society for Music Information Retrieval Conference*, pages 319–326, 2019.
- [102] Kejun Zhang, Hui Zhang, Simeng Li, Chang-yuan Yang, and Lingyun Sun. The pmemo dataset for music emotion recognition. In *Proceedings of the 2018 ACM on International Conference on Multimedia Retrieval, ICMR 2018, Yokohama, Japan, June 11-14, 2018*, pages 135–142. ACM, 2018.
- [103] Yixiao Zhang, Junyan Jiang, Gus Xia, and Simon Dixon. Song interpretation dataset, December 2022. doi: 10.5281/zenodo.7429711.

# Apêndice A

## Letras ao Longo do Tempo

### A.1 Nuvens de Bigramas do Samba (TF-IDF)



Figura A.1: Samba década de 50




Figura A.2: Samba década de 60




Figura A.3: Samba década de 70



Figura A.4: Samba década de 80



Figura A.5: Samba década de 90




Figura A.6: Samba década de 2000



Figura A.7: Samba década de 2010      Figura A.8: Samba década de 2020



## A.3 Nuvens de Bigramas do Funk (TF-IDF)



Figura A.13: Funk década de 90




Figura A.14: Funk década de 2000




Figura A.15: Funk década de 2010




Figura A.16: Funk década de 2020

## Apêndice B

### Características Acústicas

Neste apêndice, são apresentadas diversas visualizações das características acústicas médias do conjunto de dados utilizado na análise.

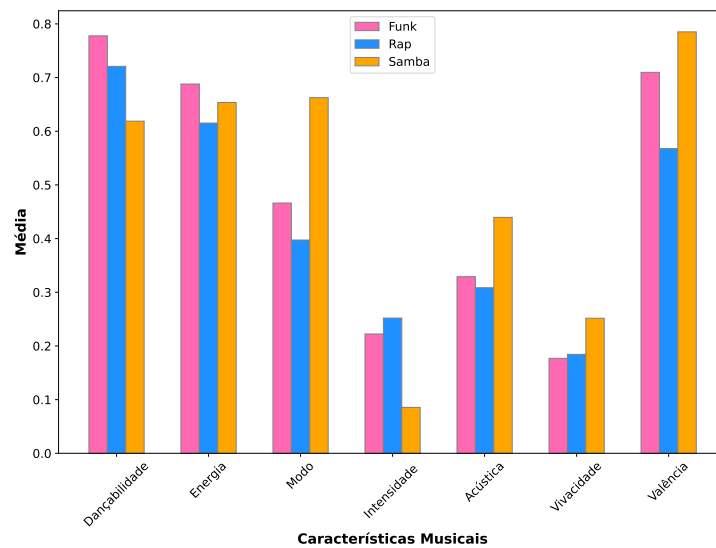


Figura B.1: Características acústicas médias positivas




Figura B.2: Característica instrumental

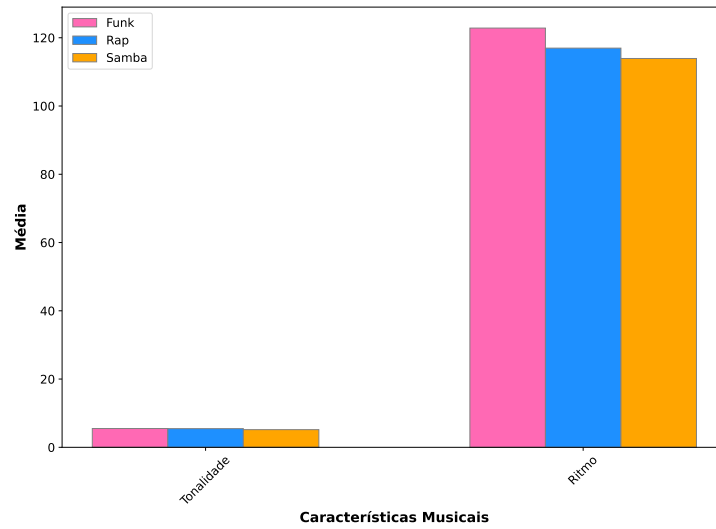


Figura B.3: Intensidade sonora média do conjunto de dados




Figura B.4: Ritmo e tonalidade média do conjunto de dados

# Apêndice C

## Exemplos de Musica

### A Vida É Desafio - Racionais MC

É necessário sempre acreditar que o sonho é possível  
 Que o céu é o limite e você, truta, é imbatível  
 Que o tempo ruim vai passar, é só uma fase  
 Que o sofrimento alimenta mais a sua coragem  
 Que a sua família precisa de você  
 Lado a lado se ganhar pra te apoiar se perder  
 Falo do amor entre homem, filho e mulher  
 A única verdade universal que mantém a fé  
 Olho as crianças que é o futuro e esperança  
 Que ainda não conhecem, não sentem o que é ódio e ganância  
 Eu vejo o rico que teme perder a fortuna  
 Enquanto o mano desempregado, viciado, se afunda  
 Falo do enfermo, (irmão) falo do são (então)  
 Falo da rua que pra esse louco mundão  
 Que o caminho da cura pode ser a doença  
 Que o caminho do perdão às vezes é a sentença  
 Desavença, treta e falsa união  
 A ambição é como um véu que cega os irmão  
 Que nem um carro guiado na estrada da vida  
 Sem farol no deserto das trevas perdidas  
 Eu fui orgia, ébrio, louco, mas hoje ando sóbrio  
 Guardo o revólver quando você me fala em ódio  
 Eu vejo o corpo, a mente, a alma, o espírito  
 Ouço o repente e o que diz lá no canto lírico  
 Falo do cérebro e do coração  
 Vejo egoísmo, preconceito de irmão pra irmão  
 A vida não é o problema, é batalha, desafio  
 Cada obstáculo é uma lição, eu anuncio  
 É isso aí, você não pode parar  
 Esperar o tempo ruim vir te abraçar  
 Acreditar que sonhar sempre é preciso  
 É o que mantém os irmãos vivos

Figura C.1: Parte da letra da música A Vida É Desafio

---

### Vida Loka, Pt. 1 - Racionais MC

Fé em Deus que ele é justo!  
Ei, irmão, nunca se esqueça  
Na guarda, guerreiro, levanta a cabeça, truta  
Onde estiver, seja lá como for  
Tenha fé, porque até no lixão nasce flor  
Ore por nós, pastor, lembra da gente  
No culto dessa noite, firmão, segue quente  
Admiro os crentes, dá licença aqui  
Mó função, mó tabela, pô, desculpa aí  
Eu me sinto às vezes meio pá, inseguro  
Que nem um vira-lata, sem fé no futuro  
Vem alguém lá, quem é quem, quem será meu bom  
Dá meu brinquedo de furar moletom!  
Porque os bico que me vê, com os truta na balada  
Tenta ver, quer saber, de mim não vê nada  
Porque a confiança é uma mulher ingrata  
Que te beija e te abraça, te rouba e te mata  
Desacreditar, nem pensar, só naquela  
Se uma mosca ameaçar, me catar, piso nela  
O bico deu mó goela, pique bandidão  
Foi em casa na missão, me trombar na Cohab  
De camisa larga, vai saber  
Deus que sabe, qual é maldade comigo, inimigo no migué  
Tocou a campainha, plim, pra tramar meu fim  
Dois maluco armado sim, um isqueiro e um estopim  
Pronto pra chamar minha preta pra falar  
Que eu comi a mina dele ah, se ela tava lá  
Vadia mentirosa, nunca vi, deu mó faia  
Espírito do mal! Cão de buceta e saia  
Talarico nunca fui e é o seguinte  
Ando certo pelo certo, como 10 e 10 é 20  
Já pensou, doido? E se eu tô com meu filho no sofá  
De vacilo desarmado era aquilo  
Sem culpa e sem chance, nem pra abrir a boca  
Ia nessa sem saber, pro cê vê, Vida Loka!

Figura C.2: Parte da letra da música Vida Loka, Pt. 1

### BENÇA - Djonga

Vó, como cê conseguiu criar 3 mulheres sozinha  
Na época que mulher não valia nada?  
Menina na cidade grande, no susto viúva  
E daquela cor que só serve pra ser abusada  
Você não costurou só roupa, né  
Teve que costurar um mundo  
De trauma, abdicação, luta  
Pra hoje falar com orgulho  
Que essa família não tem vagabundo  
Aprendi no seu colo  
Tenha medo de quem tá vivo e respeito por quem tá morto  
Ouvindo desde novo: Cê já é preto  
Num sai desse jeito, se não eles te olha torto  
Fico pensando, uma cama pra quatro  
Ditadura na rua e o frio que trinca o corpo  
Onde mães fortes e generosas se criaram  
O que é do zotro não é meu  
Mas o que é meu tá aí pro zotro se precisar  
Na macumba ela é foda  
Dinheiro é pra quem precisa, aqui é só por caridade  
Pensando tudo que cê passou nessa vida  
E no fundo dos seus olhos não consigo ver maldade  
Vejo gente criando problemas  
Pra competir quem sofre mais, porra, são covardes  
Olhe pra sua nega veia e entenda  
Que num é em blog de hippie boy que se aprende sobre ancestralidade  
Vai e vai, ganha esse mundo sem olhar pra trás  
E vai, só não esquece de voltar pra  
Vai e vai, anda esse mundo sem olhar pra trás  
E vai, só não esquece de voltar

Figura C.3: Parte da letra da música BENÇA

### Meu Mundo - Wc do Beat

Sei que você quer um pouco da minha brisa  
Sei que você gosta muito desse clima  
Desse jeito louco e da minha pegada (e da minha pegada)  
Gata, só não posso te levar pra casa (não, não, não)  
Isso não te impede de ficar comigo (de ficar comigo)  
Vai ser perda de tempo não aproveitar (não aproveitar)  
Vivo no meu mundo mas vivo perdido (vivo perdido)  
Talvez amanhã eu não possa te encontrar (não, não, não)  
Nós andamos diferente  
Ela percebe como a gente fala diferente  
Somos diferentes  
É por isso que ela quer ta perto de nós  
É diferente como nosso bonde faz a diferença  
De olhar diferente eu percebo  
Como a gente não é bem vindo aqui  
Desse jeito tu me deixa louco  
Meu tempo é pouco então vem pra ca  
Me pedindo aquilo que te excita  
Eu te pego de jeito e tu vai voltar  
Escuta tuas as amigas quando elas falarem pra não se apegar  
Porque eu não vivo a vida, a vida que me vive  
Um dia nos vai se encontrar

Figura C.4: Parte da letra da música Meu Mundo

### A Vida É Tipo Roda Gigante - Mc Andrezinho Shock

Na escola da vida aprendi como eu chorei e sofri  
No sonho eu persistir não desistir de lutar  
Vi muita gente subi, mas vi o mesmo cair  
Por humilhar e ferir quem quer só te ajudar  
Pra alcançar o sucesso eu tive fé fui a luta  
Mas não mudei minha conduta e nem meu jeito de ser  
Te dou lhe um papo na boa quer conhecer uma pessoa  
Ou dá a ela dinheiro ou lhe da fama e poder  
Ela esquece das origens num lembra nem de onde veio  
Só quer glamour e área vip se tem flash tá no meio  
Mas só que ela esquece que tudo que sobe desce  
Ela finge entender que o que nasce vai morrer  
Eu to na pista um tempão não cai de para-queda  
Quanto maior é altura, mais dolorosa é a queda  
A vida é tipo roda gigante então pra que esculacho  
Se hoje está em cima amanhã tá embaixo  
Eu tenho fé que na terra minha missão vai ser cumprida  
Porque a humildade é a essência da vida  
Porque a humildade é a essência da vida  
Grava ai  
Pra alcançar o sucesso eu tive fé fui a luta  
Mas não mudei minha conduta e nem meu jeito de ser  
Te dou lhe um papo na boa quer conhecer uma pessoa  
Ou dá a ela dinheiro ou lhe da fama e poder  
Ela esquece das origens num lembra nem de onde veio  
Só quer glamour e área vip se tem flash tá no meio  
Mas só que ela esquece que tudo que sobe desce  
Ela finge entender que o que nasce vai morrer  
Eu to na pista um tempão não cai de para-queda  
Quanto maior é altura, mais dolorosa é a queda

Figura C.5: Parte da letra da música A Vida É Tipo Roda Gigante

### As Rosas Não Falam - Cartola

Bate outra vez  
Com esperanças o meu coração  
Pois já vai terminando o verão  
Enfim  
Volto ao jardim  
Com a certeza que devo chorar  
Pois bem, sei que não queres voltar  
Para mim  
Queixo-me às rosas  
Mas, que bobagem  
As rosas não falam  
Simplesmente, as rosas exalam  
O perfume que roubam de ti, ah  
Devias vir  
Para ver os meus olhos tristonhos  
E, quem sabe, sonhavas meus sonhos  
Por fim

Figura C.6: Parte da letra da música As Rosas Não Falam

### Zé do Carço - Seu Jorge

Num serviço de alto-falante  
No Morro do Pau da Bandeira  
Quem avisa é o Zé do Carço  
Amanhã vai fazer alvoroço  
Alertando a favela inteira  
Ai, como eu queria que fosse Mangueira  
Que existisse outro Zé do Carço  
Pra falar de uma vez pra esse moço  
Carnaval não é esse colosso  
Nossa escola é raiz, é madeira  
Mas é Morro do Pau da Bandeira  
De uma Vila Isabel verdadeira  
E o Zé do Carço trabalha  
E o Zé do Carço batalha  
E que malha o preço da feira  
E na hora que a televisão brasileira  
Destrói toda gente com sua novela  
É que o Zé bota a boca no mundo  
Ele faz um discurso profundo  
Ele quer ver o bem da favela  
Está nascendo um novo líder  
No Morro do Pau da Bandeira  
Está nascendo um novo líder  
No Morro do Pau da Bandeira  
No Morro do Pau da Bandeira  
No Morro do Pau da Bandeira  
Num serviço de alto-falante  
No Morro do Pau da Bandeira  
Quem avisa é o Zé do Carço  
Amanhã vai fazer alvoroço  
Alertando a favela inteira

Figura C.7: Parte da letra da música Zé do Carço

### Todo Menino É Um Rei - Roberto Ribeiro

Todo menino é um rei  
Eu também já fui rei  
Mas quá!  
Despertei  
Todo menino é um rei  
Eu também já fui rei  
Mas quá!  
Despertei  
Por cima do mar (da ilusão)  
Eu naveguei (só em vão)  
Não encontrei  
O amor que eu sonhei  
Nos meus tempos de menino  
Porém menino sonha demais  
Menino sonha com coisas  
Que a gente cresce e não vê jamais  
Todo menino é um rei  
Eu também já fui rei  
Mas quá!  
Despertei  
Todo menino é um rei  
Eu também já fui rei  
Mas quá!  
Despertei  
A vida que eu sonhei  
No tempo que eu era só  
Nada mais do que menino  
Menino pensando só

Figura C.8: Parte da letra da música Todo Menino É Um Rei

### Papel de Pão - Jorge Aragão

Eu nem sei dizer o que senti  
Quando eu acordei e não lhe vi  
Confesso que chorei  
Não suportei a dor  
É doloroso se perder um grande amor  
Mais alucinado eu fiquei  
Quando li o bilhete que encontrei  
Estava escrito num papel de pão  
Foi o que arrasou meu coração  
Ainda me lembro bem  
Estava escrito assim  
Não me procure nosso amor  
Chegou ao fim, ao fim

Figura C.9: Parte da letra da música Papel de Pão

## 24 Horas Por Dia - LUDMILLA

Tu não tem nada pra fazer  
E fica nessa agonia  
Fala de mim, pensa em mim  
Vinte e quatro horas por dia  
Fala de mim, pensa em mim  
Vinte e quatro horas por dia  
Fala de mim, pensa em mim  
Fala, fala de mim, pensa em mim  
Só sabe meu primeiro nome  
E acha que me conhece  
Olha, se põe no seu lugar  
E vê se comigo não se mete  
Faz carinha feia  
Quando passa do meu lado  
Ainda por cima baba  
Me olhando de cima a baixo  
Novinho ficou maluco  
Até parou no tempo  
Quando eu mandei quadradinho  
Mostrando o meu talento  
Calça apertada, bunda empinada  
Dez vezes melhor que a sua namorada  
Para tudo, pego no copo  
Com a unha decorada  
Ô mandada, safadinha  
Eu já descobri seu truque  
Pra saber da minha vida  
Não sai do meu Facebook  
Tu não tem nada pra fazer  
E fica nessa agonia  
Fala de mim, pensa em mim  
Vinte e quatro horas por dia  
Fala de mim, pensa em mim  
Vinte e quatro horas por dia  
Fala de mim, pensa em mim  
Vinte e quatro horas por dia

Figura C.10: Parte da letra da música 24 Horas Por Dia