

Universidade Federal de Campina Grande
Centro de Engenharia Elétrica e Informática
Coordenação de Pós-Graduação em Ciência da Computação

Tese de Doutorado

Caracterizando e Quantificando Inovação em Redes
de Similaridade Musical

Felipe Vieira Falcão

Campina Grande, Paraíba, Brasil

08/2021

Universidade Federal de Campina Grande
Centro de Engenharia Elétrica e Informática
Coordenação de Pós-Graduação em Ciência da Computação

Caracterizando e Quantificando Inovação em Redes de Similaridade Musical

Felipe Vieira Falcão

Tese submetida à Coordenação do Curso de Pós-Graduação em Ciência da Computação da Universidade Federal de Campina Grande - Campus I como parte dos requisitos necessários para obtenção do grau de Doutor em Ciência da Computação.

Área de Concentração: Ciência da Computação
Linha de Pesquisa: Metodologia e Técnicas da Computação

Nazareno Ferreira de Andrade
Fábio Jorge Almeida Morais
(Orientadores)

Campina Grande, Paraíba, Brasil
©Felipe Vieira Falcão, 20/08/2021

F178c Falcão, Felipe Vieira.
Caracterizando e quantificando inovação em redes de similaridade musical / Felipe Vieira Falcão. – Campina Grande, 2021.
102 f. : il. color.

Tese (Doutorado em Ciência da Computação) – Universidade Federal de Campina Grande, Centro de Engenharia Elétrica e Informática, 2021.
"Orientação: Prof. Dr. Nazareno Ferreira de Andrade, Prof. Dr. Fábio Jorge Almeida Morais".
Referências.

1. Recuperação da Informação Musical. 2. Metodologia e Técnicas da Computação. 3. Computação e Música. 4. Processamento de Áudio. 5. Similaridade de Áudio. I. Andrade, Nazareno Ferreira de. II. Morais, Fábio Jorge Almeida. III. Título.

CDU 004.65:78(043)



MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DE CAMPINA GRANDE
POS-GRADUACAO CIENCIAS DA COMPUTACAO
Rua Aprigio Veloso, 882, - Bairro Universitario, Campina Grande/PB, CEP 58429-900

FOLHA DE ASSINATURA PARA TESES E DISSERTAÇÕES

FELIPE VIEIRA FALCÃO

CARACTERIZANDO E QUANTIFICANDO INOVAÇÃO EM REDES DE SIMILARIDADE MUSICAL

Tese apresentada ao Programa de Pós-Graduação em Ciência da Computação como pré-requisito para obtenção do título de Doutor em Ciência da Computação.

Aprovada em: 20/08/2021

Prof. Dr. NAZARENO FERREIRA DE ANDRADE, Orientador, UFCG

Prof. Dr. FÁBIO JORGE ALMEIDA MORAIS, Orientador, UFCG

Prof. Dr. CLÁUDIO ELÍZIO CALAZANS CAMPELO, Examinador Interno, UFCG

Prof. Dr. LEANDRO BALBY MARINHO, Examinador Interno, UFCG

Prof. Dr. DIEGO FURTADO SILVA, Examinador Externo, UFSCar

Prof. Dr. FLAVIO VINICIUS DINIZ DE FIGUEIREDO, Examinador Externo, UFMG



DO MAGISTERIO SUPERIOR, em 04/10/2021, às 20:47, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



Documento assinado eletronicamente por **NAZARENO FERREIRA DE ANDRADE, PROFESSOR(A) DO MAGISTERIO SUPERIOR**, em 06/10/2021, às 14:06, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



Documento assinado eletronicamente por **CLAUDIO ELIZIO CALAZANS CAMPELO, PROFESSOR(A) DO MAGISTERIO SUPERIOR**, em 06/10/2021, às 14:12, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



Documento assinado eletronicamente por **LEANDRO BALBY MARINHO, PROFESSOR 3 GRAU**, em 06/10/2021, às 19:06, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



Documento assinado eletronicamente por **Diego Furtado Silva, Usuário Externo**, em 07/10/2021, às 18:43, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



Documento assinado eletronicamente por **Flavio Vinicius Diniz de Figueiredo, Usuário Externo**, em 08/10/2021, às 09:42, conforme horário oficial de Brasília, com fundamento no art. 8º, caput, da [Portaria SEI nº 002, de 25 de outubro de 2018](#).



A autenticidade deste documento pode ser conferida no site <https://sei.ufcg.edu.br/autenticidade>, informando o código verificador **1815609** e o código CRC **5B1CB983**.

Resumo

Investigações sobre relações de similaridade entre composições, álbuns e artistas desempenham um papel importante na compreensão de tendências presentes nas trajetórias dos gêneros musicais. A influência exercida por essas entidades dentro de uma rede de similaridades pode ser caracterizada de diversas formas, como analisando-se a dimensão da disrupção. Considera-se disruptivo aquele ator capaz de criar uma desestabilização num contexto dominante, gerando uma quebra nas expectativas já consolidadas por práticas anteriores. Iniciativas inovadoras dessa natureza podem ser evidenciadas na música em diversos momentos, seja no surgimento do *rock and roll* ao final dos anos 40, passando pela revolução do *punk rock* três décadas depois e refletindo até mesmo aqui no Brasil com a difusão do *rock* nacional no início da década de 1980. Em contraste aos benefícios do estudo da inovação em diferentes contextos, pouco tem sido proposto e conduzido até o momento no sentido de identificar, categorizar e mensurar a inovação apresentada por entidades musicais ao longo do tempo. Este trabalho propõe-se a preencher essa lacuna e avançar o estado-da-arte no estudo da inovação em redes de similaridade musical. Para tal, um conjunto de dados composto por milhares de canções de forró foi coletado, curado, e processado para obter representações de áudio que pudessem ser comparadas em busca de similaridades entre as músicas. Estas foram utilizadas na construção de uma rede de nós (músicas) e arestas ponderadas (relações de similaridade), que por sua vez serviu de entrada para o cálculo de um índice de disrupção proposto neste estudo. Os resultados apontam para o potencial do índice de disrupção como ferramenta na investigação da inovação musical, sendo ele capaz de revelar novas informações e fatos acerca das trajetórias dos gêneros.

Abstract

Music investigations with main focus in the study of similarity relationships between songs, albums and artists play an important role when trying to understand trends in the history of music genres. The influence exercised by these entities in a similarity network can be categorized in a multitude of points-of-view, including disruption. A disruptive object is one that creates a new stream of events, changing the traditional way of how a context operates. Such class of innovative initiatives can be observed many times during the history of music, as in the emergence of the rock and roll at the end of the 1940's, passing by the punk rock revolution three decades later, and finally reflecting here in Brazil during the boom of the national rock in the early eighties. The proper categorization of innovation and measurement of disruption remain as a tasks with large room for improvement, and these gaps are even more evident in the music domain, where the topic has not received much attention so far. This work builds on preliminary studies focused on the analysis of music disruption derived from metadata-based similarity networks, demonstrating that the raw audio can augment similarity information. We developed a case study based on a collection of a Brazilian local music tradition called Forró, that emphasizes the analytical and musicological potential of a musical disruption metric to describe and explain a genre trajectory over time.

Agradecimentos

Agradeço aos meus pais, Elione e Franklin, por toda prioridade e zelo dedicados incondicionalmente à minha educação e a de meus irmãos. O resultado deste trabalho é, sem a menor sombra de dúvida, um dos muitos frutos de todo esse cuidado, amor e compreensão reservados a mim.

Agradeço imensamente à minha esposa, Ana Carolina, por toda a base familiar, suporte emocional e amor incondicional aplicados antes e durante o desenvolvimento desta tese. Você é parte essencial de tudo que faço, e essa nova conquista é sua também.

Agradeço aos meus irmãos por todos os momentos de descontração que me ajudaram a aliviar a carga de trabalho imposta pela pesquisa.

Agradeço à minha sogra Geralda por todos os conselhos e mimos, e ao meu sogro, Clebert, cuja sabedoria tanto me inspirou e inspira cotidianamente.

Agradeço aos meus orientadores, Nazareno e Fábio, pela ajuda intelectual fornecida durante todas as etapas da pesquisa. A Fábio, por ter prontamente aceitado se juntar a esta pesquisa com ela já em andamento e tanto ter agregado durante esse tempo em que trabalhamos juntos. A Naza, por ter estado presente durante boa parte da minha carreira acadêmica e, em uma de nossas várias idas ao *La Tranca*, em Málaga, ter me brindado com uma conversa que certamente tem influência direta na existência deste trabalho.

Agradeço aos meus amigos e irmãos do grupo *OFF Thread* pelas brincadeiras, ensinamentos e diálogos enriquecedores. Em especial, agradeço muito ao meu irmão Filipe Costa, que se fez ativamente presente nesta pesquisa me auxiliando no desenvolvimento do *Mapa da Inovação do Forró*.

Serei eternamente grato a todos os membros do Laboratório de Sistemas Distribuídos, em especial àqueles que dividiram comigo momentos na sala Rainha: Luiz, Daniel, Dandara, David e Talita.

Deixo também um agradecimento especial a todos que fazem parte do *Music Technology Group (Universitat Pompeu Fabra)* por toda a colaboração nesse curto período tempo em que estivemos juntos. Sou particularmente grato aos professores Xavier Serra e Baris Bozkurt pelo suporte fornecido desde o início de minha estadia em Barcelona.

Conteúdo

1	Introdução	1
1.1	Contextualização	1
1.2	Problema	3
1.3	Objetivos	3
1.4	Resultados e Contribuições	4
1.5	Cronologia do Doutorado	5
1.5.1	Prólogo: SiMPle, Python e Similaridade de Áudio	6
1.5.2	Sistemas de Avaliação para Padrões Rítmicos	7
1.5.3	Qualificação: Índice de Disrupção e Transferência de Aprendizagem	8
1.5.4	<i>Autoencoders</i> , Métricas de Similaridade e Redes Não Ponderadas	9
1.6	Organização do Documento	9
2	Fundamentação Teórica e Trabalhos Relacionados	11
2.1	Disrupção	11
2.1.1	Conceito	11
2.1.2	Índice de Disrupção em Redes Não Ponderadas	13
2.1.3	Índice de Disrupção em Redes Ponderadas	15
2.2	Corpora de Áudio	17
2.3	<i>Features</i> de áudio	21
2.3.1	<i>Mel-frequency Cepstral Coefficients</i> (MFCCs)	22
2.4	<i>Autoencoders</i>	22
2.5	Similaridade de Áudio	24

3	<i>Dataset Forró em Vinil</i>	26
3.1	Motivação	27
3.2	Fonte de Dados e Coleta do <i>Dataset</i>	28
3.3	Correção do <i>Dataset</i>	29
3.4	Extração das <i>Features</i> de Áudio	31
3.4.1	Definição e Extração das <i>Features</i>	31
3.4.2	Redução de Dimensionalidade	34
3.5	Considerações Finais	36
4	Modelando Similaridades Entre Músicas	38
4.1	Métricas de Similaridade	38
4.2	Validação das Similaridades	40
4.2.1	Primeira Validação: <i>Dataset Forró em Vinil</i>	40
4.2.2	Segunda Validação: <i>MagnaTagATune Dataset</i>	43
4.3	Definição da Métrica de Similaridade	45
4.4	Considerações Finais	46
5	Índice de Disrupção em Redes de Similaridade	47
5.1	Construção da Rede de Similaridades	48
5.2	Análise da Inovação no Forró	52
5.2.1	Músicas Mais Disruptivas	53
5.2.2	Álbuns Mais Disruptivos	55
5.2.3	Artistas Mais Disruptivos	57
5.2.4	A Disrupção Feminina	59
5.2.5	A Disrupção ao Longo dos Anos	61
5.3	Considerações Finais	65
6	Mapa da Inovação do Forró	67
6.1	Requisitos e Funcionalidades	67
6.2	Considerações Finais	71
7	Conclusão e Trabalhos Futuros	72
7.1	Limitações e Trabalhos Futuros	74

A	Índice de Disrupção em Redes de Similaridade Não-Ponderadas	84
A.1	Construção da Rede de Similaridades	85
A.2	Características da Rede de Similaridades	86
A.3	Análise das Disrupções	89
A.3.1	Músicas Mais Disruptivas	89
A.3.2	A Disrupção ao Longo dos Anos	91
A.4	Considerações Finais	94
B	30 Músicas Mais Disruptivas de Acordo com o Índice de Disrupção	97
C	30 Artistas Mais Disruptivos de Acordo com o Índice de Disrupção	99
D	30 Álbuns Mais Disruptivos de Acordo com o Índice de Disrupção	101

Lista de Símbolos

BPM - Batidas por Minuto

CSV - *Comma-Separated-Values*

DOM - Document Object Model

GEXF - *Graph Exchange XML Format*

HTML - *HyperText Markup Language*

LP - *Long Play*

MFCC - *Mel-frequency Cepstral Coefficients*

MIR - *Music Information Retrieval*

ML - *Machine Learning*

MP3 - *MPEG-1/2 Audio Layer 3*

RBF - *Radial Basis Function*

Lista de Figuras

- 1.1 Linha do tempo com eventos que se destacaram durante a trajetória deste doutorado. Anotações em vermelho se referem a *milestones* importantes da pesquisa, enquanto que textos em verde e azul indicam artigos publicados ou que tiveram notáveis contribuições no desenvolvimento dessa pesquisa, respectivamente. 6
- 2.1 Representação gráfica das relações disruptivas de influência dos *Ramones*, de acordo com o *AllMusic*. Em vermelho são dispostos os artistas que precederam e influenciaram o nó focal (em verde). Em roxo são listados os artistas que sucederam e foram influenciados pelo nó focal. 14
- 2.2 Representação gráfica das relações consolidadoras de influência do *Green Day*, de acordo com o *AllMusic*. Em vermelho são dispostos os artistas que precederam e influenciaram o nó focal (em verde). Em roxo são listados os artistas que sucederam e foram influenciados pelo nó focal. Setas com opacidade reduzida indicam influências com predecessores do nó focal. . . 14
- 2.3 Exemplo de rede de influências entre artistas. Em verde, no centro, temos o nó focal. Em vermelho os nós que antecederam cronologicamente o mesmo. Os demais nós (à direita do nó focal) são exemplificações de influências do tipo i (*Smash Mouth*), j (*blink-182*) e k (*Arctic Monkeys*). 15
- 2.4 Exemplificação gráfica de uma relação de influência do tipo i , de acordo com as novas definições para o índice de ruptura, tomando $LIMIAR = 0.1$. Nesse caso, como média dos pesos das arestas entre o sucessor e os predecessores é igual a aproximadamente 0,33, $diff(f, s) > LIMIAR$. . 18

2.5	Exemplificação gráfica de uma relação de influência do tipo j , de acordo com as novas definições para o índice de disrupção, tomando $LIMIAR = 0.1$. Nesse caso, como média dos pesos das arestas entre o sucessor e os predecessores é igual a 0,61, $-LIMIAR \leq diff(f, s) \leq LIMIAR$	18
2.6	Exemplificação gráfica de uma relação de influência do tipo k , de acordo com as novas definições para o índice de disrupção, tomando $LIMIAR = 0.1$. Nesse caso, como média dos pesos das arestas entre o sucessor e os predecessores é igual a aproximadamente 0,65, $diff(f, s) < -LIMIAR$	19
2.7	Exemplo de <i>waveform</i> (forma de onda) extraída para um trecho da música <i>Asa Branca</i> , de Luiz Gonzaga. Representação extraída com o auxílio da biblioteca Librosa.	21
2.8	Exemplo de arquitetura de um <i>autoencoder</i> . As etapas de achatamento (<i>flattening</i>) e redimensionamento (<i>reshape</i>) são operações complementares aplicadas pela rede neural.	23
3.1	Sequência de etapas que resultaram na construção do <i>Dataset Forró em Vinil</i>	26
3.2	Histograma do número de álbuns ao longo das décadas, originalmente e após cada uma das etapas de correção.	32
3.3	Histograma do número de músicas ao longo das décadas, originalmente e após cada uma das etapas de correção.	32
4.1	Esquema gráfico da primeira etapa de validação. Para efeitos de simplificação, aqui o número de comparações intra e inter-artista está reduzidos a três. Na validação realizada o número real utilizado foi de dez comparações.	41
4.2	Intervalos de confiança para a diferença das similaridades intra e inter artista com nível de confiança de 95% para a similaridade por cosseno e similaridade RBF.	43

5.1	Rede egocêntrica simplificada para a música <i>Asa Branca</i> , de Luiz Gonzaga ($I_d = -0,49$). Ao redor do nó focal (em verde, ao centro) estão os sucessores (em roxo) e predecessores (em vermelho). Além disso, as arestas são anotadas com informações reais de similaridade fornecidas pela similaridade por cosseno. Arestas mais escuras enfatizam conexões cuja origem ou destino são o nó focal.	51
5.2	Histograma dos índices de disrupção calculados durante o experimento. . .	52
5.3	Distribuição das disrupções sumarizadas ao longo do tempo. Os intervalos representam o 5-percentil (limite inferior) e o 95 percentil (limite superior).	62
5.4	Distribuição das disrupções para os artistas mais disruptivos da primeira onda de inovação.	63
5.5	Distribuição das disrupções para os artistas responsáveis pela segunda onda de inovação.	64
5.6	Distribuição das disrupções para os artistas responsáveis pela terceira onda de inovação.	65
6.1	Página inicial da aplicação <i>web Mapa da Inovação do Forró</i>	69
6.2	Visualização de detalhamento de uma música no <i>Mapa da Inovação do Forró</i>	70
A.1	Rede egocêntrica para <i>Alô, alô, Campina Grande</i> , de Jackson do Pandeiro. Os nós que precederam e sucederam o nó focal são representados em vermelho e roxo, respectivamente.	87
A.2	Distribuição dos graus de entrada e saída da rede de similaridades.	88
A.3	Histograma dos índices de disrupção calculados pelo experimento.	93
A.4	Distribuição das disrupções sumarizadas ao longo do tempo. Os intervalos representam o 5-percentil (limite inferior) e o 95 percentil (limite superior).	94
A.5	Distribuição das disrupções sumarizadas ao longo do tempo para os seis artistas mais disruptivos do <i>Dataset Forró em Vinil</i> . Os intervalos representam o 5-percentil (limite inferior) e o 95 percentil (limite superior).	95

Lista de Tabelas

3.1	Exemplos de termos que guiaram a correção do dataset. Tanto as escritas originais (e.g., "Coletânea") quanto variações (corretas ou não - e.g., "coletânea", "coletanea", "coletania"(sic)) foram consideradas durante as filtragens.	30
3.2	Valores de perda (<i>loss</i>) apresentados pelos <i>autoencoders</i> treinados com representações latentes (códigos) de tamanhos diferentes. A linha enfatizada representa a configuração que se mostrou mais coerente durante as experimentações.	35
3.3	Exemplos de espectrogramas extraídos de representações originais e reconstruções (para a mesma música) feitas por diferentes <i>autoencoders</i> . Os dois modelos foram treinados considerando tamanhos de código distintos e ilustram a semelhança entre as reconstruções propostas.	36
4.1	Taxa de concordância apresentada por cada métrica de distância durante a primeira etapa de validação.	42
4.2	Análise descritiva das similaridades intra-artista e inter-artista obtidas durante a validação de cada métrica de similaridade.	43
5.1	Estatística descritiva realizada sobre os índices de interrupção calculados durante o experimento.	53
5.2	Cinco músicas mais disruptivas de acordo com a rede de similaridades ponderada.	54
5.3	Vinte álbuns mais disruptivos do <i>dataset</i> . Em ênfase estão os álbuns lançados na década de 1970, uma das eras mais disruptivas da história do forró.	56

5.4	Dez artistas mais disruptivos do <i>dataset</i> . A lista considera apenas artistas com mais de 30 músicas nos dados e sumariza seus índices de disrupção por meio do 95-percentil.	58
5.5	Dez artistas com mais arquivos de áudio contemplados pelo <i>Dataset Forró em Vinil</i> . Em ênfase estão alguns dos pioneiros do forró.	59
5.6	Número de músicas do <i>dataset</i> por gênero.	60
5.7	Índices de disrupção agregados por gênero.	60
5.8	Cinco artistas mulheres mais disruptivas do <i>dataset</i> . A lista considera apenas artistas com mais de 30 músicas nos dados e sumariza seus índices de disrupção por meio do 95-percentil.	61
A.1	Estatísticas da rede de similaridades construída.	88
A.2	Cinco músicas mais disruptivas de acordo com a rede de similaridades não ponderada.	90
B.1	As 30 músicas mais disruptivas do <i>Dataset Forró em Vinil</i> de acordo com o índice de disrupção.	98
C.1	Os 30 artistas mais disruptivos do <i>Dataset Forró em Vinil</i> . Os índices mostrados são as sumarizações aplicadas por meio do 95-percentil de todas as observações para cada artista.	100
D.1	Os 30 álbuns mais disruptivos do <i>Dataset Forró em Vinil</i> . Os índices mostrados são as sumarizações aplicadas por meio da média de todas as observações para cada disco.	102

Capítulo 1

Introdução

1.1 Contextualização

Iniciativas inovadoras são eventos recorrentes nas trajetórias históricas da maior parte dos gêneros musicais. O *punk rock*, por exemplo, revolucionou o tradicional *rock'n'roll* dos anos 50 e 60 em diversos aspectos [64]. O braço musical da cultura *punk* que estourou em meados da década de 1970 trouxe consigo letras pesadas e com duras críticas sociais, visuais contrastantes e despojados, e até mesmo alterações nas estruturas musicais das composições, agora bem mais agitadas e barulhentas do que aquelas propostas durante as décadas anteriores. Observou-se também que essas novas características se agregaram ao *rock* proposto até então e conseguiram se consolidar com o passar dos anos, fazendo com que bandas como *Ramones*, *The Clash* e *Sex Pistols* gradativamente influenciassem artistas mais modernos como o *Green Day*, *Blink-182* e *The Offspring*, que marcam a cena musical do *rock* até os dias de hoje.

Considerando essa dinâmica de inovação musical recorrente, diferentes artistas desempenham papéis também distintos dentro da evolução dos gêneros musicais. Tomemos como exemplo inicial os supracitados *Ramones*; a banda norte-americana formada em 1974 (i.e., no início do movimento *punk*) é descrita da seguinte forma pelo guia musical *AllMusic*¹:

The Ramones may or may not have invented punk rock, but they were inarguably the most important band in punk history, creating the stylistic prototype that

¹<https://www.allmusic.com>

would be followed by countless bands who emerged in their wake.

Tal descrição atribuí aos *Ramones* não apenas o papel inovador que sua própria colocação dentro do contexto de um gênero recém-criado sugere, mas ao mesmo tempo se aprofunda na caracterização dessa inovação. O quarteto foi responsável pela criação das fundações do *punk rock*, sem que para isso tenham sido necessariamente influenciados por artistas anteriores. Logo, os *Ramones* podem ser considerados artistas *disruptivos* dentro da trajetória musical do *rock*. Conclui-se isso com base na sua interferência dentro da trajetória do gênero, caracterizada por uma novidade nos conceitos musicais previamente consolidados e responsável pela criação de uma série de padrões inéditos que viriam a ser replicados por um grupo de artistas subsequentes.

Por outro lado, observa-se um potencial inovador de natureza distinta em uma outra banda do mesmo estilo e movimento cultural: o *Bad Religion*. A banda californiana formada em 1979 teve o tempo suficiente não apenas de assimilar e incorporar as características marcantes do estilo, como também de deixar sua própria assinatura, acrescentando novos conceitos musicais aos já existentes. Esse fato é evidenciado pelo *AllMusic* na biografia do conjunto:

“(...) Instead, the band refined its attack, adding inflections of psychedelia, heavy metal, and hard rock along the way, as well as a considerable dose of melody.”

Percebe-se que, diferentemente da movimentação disruptiva exemplificada pelos *Ramones*, o *Bad Religion* deu continuidade à evolução musical de um estilo já estabelecido, caracterizando um processo de consolidação parcial com fortes raízes em influências musicais anteriores. Pode-se dizer, por conseguinte, que o *Bad Religion* possui também aspecto inovador, porém com caráter de *consolidação*, e não mais de *disrupção*.

Tanto os artistas disruptivos quanto os consolidadores possuem importância dentro da construção da identidade musical de um determinado gênero. O artista disruptivo é aquele que muda o curso normal da evolução musical, seja inserindo uma nova instrumentação, alterando a estrutura acústica das músicas, mudando o foco da temática lírica, etc. O artista consolidador aplica sua contribuição por meio da inclusão de novos aspectos a um conjunto de práticas já estabelecido, ou até mesmo apenas mediante a replicação de tais práticas, o que mantém a identidade musical do estilo em evidência.

1.2 Problema

Muito embora seja um conceito semanticamente simples de ser exemplificado e absorvido, estudos que visam a identificação e categorização da inovação, bem como a quantificação da disrupção e consolidação, são relativamente recentes, escassos e carecem de aprimoramento. Essa constatação se torna ainda mais verdadeira em se tratando de um contexto tão complexo e cheio de especificidades, como é o caso da música. Dentre os esforços já realizados, em um estudo recente sobre o tema, Funk e Owen-Smith [23] propuseram a utilização de um índice capaz de medir o nível de disrupção ou consolidação de um determinado nó dentro de uma rede, considerando para isso suas influências anteriores e nós posteriormente influenciados pelo mesmo. Outros autores buscaram uma posterior validação do mesmo índice [77], experimentando com este em diferentes contextos.

O índice de disrupção – como também é chamado – já foi inclusive aplicado no contexto musical, durante uma análise de redes de influência derivadas de metadados curados por editores musicais do já mencionado *AllMusic* [22]. Metadados são uma fonte abundante e relevante de informações a respeito das relações entre artistas, porém são geralmente incapazes de capturar algumas dimensões importantes no contexto musical. Um exemplo de aspecto não coberto é o próprio conteúdo acústico das músicas, os quais podem trazer à análise das influências também elementos de timbre, melodia e ritmo presentes nas composições. Este trabalho busca se aprofundar definitivamente na investigação da inovação no âmbito musical, mais especificamente por meio da experimentação com o índice de disrupção em redes de similaridade derivadas diretamente da comparação dos áudios de músicas.

1.3 Objetivos

Não obstante o reconhecido potencial musicológico associado à análise da inovação no contexto musical, verifica-se que há espaço para mais exploração e aperfeiçoamento do índice proposto por Funk e Owen-Smith no sentido de quantificar a disrupção também na música. Alavancados por essa motivação, define-se então que o objetivo desta pesquisa é aprimorar a categorização e quantificação da inovação musical, trazendo essa experimentação agora para o contexto da similaridade de áudio, onde novas nuances e especificidades podem requerer

adaptações e melhorias na maneira como o cálculo original da disrupção é realizado.

A fim de atingir esse objetivo principal, os seguintes objetivos específicos são almejados:

1. Ampliar os conjuntos de dados publicamente disponíveis para o estudo de análise da inovação na criação musical ao longo do tempo, criando conjuntos de dados focados em áudio;
2. Avaliar quais representações musicais de áudio e medidas de similaridade melhor se traduzem em redes de similaridade capazes de modelar as relações entre músicas ao longo do tempo de maneira mais fiel à realidade;
3. Evoluir o cálculo original do índice de disrupção proposto por Funk e Owen-Smith, de forma que o mesmo agora também suporte redes cujas arestas possuam pesos;
4. Comprovar que o índice de disrupção é uma métrica capaz de agregar informação nova ao estudo das trajetórias musicais dos gêneros;
5. Criar uma ferramenta de navegação sobre informações de inovação musical observadas no gênero musical estudado, de maneira a facilitar as análises internas do estudo, além de tornar público e interativo o acesso aos resultados obtidos pelo mesmo.

1.4 Resultados e Contribuições

Partindo do levantamento bibliográfico realizado para este trabalho, e considerando a metodologia aplicada visando o cumprimento dos objetivos específicos, os seguintes resultados e contribuições foram alcançados, resumidamente:

- A execução das tarefas compreendidas pelo **Objetivo Específico 1** culminaram na construção e disponibilização do *Dataset Forró em Vinil*². Esse conjunto de dados é composto por *features* de áudio puras, assim como representações pós-processadas e metadados referentes a 25.605 músicas de forró obtidas, curadas e processadas durante a realização dessa pesquisa;

²<https://zenodo.org/record/5125205>

- A análise sugerida pelo **Objetivo Específico 2** comparou e definiu as melhores representações de áudio e medidas de similaridade passíveis de serem aplicáveis na construção de redes de similaridade para análise de inovação musical;
- O **Objetivo Específico 3** levou a uma reformulação no cálculo do índice de interrupção. A versão adaptada suporta redes de similaridade cujas arestas possuem pesos, e não apenas arestas simples. Esse aprimoramento expande o alcance da classe de problemas passíveis de serem resolvidos e analisados por meio da utilização do índice de interrupção;
- Os resultados obtidos durante as tarefas compreendidas pelo **Objetivo Específico 4** estão em parte descritos na seguinte publicação:

FALCÃO, F.; and ANDRADE, N.; FIGUEIREDO, F.; SILVA, D.; MORAIS, F. Measuring disruption in song similarity networks. Proceedings of the 21st International Society for Music Information Retrieval Conference. 2020. p. 30-37

- Com o objetivo de cumprir o **Objetivo Específico 5** foi desenvolvida a aplicação *web Mapa da Inovação do Forró*³. Esse sistema de informações permite que usuários naveguem sobre os dados de inovação extraídos durante essa pesquisa, ao mesmo tempo que escutam os áudios das músicas e comparam ambas as informações com as percepções individuais de cada um acerca da inovação das músicas, álbuns e artistas da base de dados.

1.5 Cronologia do Doutorado

Os caminhos que levam a um resultado final tal qual os descritos nesta tese de doutorado nem sempre são tão diretos quanto podem parecer. Esta seção busca, de maneira simplificada, resumir os diversos momentos nos quais essa pesquisa se situou, os quais sombra de dúvida tiveram influências distintas nas decisões que convergiram nos objetivos finais definidos para a pesquisa. Além disso, A Figura 1.1 esquematiza graficamente uma linha do tempo com todos esses eventos distribuídos na trajetória temporal do doutorado.

³<https://www.mapadainovacao.com>

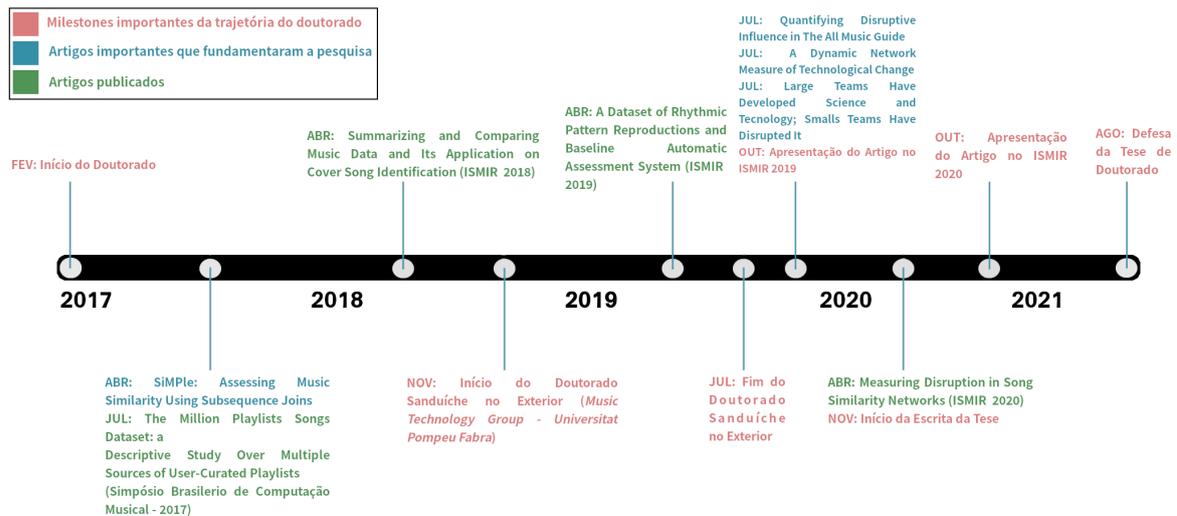


Figura 1.1: Linha do tempo com eventos que se destacaram durante a trajetória deste doutorado. Anotações em vermelho se referem a *milestones* importantes da pesquisa, enquanto que textos em verde e azul indicam artigos publicados ou que tiveram notáveis contribuições no desenvolvimento dessa pesquisa, respectivamente.

1.5.1 Prólogo: SiMPle, Python e Similaridade de Áudio

Logo nas fases iniciais de investigação e revisão sistemática tradicionais do doutorado, fui apresentado a um trabalho que propunha uma representação de dados batizada de SiMPle (acrônimo para *Similarity Matrix Profile*) [62]. O SiMPle surgiu como uma alternativa às matrizes de similaridade, estruturas comumente usadas no âmbito da computação musical em tarefas como detecção de músicas *covers*. O grande diferencial dessa nova representação era sua dimensão reduzida, em detrimento as espaços quadráticos requeridos pelas matrizes de similaridade.

Em colaboração com um dos autores do trabalho, Diego Silva, propusemos algumas otimizações à implementação original do SiMPle, compostas de sumarizações aplicadas nos áudios anteriores à execução do SiMPle propriamente dito. Esses aprimoramentos, assim como toda a discussão envolvida por seu impacto, foram publicados no artigo:

SILVA, D.; and FALCÃO, F.; ANDRADE, N. Summarizing and Comparing Music Data and Its Application on Cover Song Identification. Proceedings of the 19th International Society for Music Information Retrieval Conference. 2018. p. 732-739

Além disso, objetivos foram traçados no sentido de utilizar a representação reduzida do SiMPle em tarefas de similaridade de áudio. Para isso, entretanto, foi necessária a tradução do algoritmo para um linguagem mais familiar ao contexto deste doutorado, visto que originalmente o SiMPle é implementado em MATLAB. A conversão do algoritmo foi então realizada e os estudos propostos no tocante à similaridade de áudio foram conduzidos. Por fim, uma tentativa de submissão foi feita também na *International Society for Music Information Retrieval Conference 2018*, porém o artigo *Exploring Subsequence Joins to Learn Music Similarity for Comparative Ratings* não foi aceito naquela ocasião.

1.5.2 Sistemas de Avaliação para Padrões Rítmicos

Entre 2018 e 2019 eu passei oito meses em Barcelona para um período de doutorado sanduíche no exterior proporcionado pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - CAPES (concessão n. 88881.189929/2018-01). Durante esse período de estágio conduzi atividades de pesquisa nas instalações do *Music Technology Group* (MTG)⁴, conceituado grupo de pesquisa da área de computação musical no mundo e cujas instalações são localizadas em um dos prédio da *Universitat Pompeu Fabra* (UPF).

No MTG, em parceria com os professores Xavier Serra (UPF/MTG), Baris Bozkurt (Izmir Demokrasi University/MTG) e um determinado grupo de pesquisa do laboratório, desenvolvi atividades consistentes na avaliação automática de padrões rítmicos reproduzido por alunos em um conservatório musical na Turquia. O ciclo de pesquisa foi concluído com um novo *dataset*, composto de performances rítmicas anotadas com avaliações fornecidas por especialistas, além de um estudo comparativo de métricas passíveis de serem usadas no estudo de similaridades rítmicas, tendo essas medidas sido aplicadas em um sistema de avaliação. Todos os resultados obtidos ao final do doutorado sanduíche foram publicados no seguinte artigo:

⁴<https://www.upf.edu/web/mtg>

FALCÃO, F.; and BOZKURT, B.; and SERRA, X.; and ANDRADE, N.; and BAY-SAL, O. A Dataset of Rhythmic Pattern Reproductions and Baseline Automatic Assessment System. Proceedings of the 20th International Society for Music Information Retrieval Conference. 2019. p. 439-445

A experimentação com métricas de distância entre vetores, realizada durante esse trabalho, foi de grande utilidade durante uma etapa desta investigação em questão, conforme será visto mais adiante.

1.5.3 Qualificação: Índice de Disrupção e Transferência de Aprendizagem

Ao final do doutorado sanduíche, foi realizado um replanejamento com o intuito de escolher definitivamente a linha de pesquisa que seria seguida até o final do doutorado. A sugestão de um estudo sobre o índice de disrupção surgiu a partir de experiências anteriores de alguns membros envolvidos na pesquisa, e rapidamente foi absorvido para investigações complementares que culminam nessa tese.

Em uma primeira proposta de investigação, cujas bases são análogas às que serão detalhadas a seguir, procedeu-se com a coleta do mesmo conjunto de dados que é tratado nesta pesquisa. Já as *features* de áudio manipuladas diferiam completamente, sendo estas nesse momento baseadas em um *autoencoder* treinado por outros pesquisadores em uma outra tarefa de classificação [13]. A reutilização desse *autoencoder* sobre nosso conjunto de dados apenas foi possível por conta das bases teóricas da transferência de aprendizagem. Esse conceito defende que os pesos dos parâmetros obtidos mediante treinamento de modelos de classificação e regressão para determinadas tarefas podem ser seguramente generalizados para contextos similares.

Portanto, fazendo uso das representações do *autoencoder* de Choi em conjunto com a medida de similaridade RBF (que será detalhada mais à frente nesse estudo), a qualificação desse doutorado propôs a construção de uma rede de similaridades não ponderada. Essa rede, por sua vez, deu suporte a algumas análises preliminares envolvendo o índice de disrupção e elencou alguns aprimoramentos que poderiam ser aplicados, alguns dos quais estão presentes na versão final desta tese. Toda essa discussão inicial conduzida na qualificação do doutorado

está, em partes, documentada no Apêndice A.

1.5.4 *Autoencoders*, Métricas de Similaridade e Redes Não Ponderadas

A última fase do doutorado se iniciou com todas as sugestões recebidas durante o exame de qualificação do doutorado. Além disso, alguns meses depois desse momento, o artigo *Measuring disruption in song similarity networks* foi aceito e apresentado em conferência, e mais uma série de eventuais melhorias foram apontadas para aprimorar ainda mais os resultados obtidos.

Como será amplamente debatido adiante, a metodologia experimental foi ajustada, mudando desde as representações das músicas que eram comparadas até a métrica de distância que era utilizada para derivar as informações de similaridade. Além disso, essa etapa do doutorado deu espaço para o surgimento de uma reformulação no cálculo original do índice de disrupção, enriquecendo ainda mais os resultados entregues pelo estudo.

1.6 Organização do Documento

Este documento segue didaticamente dividido em sete capítulos e um apêndice. No Capítulo 2 será apresentado todo o ferramental teórico no qual esta investigação se sustenta a fim de alcançar os objetivos definidos. Nele é introduzido e explicado o conceito de disrupção, além de aplicações deste no contexto da música e aprimoramentos realizados sobre o mesmo no âmbito deste estudo. Também são listados exemplos de corpora de áudio que auxiliaram na construção de uma base de dados própria responsável por alimentar nossa análise. Além disso, são detalhadas as técnicas de extração de *features* de áudio às quais esses dados foram submetidos a fim de se converterem as informações puras em representações úteis que pudessem ser processadas pelo nosso estudo. Continuando, comentários são tecidos a respeito da utilidade e funcionamento de um tipo especial de redes neurais: os *autoencoders*, uma vez que esses são extremamente úteis em uma das etapas de pós-processamento do *dataset* montado. Por fim, disserta-se a respeito da similaridade musical derivada de áudio, um dos conceitos chave dessa pesquisa.

O Capítulo 3 apresenta todas as etapas envolvidas na construção de um conjunto de dados exclusivamente idealizado para esta investigação: o *Dataset Forró em Vinil*. Todos os

procedimentos de coleta, correção, extração e pós-processamento são devidamente explicados nesse momento, deixando claro sobre qual estrutura de dados a análise posterior seria realizada.

Modelagem de similaridade musical também desempenha um papel importante dentro da pesquisa, sendo ele explorado no Capítulo 4. Aqui, são levantadas algumas métricas de distância passíveis de serem utilizadas sobre as representações do *dataset* com o intuito de se obterem informações de similaridade. Também é descrito como essas métricas foram submetidas a duas etapas de validação que culminaram na seleção daquela mais eficiente designada à modelagem de similaridade musical.

O Capítulo 5 discorre a respeito de toda a experimentação feita com o índice de disrupção em uma rede de similaridades ponderada, algo inédito no estudo do índice até o momento. Além de todas as definições que resultaram na construção da rede, discussões de diversas naturezas são levantadas a partir dos índices de disrupção extraídos dos nós da rede.

O Capítulo 6 especifica uma aplicação *web* implementada também no âmbito desta pesquisa e que auxiliou na interpretação dos resultados: o *Mapa da Inovação do Forró*.

Finalmente, no Capítulo 7 é sugerido um resumo de tudo aquilo discutido até aquele momento, assim como algumas limitações levantadas durante o desenvolvimento da pesquisa e trabalhos futuros que podem ajudar a mitigar essas lacunas.

De maneira complementar, o Apêndice A trata de uma experimentação preliminar feita sobre o estudo da disrupção em redes de similaridade. A grande diferença entre esse estudo e aquele conduzido no Capítulo 5 é a natureza da rede de similaridades construída: enquanto que no experimento já mencionado tratamos de uma rede de similaridades ponderada, esta investigação inicial se fez sobre uma rede cujas arestas não possuíam pesos. Algumas discussões e sugestões levantadas após o desenvolvimento desse primeiro teste levaram a aprimoramentos e a uma necessidade de reexecução do experimento. Por último, os Apêndices B, C e D detalham as listagens de músicas, artistas e álbuns mais disruptivos do *Dataset Forró em Vinil* de acordo com os índices de disrupção extraídos durante o experimento descrito no Capítulo 5.

Capítulo 2

Fundamentação Teórica e Trabalhos Relacionados

2.1 Disrupção

2.1.1 Conceito

Do ponto de vista léxico, o termo disrupção está associado ao ato ou efeito de gerar uma quebra em um curso normal de um processo¹, deslocando a trajetória vigente. Apesar de seu significado gramatical, o tratamento da disrupção como temática central na literatura de negócios data de um passado recente, quando mais especificamente em meados da década de 1990 a indústria atentou para a importância de se analisar o impacto de tecnologias capazes de mudar a estrutura tradicional do mercado, abalando práticas de negócio já estabelecidas. A *disruptive innovation/technology* (inovação/tecnologia disruptiva), como foi batizada [8], é classificada como capaz de criar novos nichos de mercado, além requerer uma rápida adaptação por parte de grandes empresas a fim de se encaixarem nas novas diretrizes criadas pelo seu surgimento, o que nem sempre ocorre. Exemplos de falhas na assimilação de tecnologias disruptivas são as entradas tardias da IBM e Apple no mercado de computadores pessoais e portáteis (tecnologias disruptivas), respectivamente.

Seguindo a mesma tendência da indústria, o interesse científico na análise da disrupção

¹Dicionário Michaelis *On-line*: <https://michaelis.uol.com.br/moderno-portugues/busca/portugues-brasileiro/disrupção>. Acessado em 8 de Julho de 2021 às 22:17

também permanecia adormecido até poucos anos atrás, quando diversos estudos sobre a disrupção derivada de redes de influência alavancaram conclusões distintas acerca do efeito de diferentes variáveis externas sobre o tipo de influência exercida pelas entidades dentro das redes. Funk e Owen-Smith [23] foram precursores na análise da disrupção como uma métrica de redes, desenvolvendo em seu trabalho relevantes índices capazes de quantificar o nível de desestabilização ou consolidação de pesquisas científicas universitárias perante o *status quo* de cada área. Wu, Wang e Evans [77] logo expandiram o estudo anterior, simplificando a lógica matemática envolvida no cálculo de agora um único índice de disrupção. A validação do estudo, entretanto, foi feita mediante a aplicação de uma metodologia análoga à sugerida previamente, porém usando artigos científicos e patentes de *software* como fonte de dados para suas redes de influência.

Um estudo também similar foi posteriormente proposto, agora no contexto musical, quando Figueiredo e Andrade [22] visaram a validação do índice de disrupção dentro do âmbito musical. Para tal, construíram uma rede de influências alimentada com informações da base de dados virtual *AllMusic*, o que permitiu então o cálculo do índice de disrupção para cada nó da rede. Indo além, a pesquisa conseguiu concluir não somente que o índice de disrupção agrega informação semântica e descritiva às redes de influência, como também traduz uma medida dificilmente derivável a partir de outras métricas topológicas do grafo, o que torna o índice singular naquilo que se propõe a fazer (ao menos no contexto musical).

Em comum, o que esses três trabalhos anteriores defendem é o fato de que a aplicação do índice de disrupção em diferentes contextos pode ser de grande utilidade. Esse benefício fornecido pela métrica pode ser explicado tanto pela revelação de novos padrões comportamentais [22] quando na clarificação de discussões controversas como, por exemplo, os benefícios do investimento comercial na área de pesquisas universitárias [23]. Entretanto, existe também um certo consenso de que, por se tratar de uma proposição relativamente recente, o índice carece de uma validação um pouco mais cuidadosa dentro desses novos contextos, visto que cada um deles possui suas próprias idiossincrasias que podem requerer ajustes na maneira que a abordagem é utilizada.

A interpretação das disrupções existentes no âmbito musical, entretanto, demonstra ser uma tarefa com certo grau de complexidade atrelado. Isso porque a natureza multifacetada da música [46] torna difícil isolar quais aspectos são os responsáveis por eventuais altos ní-

veis de disrupção apresentados por músicas e artistas, por exemplo. Características como a letra, a apresentação dos artistas – bem como suas atitudes – e até mesmo o conteúdo acústico das composições podem carregar consigo as razões pelas quais esses envolvidos foram disruptivos dentro da trajetória histórica. É importante, portanto, a aplicação de esforços no sentido de isolar esses fatores musicológicos na tentativa de explicar ainda mais a origem das altas disrupções, algo que também foi objetivado nesta investigação.

2.1.2 Índice de Disrupção em Redes Não Ponderadas

Considerando uma rede de influências não ponderada (i.e., cujas arestas não possuem pesos), a métrica de disrupção aqui estudada parte da importante interpretação que nós disruptivos detêm maior parte da influência necessária para a continuidade da linha criativa exercida por si. Considerando esse fato, o índice de disrupção foi originalmente modelado com o intuito de caracterizar como os nós cronologicamente posteriores a um nó focal se relacionam com as influências anteriores ao mesmo.

Exemplificando com o mesmo paralelo dos *Ramones vs. Bad Religion* descrito no Capítulo 1: por serem notadamente disruptivos, os *Ramones* fazem com que os artistas influenciados por si (e.g., *Green Day*, de acordo com *AllMusic*) não se relacionem com seus predecessores. Isso porque toda (ou quase toda) a influência necessária para executar o *punk rock* vem do próprio nó focal, e não de suas influências. Essa constatação, representada graficamente na Figura 2.1, caracteriza o quarteto como disruptivo.

Já o comportamento consolidador do *Green Day*, cujo contexto inovador é análogo ao do *Bad Religion*, igualmente explicado no Capítulo 1, também é traduzido aqui pela lógica por trás do índice de disrupção (Figura 2.2): o mesmo *Yellowcard*, que também é influenciado por esse nó focal, possui simultaneamente uma forte relação com as influências do próprio *Green Day* (e.g. os próprios *Ramones*), o que mostra que nesse caso tanto o nó focal quanto seus próprios predecessores exercem influência simultânea sobre os sucessores daquele, demonstrando mais uma vez a natureza consolidadora do *Green Day*.

A formalização mais didática do índice de disrupção [22] toma como ponto de partida um nó focal a qualquer e os nós que o precederam e sucederam, assim como suas relações de influência - exemplificadas na Figura 2.3 na forma de arestas direcionadas. Tomemos como n_i o número de nós cronologicamente posteriores a a que referenciam a mas nenhum de seus

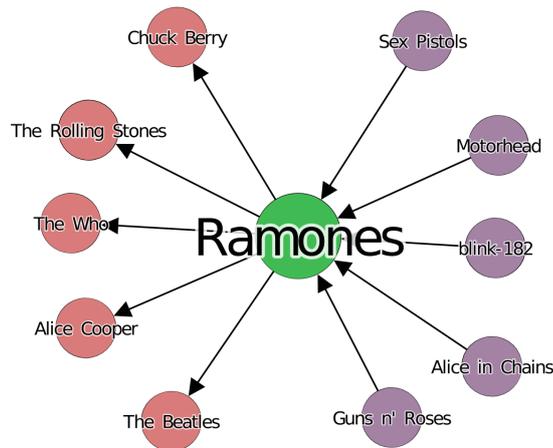


Figura 2.1: Representação gráfica das relações disruptivas de influência dos *Ramones*, de acordo com o *AllMusic*. Em vermelho são dispostos os artistas que precederam e influenciaram o nó focal (em verde). Em roxo são listados os artistas que sucederam e foram influenciados pelo nó focal.

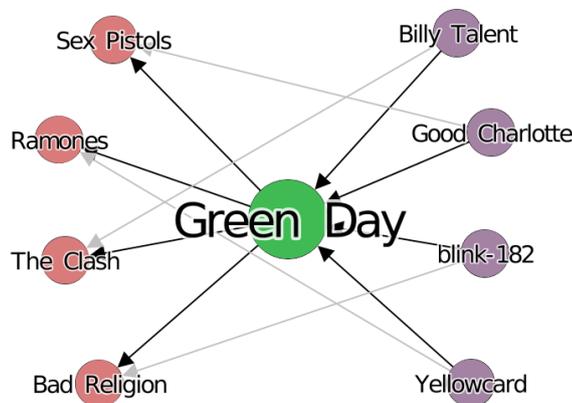


Figura 2.2: Representação gráfica das relações consolidadoras de influência do *Green Day*, de acordo com o *AllMusic*. Em vermelho são dispostos os artistas que precederam e influenciaram o nó focal (em verde). Em roxo são listados os artistas que sucederam e foram influenciados pelo nó focal. Setas com opacidade reduzida indicam influências com predecessores do nó focal.

predecessores (tipo i : *Smash Mouth*, no exemplo), n_j o número de nós que referenciam a e pelo menos um de seus predecessores (tipo j : *blink-182*), e n_k o número de nós que referenciam pelo menos um dos predecessores de a , mas não o mesmo (tipo k : *Arctic Monkey*). O índice de disrupção I_d é então calculado pela Equação 2.1:

$$I_d = \frac{(n_i - n_j)}{(n_i + n_j + n_k)} \quad (2.1)$$

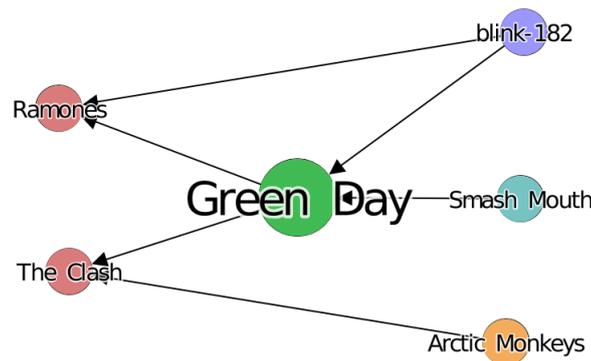


Figura 2.3: Exemplo de rede de influências entre artistas. Em verde, no centro, temos o nó focal. Em vermelho os nós que antecederam cronologicamente o mesmo. Os demais nós (à direita do nó focal) são exemplificações de influências do tipo i (*Smash Mouth*), j (*blink-182*) e k (*Arctic Monkeys*).

Os valores atrelados a esse índice compreendem o intervalo de -1 a 1, com os extremos indicando nós completamente consolidadores (i.e. $n_i = 0$ e $n_j = 0$) e nós completamente disruptivos (i.e., $n_j = 0$ e $n_k = 0$), respectivamente.

2.1.3 Índice de Disrupção em Redes Ponderadas

Não obstante a sua aplicabilidade já demonstrada anteriormente em outros contextos, esta investigação eventualmente observou algumas limitações no uso do índice de disrupção. Em especial, verificou-se que a utilização do índice em redes ponderadas (i.e., cujas arestas possuem pesos) requeriam pré-processamentos visando a conversão da rede em um grafo não ponderado. O Apêndice A trata de uma experimentação consistente em um desses esforços, e chega à conclusão que uma adaptação do cálculo da disrupção, tornando o mesmo capaz

de atuar sobre redes não ponderadas, se fazia necessário.

Diferentemente das relações binárias de influência apresentadas pelas redes não ponderadas, em uma rede de influência ponderada essas conexões são anotadas com pesos indicando suas intensidades. Em outras palavras, trazendo para o contexto do nó focal já ilustrado anteriormente, isso implica em dizer que todos os sucessores de um nó focal estariam conectados ao mesmo por meio de uma aresta ponderada. Essa característica por si só já invalida a aplicação do cálculo tradicional do índice de disrupção, pois nesse cenário não é possível usar apenas as existências das arestas para derivar as influências do tipo i , j e k . Caso isso fosse feito, todos os sucessores seriam do tipo j , pois estariam sempre conectados tanto ao nó focal quanto aos seus predecessores, fazendo com que todos os nós tivessem sempre $I_d = -1$ ($n_i = 0$ e $n_k = 0$).

Uma nova proposição para índice de disrupção precisou então considerar não somente a existência das arestas, mas também seus pesos, na determinação de quais seriam os sucessores do tipo i , j ou k . Para definir como derivar cada um desses tipos de influência, foi necessário revisitar as semânticas de cada um deles, já ilustradas na Figura 2.3. Sucessores do tipo i têm uma relação de influência exclusiva com nó focal, enquanto que sucessores do tipo j se conectam simultaneamente com o nó focal e com os predecessores do mesmo. Já os nós sucessores do tipo k não se associam ao nó focal, apenas aos seus predecessores. Recapituladas essas definições, o próximo passo foi mapear essas semânticas em algo que pudesse ser quantificado pelos níveis de influências (i.e., pesos) codificados nas arestas entre os sucessores e o nó focal. Nesse sentido, a estratégia encontrada para definir o quão exclusiva é a influência de um nó focal sobre um sucessor foi observar a diferença entre o peso do sucessor com o nó focal e do sucessor com todos os predecessores do nó focal. A premissa por trás desse raciocínio é que a influência que se sobressai para o sucessor é a que possui maior intensidade, seja a do nó focal, a dos predecessores dele ou ambas.

Nós sucessores do tipo i possuem uma relação de influência forte e exclusiva com o nó focal, logo a diferença entre as influências precisa ser tanto positiva quanto alta a fim de caracterizar uma associação desse tipo. A definição do quão alto essa diferença deveria ser, mais uma vez, dependeu da escolha de um limiar de segurança, que será discutido mais adiante. Nós do tipo j são caracterizados por uma diferença mais próxima de zero, porém não muito baixa, uma vez que diferenças mais baixas caracterizam o nó como do tipo k .

Essa nova estratégia nos leva às seguintes definições: tomemos como f um determinado nó focal, cujos predecessores fazem parte do conjunto P . A fim de derivar o tipo de influência exercida por f sobre um sucessor s , consideremos a diferença discutida acima sob a seguinte a seguinte notação:

$$diff(s, f) = peso(s, f) - \left(\frac{\sum peso(s, p') \forall p' \in P}{|P|} \right) \quad (2.2)$$

A definição do tipo da influência exercida por f sobre s é então dada pelo seguinte equação:

$$tipo(f, s) = \begin{cases} i, & \text{se } diff(s, f) > LIMIAR \\ j, & \text{se } -LIMIAR \leq diff(s, f) \leq LIMIAR \\ k, & \text{se } diff(s, f) < -LIMIAR \end{cases} \quad (2.3)$$

As Figuras 2.4, 2.5 e 2.6 esquematizam o cálculo empregado acima, exemplificando graficamente nós sucessores dos tipos i , j e k , respectivamente. Reforça-se que um dos grandes benefícios do emprego dessa estratégia durante a reformulação do índice de disrupção é a manutenção do cálculo original proposto pelos autores da métrica (Equação 2.1). Isso somente foi possível porque os valores de n_i , n_j e n_k necessários ao seu cálculo foram mantidos, tendo sido alterada apenas a forma com a qual esses são derivados.

2.2 Corpora de Áudio

Fontes de dados confiáveis desempenham um papel fundamental em tarefas de recuperação de informações musicais (ou, do inglês, *Music Information Retrieval* - MIR). Recorrentemente encontramos na literatura menções ao *Million Song Dataset* (MSD) [5]², seja no contexto de recomendação [72; 1], classificação [12; 41], agrupamento [4], dentre outros vários. Como o próprio o nome sugere, O MSD é uma coleção de metadados e *features* precomputadas para um milhão de músicas contemporâneas, incluindo nos seus atributos conexões para outros sistemas relacionados à música, como os correlacionados MusicBrainz³

²<http://millionsongdataset.com>

³<https://musicbrainz.org>

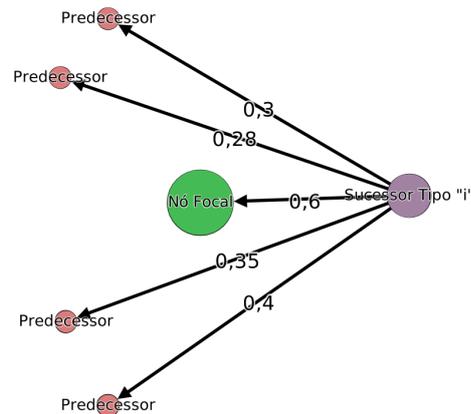


Figura 2.4: Exemplificação gráfica de uma relação de influência do tipo i , de acordo com as novas definições para o índice de interrupção, tomando $LIMIAR = 0.1$. Nesse caso, como média dos pesos das arestas entre o sucessor e os predecessores é igual a aproximadamente 0,33, $diff(f, s) > LIM IAR$.

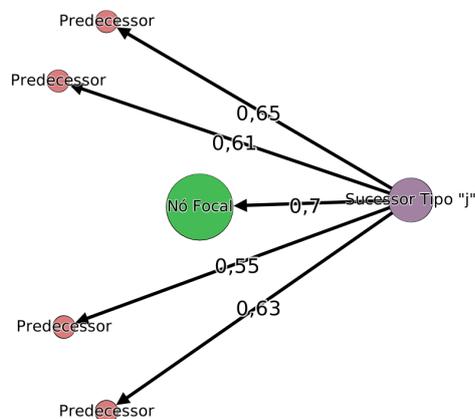


Figura 2.5: Exemplificação gráfica de uma relação de influência do tipo j , de acordo com as novas definições para o índice de interrupção, tomando $LIMIAR = 0.1$. Nesse caso, como média dos pesos das arestas entre o sucessor e os predecessores é igual a 0,61, $-LIMIAR \leq diff(f, s) \leq LIM IAR$.

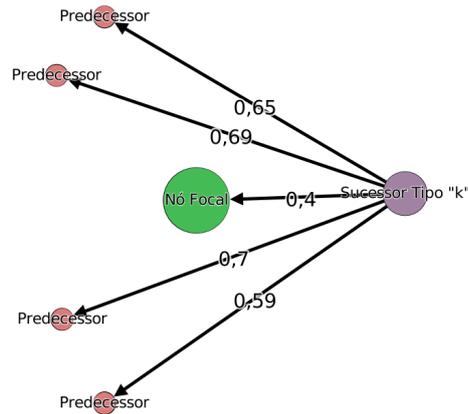


Figura 2.6: Exemplificação gráfica de uma relação de influência do tipo k , de acordo com as novas definições para o índice de interrupção, tomando $LIMIAR = 0.1$. Nesse caso, como média dos pesos das arestas entre o sucessor e os predecessores é igual a aproximadamente 0,65, $diff(f, s) < -LIMIAR$.

e AcousticBrainz⁴, fato esse que estende ainda mais a gama de informações disponíveis para as músicas da coleção. Até mesmo estudos responsáveis por análises descritivas da inovação musical ao longo do tempo [61] alavancaram também do MSD. Mediante a criação de um modelo de tópicos alimentado por seus dados, foi-se possível avaliar a relação entre inovação e influência musical em artistas e músicas dos *charts* da *Billboard*, famosa revista norte-americana especializada na indústria da música.

Diferentemente do MSD, O *MagnaTagATune Dataset* [39] é uma base de dados com áudio também disponibilizado e que tem sido amplamente utilizado principalmente por estudos na área de *auto-tagging*. O *dataset* possui mais de 25 mil trechos de áudio de cerca de 30 segundos, com gêneros variando da música clássica ao *heavy metal*. Os arquivos de áudio são publicados com informações de *tags* obtidas diretamente de pessoas que participaram do jogo *on-line TagATune*. Nele, dois jogadores eram apresentados a um mesmo áudio, e ambos tinham que informar *tags* para esses áudios. No final da rodada, eles tinham acesso às *tags* do outro jogador e precisavam decidir se ambos haviam sido apresentados à mesma música ou não, marcando pontos em caso de concordância. Anotações como “*singer*”, “*no singer*”, “*drums*”, “*classical*”, etc. estão espalha-

⁴<https://acousticbrainz.org>

dos por todo o conjunto de dados e são recorrentemente usados na alimentação de sistemas que visam a detecção automática de *tags* em sistemas de aprendizagem de máquina [53; 11]. Um subconjunto menos conhecido dessa base dados também torna público informações relativas a restrições de similaridade no formato de triplas (x, y, z) na qual existe uma ordem de similaridade que também foi anotada por pessoas durante uma rodada bônus do *TagATune*.

Outro grande esforço empregado na disponibilização de *datasets* de áudio é condensado na plataforma Dunya [54]. Em seu website ⁵ são listadas dezenas de coleções musicais advindas de nichos culturais específicos e curados durante atividades de pesquisa sediadas na *Universitat Pompeu Fabra* (Barcelona), que possui um dos grandes centros de pesquisa do mundo sobre computação musical. *Hindustani*, *Carnatic*, *Beijing Opera* e *Arab-Andalusian* figuram dentre as culturas musicais cujos conteúdos de áudio podem ser encontrados e manipulados fazendo-se uso de operações e filtros específicos de cada contexto cultural. Tanto os áudios quanto metadados atrelados a estes são disponibilizados mediante registro, tendo sido usados frequentemente em tarefas de MIR [60; 71].

Especificamente relativo à música ocidental, a *Billboard* também foi a fonte escolhida na tentativa de analisar a evolução da música popular americana nas seis décadas anteriores a 2010. Aqui [45], diferentemente das abordagens anteriores, os pesquisadores analisaram diretamente trechos de 30 segundos para 17.084 músicas, extraindo das mesmas *features* de harmonia, timbre e tonalidade, as quais foram usadas na comparação de tendências de cada época. Tal análise evidenciou três disrupções nas tendências musicais ao longo desse tempo: uma em 1964, uma em 1983 e a mais recente em 1991. Esse trabalho em particular aponta para a utilidade de se conduzirem as etapas de extração de *features* a partir do próprio áudio, em detrimento à reutilização de informações computadas anteriormente e disponibilizadas por ferramentas de terceiros.

⁵<https://dunya.compmusic.upf.edu>

2.3 Features de áudio

O som que escutamos é resultado de ondas de pressão que se propagam por um determinado meio, normalmente o próprio ar. A voz de duas pessoas conversando nasce nas vibrações das cordas vocais de uma e é transmitida pelo meio até atingir o ouvido da outra, onde existem receptores específicos que traduzem essas vibrações em impulsos nervosos que são interpretados pelos nossos cérebros. Como toda onda, o som possui frequência (o quão rápido ela vibra) e amplitude (a magnitude das vibrações). Quando digitalizamos um áudio, estamos na maior parte do tempo aplicando um processo chamado *sampling* que discretiza o sinal do som (que é contínuo por natureza) por meio da amostragem de valores de amplitude para pequenas janelas de tempo do sinal. Esse procedimento resulta na representação digital mais comum de um áudio: o *waveform* (ou forma de onda), exemplificado graficamente na Figura 2.7.

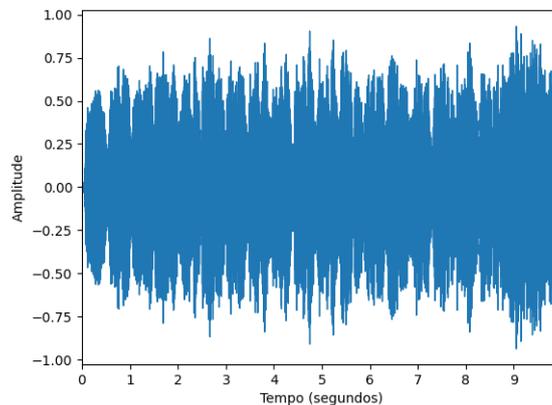


Figura 2.7: Exemplo de *waveform* (forma de onda) extraída para um trecho da música *Asa Branca*, de Luiz Gonzaga. Representação extraída com o auxílio da biblioteca Librosa.

A partir do *waveform* podem ser derivadas diversas características do áudio, e por conta disso essa representação é utilizada por diversos *frameworks* de processamento de áudio para, em conjunto com a Transformada de Fourier (ou sua versão simplificada: a Transformada Rápida de Fourier) [56; 67], extrair várias *features* de áudio, cada uma com natureza distinta e cobrindo diferentes aspectos de áudio. Existem *features* de áudio que modelam a melodia dos áudios (e.g., *chroma features* [19; 20; 58; 62]), *features* que detectam eventos rítmicos (e.g.,

onset features [18; 36; 21; 33]) e até mesmo representações capazes de sumarizar aspectos de timbre dos áudios, como é o caso dos *Mel-frequency Cepstral Coefficients* (MFCCs), que veremos mais a fundo na próxima seção.

2.3.1 *Mel-frequency Cepstral Coefficients* (MFCCs)

Os MFCCs são *features* de áudio originalmente criadas para tarefas de reconhecimento de voz [49; 30], mas que devido à sua reconhecida robustez em outros contextos passaram a ser amplamente utilizadas em uma gama de outras tarefas, como classificação de gênero e humor [37; 57], cálculo de similaridade de áudio [14; 34], identificação de instrumentos [50], dentre outras. Seu funcionamento geral parte do princípio básico que a percepção do ouvido humano no tocante a conteúdos de frequência não segue uma escala linear (i.e., um som com frequência $2x$ não “soa” duas vezes mais agudo que um som com frequência x). Para corrigir isso, cria-se a noção de uma escala especial, denominada escala mel, que passa a distribuir essas faixas de frequências em uma ordem que condiz mais fielmente com nossas percepções [69].

As extrações de MFCCs são capazes de, ao final do processo, obter uma série de coeficientes que expõem a amplitude do sinal do áudio em cada uma das diferentes bandas mel, isto é, cada uma das bandas de frequência distintas que o ouvido humano pode detectar. Isso é de fundamental importância em tarefas que exigem a detecção de sons específicos, fato esse que se torna ainda mais evidente na música, que possui uma infinidade de instrumentos, cada um capaz de emitir sinais sonoros em bandas de frequência bem específicas. Nesse cenário, a habilidade de distinguir as magnitudes de cada banda de frequência se torna fundamental em tarefas como a detecção ou não de um determinado instrumento em uma performance musical, ou a pronuncia ou não de uma palavra em uma determinada frase.

2.4 *Autoencoders*

Nos últimos anos as redes neurais revolucionaram o domínio das aplicações de aprendizagem de máquina, se tornando peça-chave no mecanismo preditivo de muitos sistemas. Tais modelos podem ser classificados de acordo com o tipo de conjunto de dados utilizados durante a etapa de treinamento. Enquanto as redes neurais supervisionadas requerem um

subconjunto de dados previamente rotulados a fim de que sejam corretamente modeladas no intuito de prever os rótulos de novas entradas, na aprendizagem não supervisionada esse subconjunto não necessário. Isso acontece porque o objetivo de uma rede neural não supervisionada difere conceitualmente daquele de um modelo treinado via aprendizagem supervisionada. Enquanto que neste visa-se geralmente a classificação ou a regressão, por exemplo, na aprendizagem não supervisionada o objetivo é derivar representações da entrada que possam ser mais eficientemente usadas no processo de tomada de decisão [25]. Por conta disso, abordagens não supervisionadas são recorrentemente associadas à resolução de problemas que envolvem clusterização [17; 24], redução de dimensionalidade [31; 38] e de ruído [3; 2; 7], aprendizagem de representação [26; 40], dentre outros.

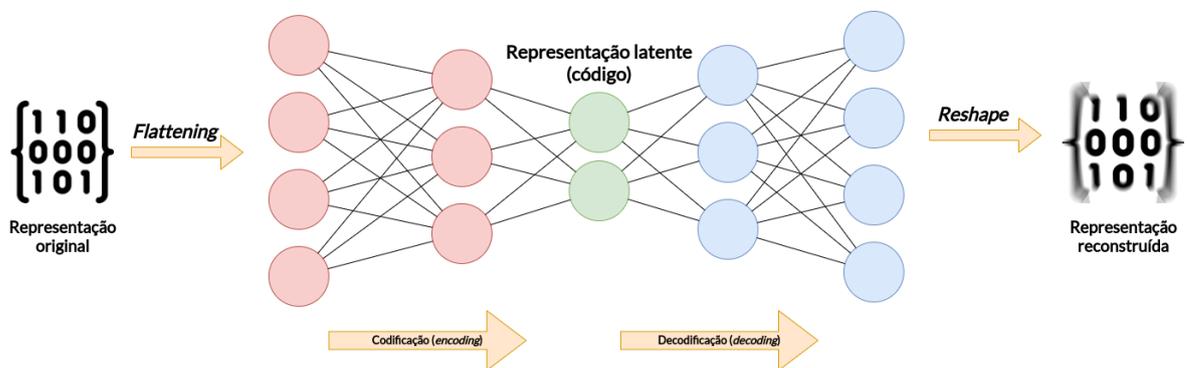


Figura 2.8: Exemplo de arquitetura de um *autoencoder*. As etapas de achatamento (*flattening*) e redimensionamento (*reshape*) são operações complementares aplicadas pela rede neural.

Autoencoders são exemplos clássicos de redes neurais não supervisionadas, com a peculiaridade de que aqui o principal objetivo é copiar a suas entradas nas suas saídas, gerando uma representação simplificada do *input* durante esse processo. A arquitetura de qualquer *autoencoder* tradicional, esquematizada graficamente na Figura 2.8, é dividida entre dois componentes: o processo de codificação (*encoding*), realizado pelo codificador (*encoder*) e que consiste na conversão da entrada original em uma representação de estado latente (ou código) com tamanho reduzido; e a decodificação (*decoding*), baseada em um processo de engenharia reversa realizado pelo decodificador (*decoder*) que busca reconstruir a informação original partindo apenas do código que foi gerado na fase intermediária do *autoencoder*.

Por conta do potencial de compactação do codificador no momento da criação do có-

digo, os *autoencoders* são normalmente utilizados em problemas que envolvem redução de dimensionalidade. Ademais, uma vez que a modelagem do código também visa apenas a manutenção das informações absolutamente cruciais ao dado original - e isso é necessário a fim de assegurar a compactação do código, ele acaba naturalmente ignorando possíveis ruídos desse dado de entrada. Isso acaba refletindo nas reconstruções criadas pelos decodificadores, e resultado disso são versões dos dados sem ruído, o que se torna uma propriedade extremamente útil, em especial no campo de processamento digital de imagens [51; 10; 27].

2.5 Similaridade de Áudio

Similaridade musical não é uma temática nova, passando a ser recorrentemente debatida principalmente a partir do momento que o advento do *MPEG-1/2 Audio Layer 3* (MP3) e outros algoritmos de compressão digital mudaram o mundo da distribuição musical, tornando a música um conteúdo ubíquo na vida das pessoas [44]. Desde então, o que se tem visto é uma corrida em busca de algoritmos e modelos que melhor caracterizem relações de similaridade entre músicas, artistas, álbuns, *playlists*, etc. De uma forma geral, essas informações são especialmente cruciais na alimentação de sistemas de recomendação, os quais desempenham papel importante nas receitas de plataformas de *streaming* como *Spotify*, *Deezer*, *Apple Music*, dentre outros.

Existem na literatura alguns tipos diferentes de abordagens cujos intuítos são modelar o quão parecidas músicas, álbuns ou artistas são dentro do contexto musical. A filtragem colaborativa [6; 68; 32], por exemplo, apesar de originalmente se tratar de um algoritmo de sistemas de recomendação, é uma técnica regularmente utilizada na música a fim de se quantificar o quão similares as entidades musicais são [47]. Sistemas de informação tais como o Last.fm ⁶ disponibilizam noções de similaridade derivadas mediante a análise comportamental de usuários que compartilham de hábitos musicais semelhantes.

A aprendizagem de máquina, assim como em vários outros segmentos de pesquisa, também alavancou os estudos de similaridade musical, abrindo portas para vários modelos exaustivamente treinados e capazes de classificar novas entradas de maneira extrema-

⁶<http://last.fm>

mente precisa. Diferentemente das estratégias baseadas em filtragem colaborativa, muitos desses modelos de *machine learning* (ML) já incorporam a si outros aspectos importantes da música além da questão comportamental dos usuários, como metadados [28; 75] e finalmente os conteúdos acústicos dos áudios [74; 9]. Isso os torna ainda mais robustos e capazes de identificar e sugerir similaridades com potencial de surpreender os consumidores finais.

Uma das áreas de ML investiga especificamente como comparar diferentes itens. A aprendizagem de similaridade (ou *similarity learning*) trata da descoberta de uma função de similaridade que se comporte de maneira ótima perante um certo conjunto de dados. De maneira análoga aos *autoencoders* discutidos anteriormente, esses modelos também se utilizam de técnicas de *encoding* sobre dados de entrada, ajustando as funções de similaridade sobre os códigos construídos por esses componentes. Na música, a aprendizagem de similaridade já foi aplicada tanto na identificação de músicas *covers* [35] quanto no cálculo de similaridade áudio em geral [48].

A despeito de suas reconhecidas eficácias, essas abordagens discutidas e outras de naturezas semelhantes possuem atreladas a si um considerável custo de alimentação de massivas bases de dados necessárias tanto para realizar o treinamento dos modelos inteligentes quanto para sustentar as análises comportamentais da filtragem colaborativa, por exemplo. Essa limitação pode ser exemplificada pelo problema de *cold start* apresentado pela maioria dos sistemas que se baseiam em técnicas de filtragem colaborativa [42; 59], por exemplo.

Uma alternativa para se contornar problemas semelhantes ao *cold start* é propor a comparação direta entre representações dos itens sobre os quais se deseja mensurar a similaridade, fazendo uso de métricas lineares designadas ao cálculo de distâncias entre vetores no espaço, por exemplo. No caso especial da música, uma vez que pode-se fazer a representação de uma composição como um vetor (ou um conjunto de vetores) essa abordagem se mostra de extrema valia, tendo sido inclusive utilizada em outros estudos de natureza semelhante a deste trabalho [65; 52].

Capítulo 3

Dataset Forró em Vinil

A partir de agora, define-se como meta a caracterização do *dataset* construído durante o desenvolvimento deste trabalho especialmente com objetivo de dar suporte a todas as atividades complementares ao estudo da inovação em redes de similaridade musical. As próximas seções discutirão todas as etapas componentes da construção desse *dataset*, conforme esquematizado na Figura 3.1. Serão explanados os motivos que resultaram na escolha de coletar um conjunto de dados próprio, em detrimento à reutilização de bases já existentes. Além disso, a origem das informações coletadas será devidamente detalhada, assim como as etapas que culminaram na coleta das músicas. Por fim, os processos de correção do *dataset* e extração das *features* de áudio que alimentaram as redes de similaridade são também destrinchadas, o que completa o conjunto de informações necessárias para se compreender exatamente como esses dados foram utilizados no restante da pesquisa.



Figura 3.1: Sequência de etapas que resultaram na construção do *Dataset Forró em Vinil*.

3.1 Motivação

A natureza da investigação sugerida por este trabalho requeria uma fonte de dados com características muito específicas. Primeiramente, buscávamos aqui um conjunto de dados que contemplasse também os arquivos de áudio das músicas. Esse fato por si só já restringe consideravelmente o subconjunto de *datasets* existentes na literatura, visto que um grande número de candidatos não disponibiliza o áudio das canções, apenas publicando *features* calculadas previamente que limitariam o desenvolvimento das atividades planejadas aqui. Ademais, uma vez que o estudo de inovação desejado faz-se presente dentro da trajetória histórica de gêneros específicos, os dados a serem analisados também precisam estar situados dentro de um contexto musical definido e ser anotado com informações relativas à época em que as músicas foram lançadas.

Uma vez levantados todos esses requisitos a respeito da natureza do *dataset* que seria alvo deste estudo, e confirmada a ausência de uma solução existente na literatura que atendesse a todos esses critérios, optou-se pela coleta e gerenciamento de um conjunto de dados próprio. Essa coleta personalizada buscava um total controle sobre os metadados disponíveis para cada música, além da garantia de que todas as composições se encaixavam em um mesmo gênero musical e eram rotuladas com suas respectivas épocas de lançamento. É nesse contexto que se propôs a criação do *Dataset Forró em Vinil*, que além de servir como base para toda a análise aqui proposta, foi tornado público para alavancar novos estudos por parte de outros pesquisadores e entusiastas da área da computação musical.

A escolha do forró como temática musical se fortifica na completude dos arquivos musicais disponibilizados pela fonte de dados escolhida (a ser melhor detalhada a seguir), em sua grande maioria anotados cuidadosamente com os nomes dos artistas, álbuns, músicas e anos de lançamento, fato esse que auxiliaria bastante no processo de extração de metadados. Além disso, a preferência por um gênero musical familiar ao pesquisador sempre foi visto como de grande valia, principalmente em um cenário – previsto desde um primeiro momento – em que se precisasse fazer um procedimento manual e subjetivo de correção sobre as músicas obtidas. Por último, e se sustentando em alguns dos pilares defendidos pelos criadores da plataforma *Dunya* – já mencionada no Capítulo 2 – a proposição de um novo *dataset* que contempla uma tradição musical regional se mostra de extrema utilidade

na construção de sistemas de informação que visam experiências musicais completas e que respeitem especificidades culturais [54].

3.2 Fonte de Dados e Coleta do Dataset

Em se tratando da música regional nordestina, o *website* Forró em Vinil ¹ figura como detentor de um grande coleção de mídias digitais cuja principal temática é o forró. A página se autointitula “a maior plataforma virtual de forró” e tem se dedicado, desde o ano de 2007, ao compartilhamento do gênero por parte de uma rede colaborativa filantrópica de colecionadores. Inicialmente focado na digitalização de discos de vinis (ou *Long Plays*, os famosos LPs), compactos e disco de 78 rotações (78rpm), a plataforma logo atentou para a existência de mídias mais contemporâneas (fitas cassetes, CDs e DVDs) que também continham conteúdo inédito, passando a também contemplar esse tipo de material em seu acervo. Hoje, dezenas de milhares de gravações originais, coletâneas e performances ao vivo são facilmente encontradas entre as seções do site, classificando-o como uma enorme coleção multimídia que narra não somente a história do forró, mas da musical regional brasileira como um todo.

Se aproveitando da estrutura bem definida dos documentos escritos em *HyperText Markup Language* (HTML) e servidos pelo site (ou o DOM – *Document Object Model* – do mesmo), propôs-se a criação de um *script* responsável pela navegação recursiva por entre as inúmeras seções do Forró em Vinil. A estratégia de *crawling*, como também é conhecida, pôde facilmente se basear em práticas de detecção de padrões textuais para identificar a presença de *links* externos que poderiam redirecionar os usuários a plataformas de hospedagem de arquivos (e.g., *Megaupload*, *Rapidshare*, *4shared*), salvando tais conexões para posterior obtenção dos arquivos. Finalmente, levantados todos os endereços de potenciais álbuns hospedados na *web*, a automatização do *download* desses arquivos foi conseguida mediante a execução de um segundo *script*.

Descartados todos os *links* inválidos ou expirados, essa estratégia foi responsável pela obtenção de um total de 3.589 álbuns, contemplando 32.411 músicas lançadas, relançadas ou tocadas ao vivo entre os anos de 1945 e 2016. A distribuição da quantidade de álbuns ao

¹<https://www.forroemvinil.com>

longo dos anos pode ser analisada na Figura 3.2 e evidencia uma maior concentração de coleções nas décadas 1970, 1980 e 1990, com um crescimento exponencial durante as décadas iniciais. De maneira análoga, vemos intuitivamente na Figura 3.3 uma distribuição de natureza semelhante para o número de faixas ao longo do tempo. Os procedimentos de correção que resultaram numa filtragem sobre os dados originalmente captados será explanada mais adiante.

A coleção musical mais antiga dentre as baixadas data do ano de 1945 e é um disco de 78 rotações da tradicional gravadora RCA Victor (atual *RCA Records*) contendo apenas duas faixas (*Festa Napolitana* e *Ovo Azul*) do ícone da música nordestina Luiz Gonzaga, enquanto que o álbum mais recente é o *Os Gonzagas* (Os Gonzagas, 18 faixas) lançado no ano de 2016. A base de dados montada originalmente totaliza um espaço em disco de 256 *gigabytes* (dentre arquivos de áudio e artes das mídias) e se encontra atualmente armazenada no servidor de *datasets* do Laboratório de Sistemas Distribuídos.

3.3 Correção do Dataset

A despeito de sua própria alcunha, o acervo disponibilizado pelo *Forró em Vinil* vai bem além do tradicional forró nordestino, contando com uma vasta diversidade de gêneros musicais. Gravações de samba, MPB, brega, repente, etc. são partes consideráveis da galeria disponibilizada pelo site. Dito isso, e considerando que a presente análise buscou a todo momento reduzir o escopo do gênero musical analisado para o forró apenas, foram necessários esforços de correção sobre o *dataset* originalmente montado, a fim de se contemplarem apenas álbuns desse gênero proposto. Com essa finalidade, efetuou-se inicialmente a listagem de todos os artistas cobertos pelo *dataset*, seguida de uma análise manual aplicada de modo a excluam-se álbuns de artistas cujos gêneros majoritários não fossem o forró. A otimização desse procedimento manual foi suportada pela familiaridade do autor com a temática musical escolhida, o que reforça a utilidade da escolha de um gênero regional e íntimo aos pesquisadores envolvidos no trabalho.

Seguinte, um outro esforço de correção de *dataset* consistiu na remoção de álbuns que não estivessem associados ao lançamento de gravações originais, como são os casos das coletâneas, regravações, performances ao vivo, tributos, dentre outros tipos de mesma natureza.

Termo(s)	Razão de filtragem	Exemplo encontrado no dataset
"Coletânea"	Divergência cronológica	<i>Coletânea - 2012 - Salve 100 anos Gonzagão</i>
"Sucessos"	Divergência cronológica	<i>Zito Borborema - 1961 - Seus Sucessos</i>
"Anos"	Divergência cronológica	<i>Zé Calixto - 1979 - 20 anos de forró</i>
"Ao Vivo"	Divergência cronológica	<i>Sociais do Forró - 1987 - Ao vivo na rádio</i>
"DVD"	Divergência cronológica	<i>Forróçacana - 2005 - O Melhor Forró do Mundo - áudio do DVD</i>
"Áudio"	Divergência cronológica	<i>Forróçacana - 2005 - O Melhor Forró do Mundo - áudio do DVD</i>
"Zé Ramalho"	Divergência de gênero	<i>Zé Ramalho - 1978 - Zé Ramalho</i>
"Alceu Valença"	Divergência de gênero	<i>Alceu Valença - 1981 - Cinco Sentidos</i>
"Clara Nunes"	Divergência de gênero	<i>Clara Nunes - 1985 - O talento de Clara Nunes</i>

Tabela 3.1: Exemplos de termos que guiaram a correção do dataset. Tanto as escritas originais (e.g., "Coletânea") quanto variações (corretas ou não - e.g., "coletânea", "coletanea", "coletania"(sic)) foram consideradas durante as filtragens.

A motivação por trás dessa manobra resume-se na necessidade de se ter controle cronológico sobre as músicas cujas influências serão analisadas, visto que essa variável pode, por si só, descartar a possibilidade de uma eventual influência (e.g., uma gravação lançada em 1980 não pode ter sido influenciada por uma outra lançada em 1990). Sendo assim, a especificidade do procedimento de correção aqui empregado consistiu na análise léxica dos títulos dos álbuns, excluindo-se de maneira supervisionada todos aqueles que se incluíssem em alguma das categorias não desejadas. A Tabela 3.1 exemplifica alguns dos termos que guiaram a filtragem dos dados, exibindo também o motivo pelo qual se ambicionava a remoção das coleções que contivessem tais trechos e exemplos de entradas que foram removidas.

Por fim, também foram desconsiderados do *dataset* quaisquer álbuns com ausência de informação cronológica em seus títulos. Apesar do Forró em Vinil possuir uma política de nomenclatura criteriosa a ser seguida pelos colaboradores, alguns poucos álbuns obtidos não possuíam a informação do ano em que foram lançados. Como a dimensão cronológica é de fundamental importância no estudo propôs-se a deleção de tais entradas.

Tais procedimentos de correção foram realizados em dois momentos distintos deste estudo, visto que a primeira filtragem demonstrou-se posteriormente não ter sido completamente eficaz. As Figuras 3.2 e 3.3 mostram a evolução nos números de álbuns e músicas ocasionada pelas correções, respectivamente. Ao final da aplicação da segunda filtragem a

quantidade total de músicas havia decrescido das originais 32.411 para 25.605 (redução de 21%), enquanto que os álbuns sofreram uma diminuição de 12,53%, figurando agora com 2.142 coleções distintas, contra as 2.449 anteriores. Apesar de tais porcentagens se traduzirem em um decréscimo considerável no tamanho do *dataset*, considera-se que ainda assim a base de dados contempla um número satisfatório de informações, estando estas integralmente situadas no contexto musical escolhido.

3.4 Extração das Features de Áudio

A escolha das *features* de áudio a serem utilizadas no esforço de modelar as influências apresentadas pelas músicas ao longo do tempo foi uma das etapas mais importantes deste trabalho. Isso porque existem inúmeras dimensões de similaridade associadas ao áudio. Um ouvinte pode considerar, por exemplo, que as versões de *Higher Ground* executadas originalmente por *Stevie Wonder* e posteriormente por *Red Hot Chili Peppers* são similares, simplesmente por se tratar da mesma música. Outra pessoa pode achar que *Nothing Else Matters* e *Eu Só Quero Um Xodó*, ambas tocadas num órgão, são similares pelo fato de compartilharem de um mesmo instrumento musical. As múltiplas facetas atreladas ao áudio, aliadas à subjetividade de cada pessoa na maneira de perceber a música pode dificultar o processo de modelagem de uma rede de similaridades dedicada à análise da inovação.

3.4.1 Definição e Extração das Features

A fim de se mitigar essa ameaça, foi de fundamental importância definir-se bem as dimensões de áudio que desejávamos refletir nas redes de similaridade. A forma escolhida para fazer isso foi tentar antever o tipo de evento inovador que se esperava que fosse capturado por essas redes mediante o cálculo do índice de interrupção. Em uma primeira reflexão, aspectos ligados à melodia e ao ritmo não pareceram poder ser convertidos em eventos de inovação relevantes para o nosso estudo. Entretanto, a realização do mesmo exercício considerando características de timbre dos áudios resultou em uma visão mais clara do tipo de episódio que poderia ser encontrado durante a observação das redes construídas. Uma vez que o timbre é uma propriedade específica do material que emite o som, é esperado que diferentes vozes, instrumentos e combinações destes dois produzam sons com timbres bem diferentes.

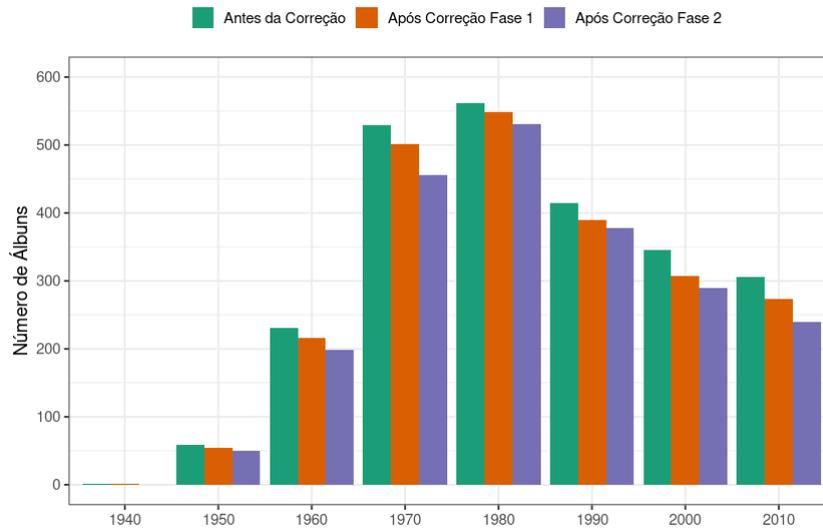


Figura 3.2: Histograma do número de álbuns ao longo das décadas, originalmente e após cada uma das etapas de correção.

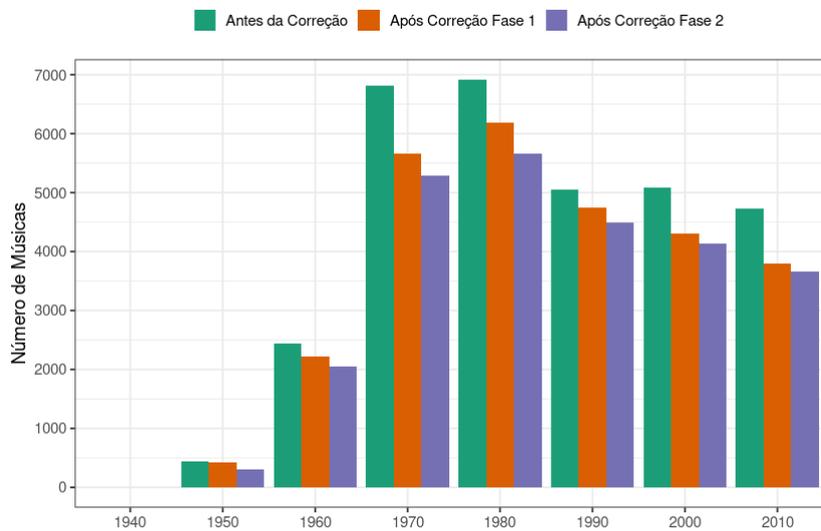


Figura 3.3: Histograma do número de músicas ao longo das décadas, originalmente e após cada uma das etapas de correção.

A agregação de aspectos de timbre a redes de similaridade no âmbito da análise de inovação pode oportunizar a descoberta de eventos como álbuns que passaram disruptivamente a ser interpretados por vozes femininas ou músicas que inseriram uma instrumentação inovadora, dentre outros. Esses fatos, comuns à história da maioria dos gêneros musicais, sustentaram a escolha das *features* de timbre como sendo as representações de áudio preferidas para esta investigação.

Em se tratando de *features* de áudio especializadas na modelagem de aspectos de timbre, nota-se na literatura considerável destaque aos *Mel-frequency Cepstral Coefficients* (MFCCs), anteriormente explicados no Capítulo 2. Considerando esse fato, optou-se, portanto, pela escolha dos MFCCs como *feature* responsável por representar matematicamente os áudios de cada uma das músicas contempladas pelo *dataset* coletado na etapa anterior. Conforme já debatido, MFCCs são *features* difundidas na comunidade de processamento de áudio e MIR, tendo sua extração implementada por diversos *frameworks* escritos nas mais diferentes linguagens de programação, como C++, Java, Python, Ruby, dentre outras. Especificamente no tocante a Python, é disponibilizada uma biblioteca chamada Librosa², completa no que se refere a tarefas de análise e processamento de áudio. Uma vez que Librosa é recorrentemente utilizada por outros pesquisadores em tarefas de naturezas semelhantes à nossa, e dado que a mesma possui uma implementação clara e direta de um extrator de MFCCs, este estudo baseou-se nessa ferramenta para tudo aquilo que se refere à extração das *features* propriamente dita.

Scripts Python foram responsáveis pela extração dos MFCCs para cada uma das 25.605 músicas do *Dataset Forró em Vinil*. Seguindo o que também foi explicado no Capítulo 2, essas *features* de áudio são capazes de quantificar a magnitude do sinal de áudio em diferentes bandas de frequência, sendo esse número de bandas um parâmetro ajustado durante atividades desse tipo. Neste estudo, utilizou-se um valor comum de dez, significando na prática que cada música possui informações referentes a dez coeficientes *mel-cepstrais*. Ademais, as magnitudes do sinal de áudio para cada uma das bandas de frequência variam com o passar do tempo, portanto cada coeficiente é representado por uma série temporal. A dimensão dessa série temporal é variável e também é um parâmetro dos extratores de MFCCs mais comuns, tendo nossa investigação adotado um valor de 500 observações ao longo do tempo

²<https://librosa.org/doc/latest/index.html>

para cada música. Finalmente, todas essas definições levaram os áudios da coleção a serem traduzidos em matrizes de MFCCs com formato 10x500, modelando devidamente os aspectos de timbre associados a cada uma das músicas.

3.4.2 Redução de Dimensionalidade

As representações extraídas na etapa anterior conseguem modelar satisfatoriamente as músicas nos aspectos de áudio desejados, porém possuem dimensões extensas. As matrizes que resumizam cada uma das músicas são compostas por 5.000 observações distintas de diferentes coeficientes *mel-cepstrais*, e esse tamanho extenso certamente tornaria árdua a tarefa de comparar representações diferentes utilizando medidas de distância entre vetores. Nesse sentido, um esforço extra de redução de dimensionalidade foi proposto para mitigar esse risco, tornando as representações mais compactas ao passo que se evitou ao máximo a perda de informação. Esse objetivo foi alcançado mediante a proposição de um *autoencoder* treinado exclusivamente sobre dados do *Dataset Forró em Vinil*.

A arquitetura do *autoencoder* utilizado neste estudo já foi esquematizada na Figura 2.8 do Capítulo 2 quando exemplificamos um *autoencoder* tradicional, e possui tanto um codificador quanto um decodificador simples e compostos por duas camadas. No caso do codificador (*encoder*) a primeira camada é inicialmente responsável pela conversão da matriz 10x500 multidimensional em um vetor de uma única dimensão (5000) – processo também chamado de *flattening*. A segunda é uma camada densamente conectada responsável pela compactação do vetor de entrada no código de tamanho fixo (falaremos dele a seguir). O decodificador (*decoder*) segue uma estrutura análoga, com sua primeira camada densamente conectada capaz de decodificar o código em um vetor unidimensional com tamanho equivalente à entrada, e uma última camada de redimensionamento (*reshape*) que traduz esse vetor de volta para a estrutura de matriz 10x500 original.

O tamanho da representação latente (código) foi definido por intermédio da execução de um experimento que visava a manutenção de uma representação compacta, porém eficiente o suficiente para permitir reconstruções fiéis durante a etapa de *decoding*. Para isso, foram inicialmente definidos tamanhos fixos para esse código, então treinaram-se *autoencoders* considerando cada configuração, e finalmente foi feita a avaliação da eficiência do modelo treinado. Essa avaliação foi feita em duas etapas: por meio da visualização das perdas (*loss*)

Tamanho do Código	Perda (<i>loss</i>)
50	0.7
60	0.53
70	0.2
80	0.11
90	0.05
100	0.01
120	0.01
150	0.008
180	0.01
200	0.007

Tabela 3.2: Valores de perda (*loss*) apresentados pelos *autoencoders* treinados com representações latentes (códigos) de tamanhos diferentes. A linha enfatizada representa a configuração que se mostrou mais coerente durante as experimentações.

apresentadas pelos modelos treinados, e por uma comparação visual entre as representações originais e as reconstruídas por cada *autoencoder*. A Tabela 3.2 resume a primeira bateria de avaliação, listando as perdas apresentadas por cada modelo. Nela, observa-se uma grau uniformização nos valores de perda a partir de um código com tamanho 100, indicando que talvez não houvesse um benefício considerável em se prosseguir com códigos maiores. Essa hipótese é de fato confirmada pela segunda fase de avaliação, exemplificada pela Tabela 3.3, e que mostra que as reconstruções do código de tamanho 100 e 200 são similares e igualmente próximas à entrada original. Intuitivamente optou-se então pelo código de tamanho 100, uma vez que se ambicionava a redução máxima da dimensão dos MFCCs.

Assim como na etapa de extração dos MFCCs, a linguagem de programação Python foi escolhida para a implementação do *autoencoder*, uma vez reconhecido seu potencial para tarefas de aprendizagem de máquina e dado que a mesma possui a biblioteca Tensorflow³, que possui um conjunto de ferramentas completo para a construção da rede neural ambicionada aqui. Uma vez implementado e treinado com todos os parâmetros mencionados (arquitetura,

³<https://www.tensorflow.org/>

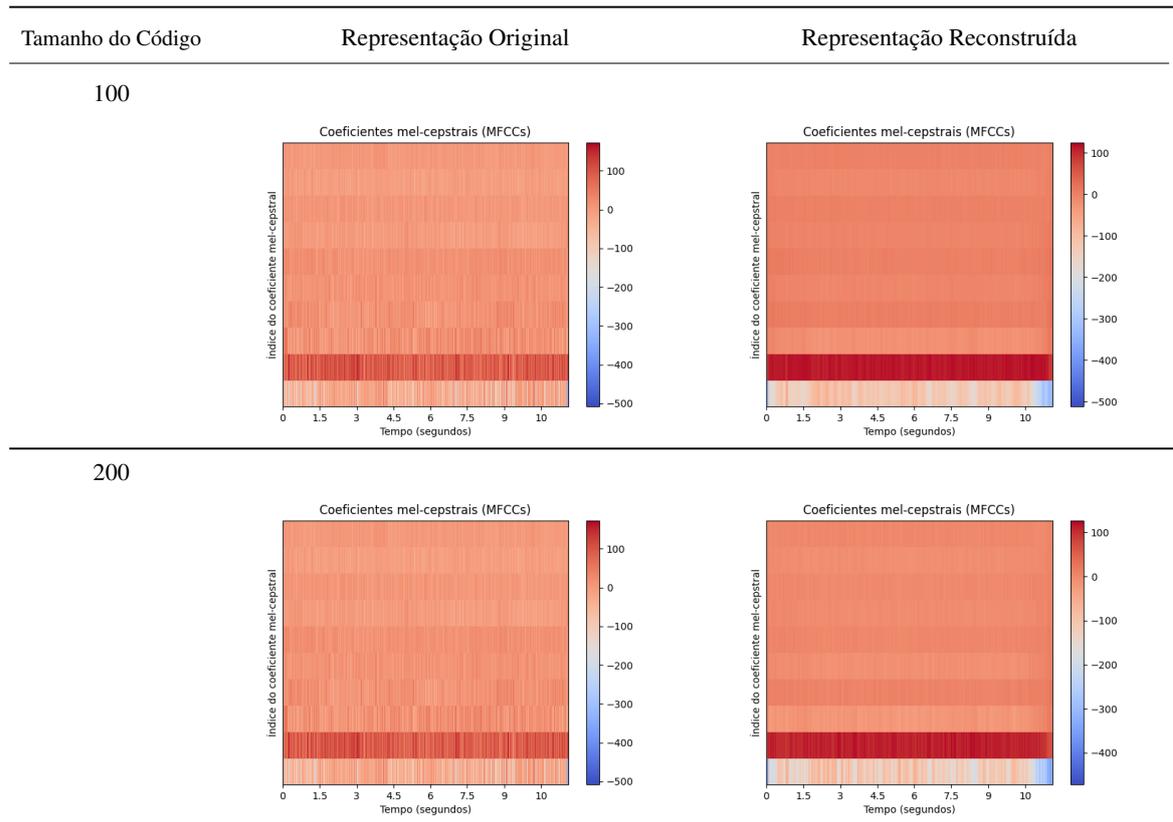


Tabela 3.3: Exemplos de espectrogramas extraídos de representações originais e reconstruções (para a mesma música) feitas por diferentes *autoencoders*. Os dois modelos foram treinados considerando tamanhos de código distintos e ilustram as semelhança entre as reconstruções propostas.

tamanho do código, etc.) o *autoencoder* foi então utilizado na redução de dimensionalidade de todos os MFCCs do *Dataset Forró em Vinil*, convergindo finalmente para as representações finais dos áudios que viriam a ser posteriormente utilizadas no estudo.

3.5 Considerações Finais

Neste capítulo foram apresentadas todas as etapas que convergiram para a construção do *Dataset Forró em Vinil*, inédito para o gênero musical coberto e com visível potencial de ser reutilizado em outras investigações que necessitem de bases de dados musicais com informações relativas a áudio. No transcorrer dos últimos parágrafos, fomos apresentados à sequência de procedimentos, também esquematizada na Figura 3.1, que se iniciou na coleta automatizada de 32.411 arquivos de áudio servidos pelo *website Forró em Vinil* e teve seu

fim na conversão dessas músicas em representações reduzidas prontas para serem utilizadas em etapas seguintes deste estudo.

Capítulo 4

Modelando Similaridades Entre Músicas

Conforme já amplamente debatido no Capítulo 2, a definição de similaridades entre músicas não é tarefa trivial. Neste estudo, tomando como motivação os consideráveis custos de treinamento e alimentação exigidos por técnicas mais sofisticadas (como modelos de ML ou algoritmos de filtragem colaborativa) optou-se por uma abordagem mais direta. Nesta, propõe-se que as próprias representações vetoriais fornecidas pelo *Dataset Forró em Vinil* sejam diretamente comparadas em pares por meio do uso de medidas de distância entre vetores. A escolha de qual medida de distância utilizar, portanto, desempenha um papel crucial dentro da modelagem de similaridades aqui proposta.

4.1 Métricas de Similaridade

Após a identificação de algumas das métricas mais comumente usadas visando o cálculo de distâncias entre vetores no espaço [55], chegou-se à escolha de três candidatas passíveis de serem utilizadas na construção das redes de similaridades que buscamos neste estudo. A distância euclidiana – utilizada normalmente no cálculo de distâncias entre dois pontos no plano bidimensional – também pode ser utilizada no cálculo de distâncias em um espaço multidimensional, também conhecido como espaço vetorial. Nesse tipo de espaço, consideremos dois pontos $a = (x_1, x_2, x_3 \dots, x_n)$ e $b = (y_1, y_2, y_3 \dots, y_n)$. A distância euclidiana d_{euc} entre a e b é definida pela Equação 4.1 a seguir:

$$d_{euc}(a, b) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (4.1)$$

Seguindo um raciocínio semelhante, a Fórmula 4.2 expõe a fórmula da segunda candidata considerada: a similaridade por cosseno, que, como o próprio nome já deixa explícito, declara que o cálculo da distância entre dois vetores é dependente do cosseno do ângulo formado por eles no espaço vetorial. Uma vez considerados x e y dois vetores, sua similaridade por cosseno é expressa por:

$$sim_{cos}(a, b) = \frac{ab^T}{\|a\| \|b\|} \quad (4.2)$$

É sabido que medidas que possuem natureza linear – como a distância euclidiana e a similaridade por cosseno – são consideravelmente sensíveis a alterações sutis nos valores das sequências. Isso pode fazer com que modificações causadas por motivos alheios aos relacionados à gravação das músicas, como distorções no próprio *sampling* do áudio, tenham graves influências nas distâncias computadas. Uma solução para essa limitação é a utilização de uma métrica que consiga mitigar essa sensibilidade, minimizando divergências em valores específicos e maximizando as similaridades globais entre os vetores. Tendo isso em mente, uma terceira alternativa – dessa vez de uma métrica não-linear – também foi considerada durante a fase de experimentação: a similaridade RBF (*Radial Basis Function*) [43; 29]. A similaridade RBF aqui utilizada é definida como sendo o valor calculado pela função *kernel RBF* (ou gaussiana) para dois conjuntos de *features* x e x' , sendo tal função formalizada pela Equação 4.3:

$$K(\mathbf{x}, \mathbf{x}') = \exp\left(-\frac{\|\mathbf{x} - \mathbf{x}'\|^2}{2\sigma^2}\right) \quad (4.3)$$

Uma vez que a natureza matemática da função *kernel RBF* faz com que os valores calculados variem entre 0 (quando x é igual a x') e 1 (quando a distância $\|\mathbf{x} - \mathbf{x}'\|$ tende ao infinito), se relacionando de maneira inversamente proporcional com a distância entre os vetores, o *kernel RBF* atribui a si uma interpretação de similaridade [73], o que por sua vez conclui o potencial da utilização dessa abordagem dentro do contexto estudado. O *kernel RBF* é implementado em Python pela biblioteca *scikit-learn*¹, sendo essa implementação

¹<https://scikit-learn.org>

capaz de computar uma matriz de similaridades RBF relativa a uma coleção de vetores passado como entrada.

4.2 Validação das Similaridades

Definidas as três postulantes à função de métrica responsável por modelar as interações de similaridade entre as músicas da rede, efetuou-se um procedimento complementar com o objetivo de validar quais dessas conseguiam de fato traduzir percepções reais de similaridade musical. Essa checagem visou blindar ao máximo nossa experimentação com o índice de disrupção de qualquer ameaça relacionada à não utilização de informações de similaridade realísticas ao contexto musical. Ainda com o objetivo de tornar essa validação mais robusta e completa, ela foi realizada em dois momentos distintos: inicialmente experimentou-se com cada uma das métricas sobre o próprio *Dataset Forró em Vinil*. A seguir, ambicionaram-se também testes utilizando um *dataset* externo, com características diferentes e amplamente utilizado em tarefas de checagem de similaridades.

4.2.1 Primeira Validação: *Dataset Forró em Vinil*

A primeira etapa de validação foi realizada utilizando as próprias representações do *Dataset Forró em Vinil* e consistiu em testar se as similaridades modeladas por cada uma das métricas estava em consonância com uma hipótese derivada de uma percepção musical verossímil. Nesse caso, optou-se por uma hipótese até certo ponto óbvia, de forma que métricas que não estivessem em concordância com a mesma pudessem ser seguramente descartadas. A hipótese que essa etapa de validação visou confirmar foi a seguinte:

"A similaridade média entre músicas de um mesmo artista é maior que a similaridade média entre músicas de artistas diferentes"

A obviedade dessa afirmação reside no fato de que músicas interpretadas por um mesmo artista tendem a ser mais parecidas entre si – visto que possuem mesma voz e geralmente a mesma instrumentação – do que músicas de artistas diferentes, com vozes diferentes (ou até mesmo ausência de uma), arranjos instrumentais diversos, e até mesmo questões relacionadas à época que podem afetar no áudio. A não concordância com uma hipótese dessa

natureza pode ser um forte indicativo de que a métrica em questão não se comporta bem perante o conjunto de dados que lhe é apresentado.

Desta forma, cada uma das três métricas objetivadas foi testada contra a hipótese anterior por meio de uma varredura sobre todas as músicas do *Dataset Forró em Vinil*, conforme é esquematizado pela Figura 4.1. Para cada música alvo eram obtidas as similaridades entre a mesma e dez outras músicas do mesmo artista – escolhidas aleatoriamente – utilizando a medida de similaridade sendo testada naquela rodada. Os valores de similaridade entregues pela métrica eram salvos para posterior comparação e um processo semelhante era então repetido, porém agora comparando a mesma música alvo com dez outras composições interpretadas por artistas diferentes, também escolhidas aleatoriamente. Ao final de cada iteração, verificava-se se a média das similaridades intra-artista (primeiro conjunto de comparações) era maior que a média das similaridades inter-artista (segundo conjunto de comparações), incrementando a contagem de concordâncias daquela métrica em caso positivo. Dessa forma, ao final da validação foi possível descobrir qual das medidas de distância concordou mais vezes com nossa hipótese musical.

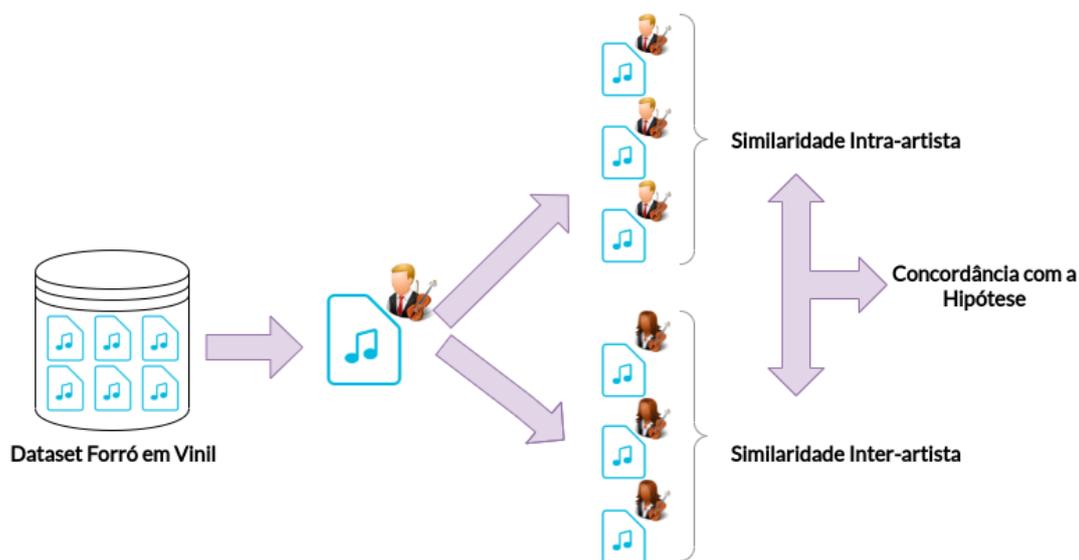


Figura 4.1: Esquema gráfico da primeira etapa de validação. Para efeitos de simplificação, aqui o número de comparações intra e inter-artista está reduzidos a três. Na validação realizada o número real utilizado foi de dez comparações.

Os resultados dessa experimentação podem ser observados na Tabela 4.1 e mostram que

Tabela 4.1: Taxa de concordância apresentada por cada métrica de distância durante a primeira etapa de validação.

Métrica	Taxa de Concordância
Distância Euclidiana	71,02%
Similaridade por Cosseno	81,16%
Similaridade RBF	74,45%

as três métricas de distância tiveram desempenhos aceitáveis na tarefa de modelagem de similaridade para esse cenário de validação. Conclui-se isso pois nos três casos houve concordância com a hipótese em mais de 70% dos testes feitos, tendo a similaridade por cosseno se sobressaído um pouco mais e ficado ainda acima dos 80%. Entretanto, dado que a diferença entre o desempenho da distância euclidiana e a similaridade por cosseno foi maior que 10%, optou-se, a partir desse momento, por limitar a validação entre as duas alternativas que obtiveram as maiores taxas de concordância. Outro motivo que sustentou essa decisão foi o fato de que as duas opções mantidas tratavam-se de medidas diretas de similaridade, o que facilitaria as comparações em nível de magnitude que seriam feitas a seguir.

A fim de generalizar os resultados de concordância levantados anteriormente, calcularam-se também os intervalos de confiança com nível de confiança de 95% para as diferenças entre as médias intra e inter artista obtidas durante essa experimentação. Os resultados seguem exibidos na Figura 4.2 para as duas métricas remanescentes. A verificação de intervalos positivos para ambas as métricas concorda com a análise das médias feita anteriormente, e reforça a eficiência tanto da similaridade por cosseno quanto da similaridade RBF na modelagem de percepções reais de similaridade.

Além de monitorar a concordância geral das métricas a respeito da hipótese com base na diferença das similaridades intra-artista e inter-artista, a validação também manteve controle de todos os valores de similaridade apresentados para cada um desses tipos. O objetivo dessa abordagem era, ao final de toda a varredura, verificar não somente se a hipótese havia sido respeitada de uma maneira geral, mas também se a distribuição das similaridades era condizente com percepção musical que sugerimos para a validação. A estatística descritiva básica desses dados é resumida na Tabela 4.2 e mais uma vez confirma que as similarida-

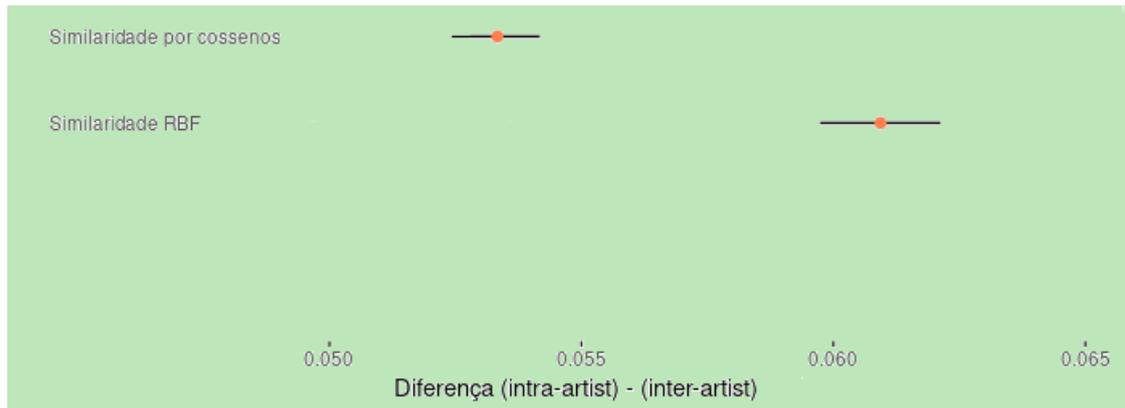


Figura 4.2: Intervalos de confiança para a diferença das similaridades intra e inter artista com nível de confiança de 95% para a similaridade por cosseno e similaridade RBF.

Tabela 4.2: Análise descritiva das similaridades intra-artista e inter-artista obtidas durante a validação de cada métrica de similaridade.

Métrica	Similaridade Intra-Artista			Similaridade Inter-Artista			Diferença	
	Média	Mediana	Desvio padrão	Média	Mediana	Desvio padrão	Média	Mediana
Similaridade por Cosseno	0.7467	0.7639	0.1133	0.6932	0.7110	0.1134	0,0535	0,0529
Similaridade RBF	0.6354	0.6600	0.1771	0.5735	0.5934	0.1711	0,0619	0,0666

des modeladas por ambas as métricas atendem à percepção sugerida. É importante ressaltar, entretanto, que a margem de diferença apresentada pelas médias dos dois tipos de similaridades não é grande, o que é um motivo de alerta. Esse fator se torna ainda mais arriscado para a similaridade RBF, que aliada a essa estreita diferença possui um desvio padrão um pouco mais alto que o da similaridade por cosseno.

4.2.2 Segunda Validação: *MagnaTagATune Dataset*

O primeiro passo da validação descrita na seção anterior foi a definição de uma hipótese (ou restrição) musical a ser obedecida pelas métricas de distância a fim de se considerar êxito na tarefa de modelagem de similaridade. Complementar a essa hipótese, e conforme já discutido no Capítulo 2, o *MagnaTagATune Dataset* também possui um subconjunto de dados composto de restrições de similaridade que foram definidas por usuários, tendo sido usadas por diversos pesquisadores em tarefas de validação semelhantes a esta proposta aqui. Logo,

considerou-se de grande valia executar um segundo momento de validação de similaridades usufruindo-se dessa base de dados.

Diferentemente da validação inicial, neste caso em particular não se possuíam as representações vetoriais de MFCCs criadas pelo *autoencoder* durante a construção do *Dataset Forró em Vinil*. Entretanto, esse novo *dataset* também disponibiliza todos os áudios envolvidos nas restrições de similaridade, de forma que não seria custoso treinar um novo *autoencoder* com a mesma arquitetura descrita no Capítulo 3, só que agora com novas músicas. E dessa forma foi feito para todos os áudios do *MagnaTagATune Dataset* que eram referenciados no subconjunto de restrições de similaridade. Ao final desse processo, todos os áudios de interesse haviam sido convertidos para a representação simplificada gerada pelo *autoencoder*.

As restrições de similaridade do *MagnaTagATune Dataset* são armazenadas em um arquivo *comma-separated-values* (CSV) e possuem semântica extremamente simples. Elas foram coletadas durante uma rodada bônus do jogo *TagATune*, que consistia num clássico exercício de *odd one out*: eram apresentados a dois jogadores três áudios e era solicitado a eles que selecionassem aquele que parecia mais estranho aos demais, gerando pontos para ambos em caso de concordância. Nesse caso, a resposta do *odd one out* simbolizava uma percepção clara a respeito do áudio que os usuários consideravam mais dissimilar aos outros dois, e é dessa forma que esse *dataset* tem sido usado em tarefas de validação de similaridade.

O arquivo CSV pode ser facilmente convertido em uma coleção de triplas no formato (C_i, C_j, C_k) , no qual C_k é considerado o *outlier*. Wolff e Weyde [76] utilizaram essa notação de triplas para derivar duas restrições de similaridade relativas: dados três trechos de áudio C_i , C_j e C_k , a conclusão de que C_k é o *outlier* pode ser interpretada usando as seguintes duas relações:

$$\begin{aligned} & \text{similaridade}(C_i, C_j) > \text{similaridade}(C_i, C_k) \\ & \wedge \text{similaridade}(C_i, C_j) > \text{similaridade}(C_j, C_k) \end{aligned} \quad (4.4)$$

Foi essa exata abordagem de restrições relativas de similaridade que a validação externa seguiu. Em uma fase preliminar, os 7.650 votos de usuários, espalhados entre 346 triplas distintas (cobrindo um total de 1.019 áudios) foram analisados com objetivo de se verificar

se todas as triplas possuíam algum nível de consenso a respeito do *outlier*. Infelizmente, uma grande parte das triplas foi considerada inválida para essa parte do estudo por um dos seguintes motivos: ou possuía menos de cinco votos, o que torna difícil alguma definição, ou mostrava votações muito acirradas entre dois ou às vezes até entre os três candidatos. Definiu-se que, para que uma tripla pudesse ser seguramente utilizada na etapa seguinte do estudo, ela deveria ter mais de cinco votos e ter um *outlier* escolhido com no mínimo 30% de votos a mais que o segundo colocado. Esse processo de filtragem reduziu o número de triplas válidas para 116, o que ainda foi considerado um número aceitável para a continuidade da etapa de validação.

O restante do procedimento foi análogo ao aplicado na primeira fase da validação e consistiu na verificação da taxa de concordância com as restrições de similaridades definidas. Uma vez que, de acordo com a Equação 4.4 cada tripla equivale a duas restrições distintas, um total de 232 testes seriam feitos para cada métrica de similaridade, mantendo sempre o controle dos acertos. Finalizada a execução da validação externa sobre as duas métricas de similaridade remanescentes no estudo, verificou-se um desempenho superior da similaridade por cosseno, que apresentou uma taxa de concordância de 85,34% (198 acertos) contra 75,86% (176 acertos) da similaridade RBF.

4.3 Definição da Métrica de Similaridade

Finalizada a validação planejada para as métricas de distância escolhidas, concluiu-se que as três seriam escolhas razoáveis na tarefa de modelar similaridade nesse contexto específico. Diz-se isso com base no bom desempenho que todas tiveram na primeira etapa de verificação, além do próprio resultado aceitável atingido pela similaridade RBF quando testada sobre o *MagnaTagATune Dataset*. Porém, alguns fatos pesam bastante em prol da escolha da similaridade por cosseno como métrica a ser usada de agora em diante. Primeiro, a diferença de desempenho entre a mesma e a distância euclidiana na primeira etapa de validação foi considerável (cerca de 10%), e isso não pode ser ignorado. Ademais, além do desempenho superior da mesma sobre a similaridade RBF no segundo experimento, esta apresentou um desvio padrão mais alto que a primeira, o que é um fator de risco dado que a diferença entre os dois grupos de similaridades já não foi tão alto quanto esperado. Pelos motivos supracitados,

foi definido ao final da etapa de validação que a métrica de distância que passaria a ser utilizada para modelar as redes de similaridade de agora em diante seria a similaridade por cosseno.

4.4 Considerações Finais

Neste capítulo foram descritas todas as diretrizes metodológicas responsáveis pela validação de um conjunto de métricas de distância candidatas a serem aplicadas sobre as representações de áudio construídas anteriormente. Após duas etapas de verificação: uma aplicada sobre o próprio *Dataset Forró em Vinil* estudado, e outra conduzida sobre um outro conjunto de dados externo (*MagnaTagATune Dataset*), motivos foram elencados que levaram a concluir que a métrica de distância mais indicada para modelar as similaridades entre músicas seria a similaridade por cosseno. Considera-se que a aplicação dessa metodologia de validação ajuda a assegurar que as relações de similaridade que serão modeladas a seguir de acordo com essas instruções estarão próximas às percepções reais de similaridade apresentadas por pessoas.

Capítulo 5

Índice de Disrupção em Redes de Similaridade

Todo o levantamento bibliográfico e metodologias discutidas durante os últimos capítulos convergiram para a aplicação do índice de disrupção e análise da inovação que discutiremos neste capítulo. Tanto o *Dataset Forró em Vinil*, coletado para o fim específico deste estudo, quanto as definições de similaridade do Capítulo 4 forneceram as bases necessárias para a construção de uma rede de similaridades. Essa rede é responsável por modelar as influências apresentadas por um subconjunto de músicas de forró ao longo dos últimos 80 anos. Uma vez construída a mesma, coube ao cálculo do índice de disrupção quantificar os potenciais inovadores de músicas, álbuns e artistas dentro da história do gênero.

As subseções a seguir detalham a experimentação feita com o índice sobre uma rede ponderada com informações de similaridade entre as músicas. Antes disso, entretanto, é relevante mencionar que, anterior à realização desse experimento, uma investigação semelhante foi realizada sobre uma rede não ponderada. Por motivos didáticos, a discussão envolvendo esse experimento inicial é conduzida separadamente no Apêndice A. Nele, discorre-se a respeito de todas as decisões que levaram à construção de um grafo sem pesos a partir das similaridades RBF calculadas entre as músicas. Vale salientar que naquele momento essa era a única medida de similaridade que havia sido validada, sendo por isso escolhida para modelagem das influências entre composições.

Reflexões e discussões posteriores à condução desse teste inicial levantaram algumas limitações atreladas ao mesmo. Ao mesmo tempo, essas imperfeições também despertaram

ideias de aprimoramentos passíveis de serem aplicados em uma eventual segunda fase de investigação. Um desses melhoramentos – proposto por este estudo – foi a inclusão do suporte a redes ponderadas no cálculo do índice de disrupção, conforme já detalhado no Capítulo 2. Esse experimento, portanto, adota a aplicação do índice de disrupção sobre uma rede ponderada, de forma que uma maior quantidade de informação de similaridade entre músicas fosse utilizada. Isso difere da metodologia empregada na experimentação preliminar, quando similaridades abaixo de um limiar definido eram descartadas.

5.1 Construção da Rede de Similaridades

Assim como descrito no Capítulo 2, o cálculo do índice de disrupção proposto por Funk e Owen-Smith é estrutural e sustenta-se na análise de redes para quantificar o potencial de disrupção e consolidação dos nós. Em estudos anteriores, esses nós representavam patentes de invenções, artigos científicos, e até mesmo artistas musicais, enquanto que as arestas simbolizavam as relações de influência entre esses itens. Nesta investigação, se ambicionou a construção da rede musical a partir de entidades musicais de menor granularidade: as próprias músicas. Essa sugestão já havia sido levantada por Figueiredo e Andrade [22] com o objetivo de expandir a validação da métrica no âmbito da música.

Uma vez definido que as músicas seriam os nós da rede, o próximo passo foi escolher como conectar as composições de modo a se traduzirem relações de influência entre elas. Considerou-se que, dentro de um mesmo gênero musical, a própria similaridade acústica entre duas músicas já seria um indicativo razoável de que existe ali uma relação de influência. Na música, há um certo senso comum de que artistas mais novos costumam trazer para suas apresentações diretrizes acústicas de outros artistas que idolatram ou admiram. Como exemplo disso, em 2019, durante uma entrevista à revista *Guitar World*, *Brian May* – guitarrista da clássica banda britânica de *rock Queen* – comentou:

*“The Beatles built our bible as far as musical composition, arrangement and production went.”*¹

¹<https://www.express.co.uk/entertainment/music/1237266/Queen-music-influences-The-Beatles-John-Lennon-Freddie-Mercury-Jimi-Hendrix-Brian-May>

Logo, sustentando-se nesse argumento, estabeleceu-se que as associações entre as músicas da rede, que idealmente seriam descritas pelas influências reais presentes entre elas, seriam nesse caso em especial modeladas por intermédio de suas próprias similaridades acústicas. Por um lado, essa é uma maneira viável de operacionalizar a análise de fluxos criativos e de influência em um corpus de canções. Por outro lado, é ambicioso considerar que essa implicação direta entre similaridade e influência é sempre verdade. Em outras palavras, é plausível que duas músicas sejam similares sem que necessariamente o artista da primeira tenha sido influenciado pelo da segunda. Espera-se, contudo, que em um volume razoável de músicas a identificação de padrões claros corresponda com frequência a relações de influência sonora.

Desta maneira, cada música do *Dataset Forró em Vinil* foi representada por um nó distinto na rede. Já suas arestas traduziriam as relações de similaridade entre as músicas, de forma que uma conexão entre as representações vetoriais m_1 e m_2 de duas músicas seria anotada com um $peso(m_1, m_2) = sim_{cos}(m_1, m_2)$. Além disso, reitera-se que essas arestas também codificam informações referentes às influências entre músicas (i.e., *quem foi influenciado por quem*), sendo essa noção restrita pelo fator cronológico. Isto implica dizer que uma aresta entre m_1 e m_2 apenas é possível, na prática, se m_1 suceder m_2 no tempo, caso contrário é cronologicamente impossível que m_1 tenha sido influenciado por m_2 . Essa assimetria demonstrada pelas relações de influência propostas por este estudo faz com que as arestas da rede sejam, além de ponderadas, dirigidas.

Mediante essas definições, procedeu-se então com a construção de uma rede conectando os nós (músicas) por meio de arestas dirigidas e ponderadas (similaridades). Esse processo foi auxiliado pela biblioteca NetworkX², disponível para a linguagem de programação Python. Todavia, verificou-se desde as primeiras etapas desse procedimento que a densidade da rede visada inviabilizaria a criação de uma estrutura global conectando todos os nós entre si por meio de arestas com pesos. Isso porque a construção das redes depende do armazenamento dos dados em memória, e o número de arestas geradas pelas combinações de nós eventualmente excedia os recursos disponíveis em todas as máquinas acessíveis ao experimento. Essa limitação foi observada tanto mediante a utilização da NetworkX quanto durante uma experimentação com outra biblioteca alternativa designada ao mesmo fim: a

²<https://networkx.org>

igraph³.

A alternativa encontrada para contornar essa limitação foi segmentar esse grafo geral em redes egocêntricas menores centralizadas em torno de cada um dos nós. Dessa forma, o cálculo do índice de disrupção poderia ser aplicado a essas estruturas simplificadas sem problemas de desempenho. Ajustou-se, portanto, o *design* desse experimento, de forma que agora cada nó da rede teria inicialmente sua rede egocêntrica calculada. Esse grafo seria composto pelo nó focal, seus sucessores, predecessores, e relações de similaridade (arestas) entre todos esses.

Além disso, optamos por usar no processo de construção das redes egocêntricas uma limitação no número de predecessores e sucessores do nó focal incluídos na estrutura. Essa decisão baseou-se em dois entendimentos: otimização de performance e igualdade perante o cálculo das disrupções. No tocante à performance, percebeu-se que as computações exigidas pelas novas definições do cálculo (Equação 2.3) se mostraram bastante custosas quando aplicadas a redes ponderadas, ainda que em se tratando de redes egocêntricas reduzidas. Isso se explica pelo fato do cálculo de $diff(f, s)$ requerer a obtenção dos pesos das arestas de cada sucessor com cada predecessor do nó focal. A segunda motivação da limitação surge de uma característica da própria fórmula do índice: de acordo com a Equação 2.1, I_d é diretamente proporcional n_i , e a probabilidade de termos n_i altos cresce à medida que se aumenta o número de predecessores. Logo, considerar números de sucessores e predecessores diferentes para cada nó afetaria na isonomia do cálculo, prejudicando a comparação entre nós. A fim de endereçar ambos os problemas, limitamos o número de predecessores e sucessores comparados a um valor de 1000 para todos os nós. Tanto os predecessores quanto os sucessores são as músicas imediatamente anteriores ou posteriores ao nó focal na ordem cronológica, respectivamente, excluindo-se de ambos os grupos músicas interpretadas pelo mesmo artista que a do nó focal.

A última escolha a ser feita antes de se iniciar a elaboração das redes egocêntricas era relativa ao limiar de segurança requerido pelas novas definições do cálculo do índice de disrupção, conforme descrito na Seção 2.1.3. Recapitulando, esse limiar é utilizado para definir uma faixa de valores para similaridades altas e baixas, guiando a classificação dos sucessores do tipo i , j e k . Para definir esse número, revisitou-se a primeira etapa de validação sobre

³<https://igraph.org>

as similaridades, executada no Capítulo 4. Lá foi observado que a diferença média entre as similaridades por cosseno intra-artista e inter-artista se aproximou de 0,06. Usando esse número como referência, e aplicando uma aproximação direta, ajustou-se o valor do limiar de segurança para 0,1.

Definida a metodologia, realizou-se então a construção das redes egocêntricas de todas as músicas do *Dataset Forró em Vinil*. A Figura 5.1 ilustra um exemplo simplificado de rede egocêntrica construída para a canção *Asa Branca*, interpretada por Luiz Gonzaga no ano de 1962. O grafo é representado pelo nó focal, seus sucessores e predecessores, além de todas as arestas dirigidas anotadas com pesos extraídos das similaridades por cosseno entre as representações das músicas.

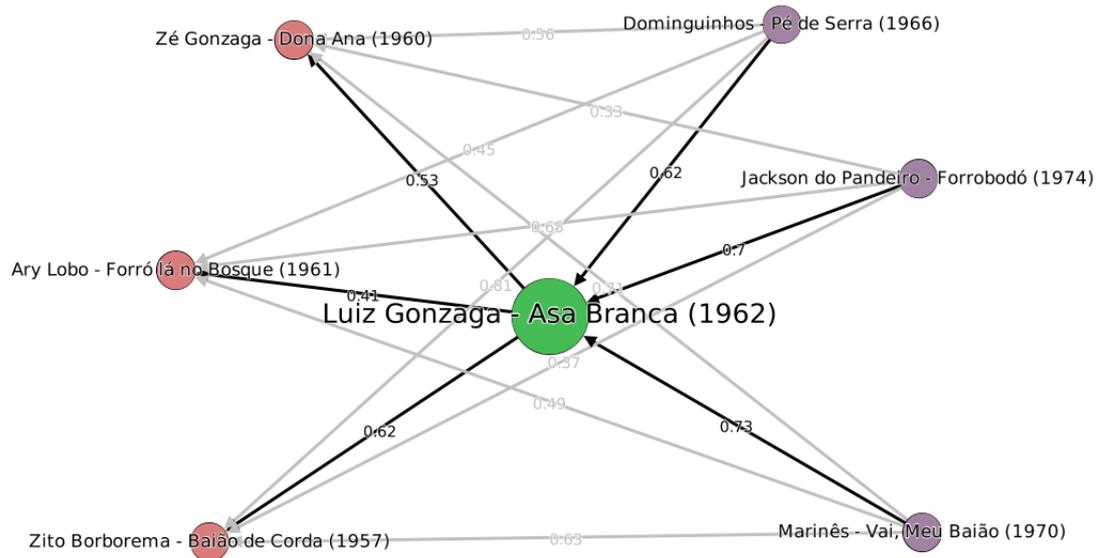


Figura 5.1: Rede egocêntrica simplificada para a música *Asa Branca*, de Luiz Gonzaga ($I_d = -0,49$). Ao redor do nó focal (em verde, ao centro) estão os sucessores (em roxo) e predecessores (em vermelho). Além disso, as arestas são anotadas com informações reais de similaridade fornecidas pela similaridade por cosseno. Arestas mais escuras enfatizam conexões cuja origem ou destino são o nó focal.

Uma vez calculadas as redes egocêntricas relativas a cada música do *dataset*, procedeu-se com a aplicação do cálculo do índice de disrupção em cada um desses grafos, de acordo com as definições do Capítulo 2.

5.2 Análise da Inovação no Forró

A condução do cálculo do índice de disrupção sobre as redes egocêntricas produziu uma coleção de métricas de inovação referentes às músicas do *Dataset Forró em Vinil*. Em uma análise preliminar, constata-se tanto na Figura 5.2 quanto na Tabela 5.1 que a distribuição desses índices apresenta uma concentração sobre valores negativos (centralizados entre -0,4 e -0,5), com cauda bem pequena à direita, em direção aos valores positivos. A conclusão que se pode tirar desse fato é que existem no forró mais músicas que inovaram o gênero de maneira consolidadora do que músicas que aplicaram algum nível de desestabilização ao mesmo. Essa primeira constatação também já havia sido observada em estudos anteriores do índice em diferentes contextos [23; 77; 22]. E, do ponto de vista prático, parece intuitiva a noção de que dificilmente uma trajetória será disruptiva na maior parte do tempo, pois caso isso acontecesse sua linha criativa seria desestabilizada a todo momento, gerando um caos que poderia culminar numa descaracterização do próprio contexto.

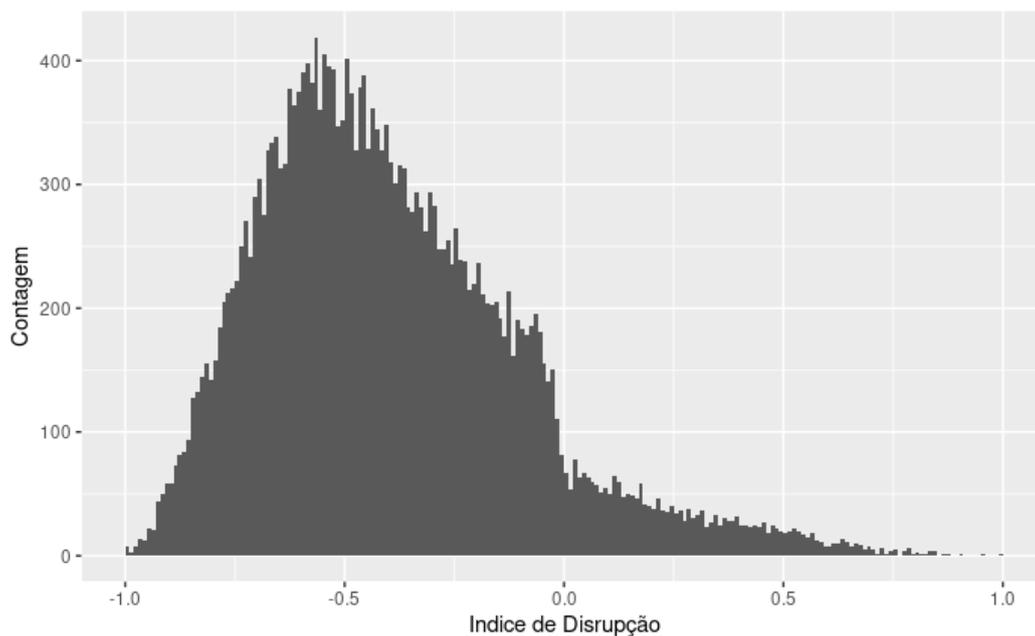


Figura 5.2: Histograma dos índices de disrupção calculados durante o experimento.

Medida	Valor
Mínimo	-1
Máximo	1
1° Quartil	-0,61
3° Quartil	-0,22
Média	-0,39
Mediana	-0,44

Tabela 5.1: Estatística descritiva realizada sobre os índices de disrupção calculados durante o experimento.

5.2.1 Músicas Mais Disruptivas

A Tabela 5.2.1 mostra o *top-5* de músicas mais disruptivas para apresentar as composições que tiveram posição de destaque sob este ângulo. Uma lista mais completa pode ser verificada na Tabela B.1 do Apêndice B. Enfatiza-se a carga disruptiva atribuída a Luiz Gonzaga, que figura com duas músicas dentre as cinco canções que mais desestabilizaram o gênero durante essas sete décadas. Outra presença recorrente nesse *ranking* de criatividade, Marinês também aparece na lista com a música mais disruptiva do *Dataset Forró em Vinil (Pica Pau - 1966)*. A frequência de aparição desses dois artistas tanto nesse *ranking* quanto no que será mostrado adiante no Apêndice A corrobora com a importância exercida por ambos sob a ótica inovadora do gênero. A Tabela 5.2.1 também levanta algumas evidências encontradas nos áudios que podem contribuir para as altas disrupções associadas a essas músicas mencionadas e outras com alto potencial disruptivo.

A lista de músicas mais disruptivas também apresenta dois artistas até então não mencionados: Castanheiro e Genival Lacerda. Especificamente sobre este, parece coerente o destaque apresentado pelo artista campinense, dada a sua rica história no forró. Genival Lacerda iniciou sua carreira na década de 1950, apenas obtendo sucesso no final dos anos 70 com a música *Severina Chique Chique*. Durante a sua longa carreira, encerrada no começo desse ano com sua morte por conta de complicações causadas pela COVID-19, lançou inúmeras músicas com letras cômicas e tons jocosos, algumas de grande sucesso dentro do gênero musical, como *De quem é esse jegue* e a própria *Radinho de Pilha*, que aparece no

Música	Artista	Álbum (ano)	Índice de Disrupção & Comentários
<i>Pica Pau</i>	<i>Marinês</i>	<i>Meu Ben-zim (1966)</i>	$D = 0,96$ ($n_i = 933, n_j = 17, n_k = 0$). Essa música da pioneira do forró Marinês, com sanfona e percussões bastante evidentes, apresenta várias similaridades altas com músicas de outra voz feminina contemporânea: Clemilda.
<i>Estrada de Canindé</i>	<i>Luiz Gonzaga</i>	<i>O homem da terra (1980)</i>	$D = 0,91$ ($n_i = 915, n_j = 33, n_k = 17$). <i>Estrada de Canindé</i> é um dos grandes sucessos de Luiz Gonzaga, já tendo sido regravada por artistas de renome, como Fagner e Lucy Alves. No <i>dataset</i> sua primeira aparição consta no ano de 1980, tendo influenciado disruptivamente outras composições com fortes arranjos de sanfona.
<i>Flor do Limoeiro</i>	<i>Castanheiro</i>	<i>Caruaru (1973)</i>	$D = 0,88$ ($n_i = 920, n_j = 60, n_k = 0$). Menos conhecido no cenário do forró, Castanheiro se destaca nesse <i>ranking</i> com uma música com percussão e baixo destacados, influenciando músicas com características semelhantes.
<i>Radinho de pilha</i>	<i>Genival Lacerda</i>	<i>Não despreze seu coroa (1979)</i>	$D = 0,88$ ($n_i = 919, n_j = 59, n_k = 1$). Um dos grandes sucessos de Genival Lacerda - cujas músicas eram caracterizadas por contos cantados por sua voz estridente - esta canção demonstra influência sobre outras também marcadas por vocais destacados.
<i>Siri jogando bola</i>	<i>Luiz Gonzaga</i>	<i>O homem da terra (1980)</i>	$D = 0,87$ ($n_i = 901, n_j = 64, n_k = 1$). Gonzagão mais uma vez se faz presente no <i>ranking</i> de músicas mais disruptivas, com outra canção recente que influenciou consideravelmente artistas da geração intermediária do forró com suas melodias de acordeon..

Tabela 5.2: Cinco músicas mais disruptivas de acordo com a rede de similaridades ponderada.

top-5 de músicas mais disruptivas.

No caso específico de *Radinho de Pilha*, verifica-se que a música – a qual conta com uma qualidade de áudio muito boa no *dataset* – além de possuir a instrumentação tradicional do forró é também caracterizada por uma apresentação vocal muito forte. Ademais, escuta-se também em diversos momentos da música a presença de *backing vocals* que complementam a performance do artista principal. Chama-se a atenção para esses fatos, pois, dentre algumas das músicas que possuem relações de influência exclusivas com *Radinho de Pilha* temos outras que compartilham dessas mesmas características. Artistas como Pinto do Acordeon e Dominginhos, com músicas como *Tarde de Domingo* e *Tudo é São João*, respectivamente, cujas similaridades com a composição de Genival são altas, elevam o nível disruptivo de *Radinho de Pilha*, dentre outros motivos.

5.2.2 Álbuns Mais Disruptivos

Além das análises individuais no nível das músicas, é possível observar também como a inovação no forró se comportou de forma agregada. Isso é especialmente útil caso desejemos verificar, por exemplo, como diferentes álbuns, artistas ou épocas figuraram do ponto de vista inovador durante essas sete décadas de história do gênero. A Tabela 5.3 ranqueia os 20 álbuns mais disruptivos em nosso estudo, além de informar a que artista cada disco pertence e em que ano foi lançado. Uma lista mais ampla, com 30 álbuns, pode ser analisada na Tabela D.1 do Apêndice D. Essa ordenação foi realizada de acordo com as médias dos índices de disrupção de todas as músicas presentes nos álbuns. Chama atenção o fato de que quase metade dos álbuns desse *ranking* (9 de 20) foram lançados na década de 1970. Isso reforça uma suspeita relacionada a uma elevada carga disruptiva presente nesse período – fato que também será discutido a seguir durante a discussão do experimento com redes não ponderadas. Na investigação conduzida aqui, Marinês e Abdias figuram com álbuns muito disruptivos, assim como Luiz Gonzaga e Jackson do Pandeiro, que também possuem lançamentos com considerável nível de disrupção um pouco abaixo desse *ranking*.

Outra discussão significativa é sugerida a respeito do álbum mais disruptivo do *Dataset Forró em Vinil*. *Rato Molhado*, de Pedro Sertanejo (1967) é, assim como grande parte da obra do músico baiano, uma coleção composta por toadas instrumentais, sem qualquer interferência vocal. Em todas as músicas de *Rato Molhado* tudo que se houve são arranjos de

#	Álbum	Artista	Ano	Índice de Disrupção Médio
1	Rato Molhado	Pedro Sertanejo	1967	0,51
2	Forró Exportação	Zé Duarte	1985	0,45
3	Voltando para Penedo	Trio Estrela do Norte	1982	0,40
4	Sonhando com Meu Bem	Marinês	1970	0,32
5	Chega de Promessa	Fuba de Taperoá	1993	0,29
6	Torrão de Ouro	Anastácia	1971	0,29
7	Forró Bom Danado	Benedito Nunes	1971	0,28
8	Vamo Xamegá	Anastácia	1972	0,27
9	Valor do Homem	Ary Lobo	1970	0,26
10	Entre na Nossa Quadrilha	Zé Cupido	1976	0,26
11	Quadrilhas e Marchinhas Juninas	Luiz Gonzaga	1965	0,26
12	No Oitão La de Casa	Zé do Baião	1969	0,26
13	Os Nordestinos do Ritmo	Os Nordestinos do Ritmo	1994	0,26
14	Festaça Computada	Grupo Coração do Brasil	1990	0,22
15	Na Ginga do Merengue	Abdias	1970	0,22
16	Amor de Primeira	Oswaldo Oliveira	1971	0,22
17	Chegou um Sanfoneiro	Marquinhos	1982	0,21
18	Asa Branca	Zé Gonzaga	1992	0,21
19	Só pra Machucar	Marinês	1973	0,21
20	E Muita Cantiga Nordestina	Alventino Cavalcanti	1968	0,20

Tabela 5.3: Vinte álbuns mais disruptivos do *dataset*. Em ênfase estão os álbuns lançados na década de 1970, uma das eras mais disruptivas da história do forró.

sanfona acompanhados de percussão, inclusive de alguns sucessos de outros artistas, como *Asa Branca* de Luiz Gonzaga. O que torna esse fato tão peculiar no contexto da disrupção é que dentre as canções que possuem altas e exclusivas similaridades com *Rato Molhado* observam-se músicas de outros artistas que também possuem apenas aspecto instrumental. Artistas como Abdias e Severino Januário, com canções como *Homenagem a Januário* e *Zé Miúdo*, respectivamente, se assemelham a músicas do álbum disruptivo de Pedro Sertanejo. Analisando o *dataset* com um foco em discos anteriores a 1967 (ano de lançamento de *Rato Molhado*) não se encontram outras iniciativas compostas exclusivamente pelo aspecto instrumental. Esse é um indicativo de que a alta disrupção de *Rato Molhado* pode residir no fato de ele ter sido precursor como álbum de forró instrumental lançado.

5.2.3 Artistas Mais Disruptivos

Analogamente à exploração anterior, a agregação dos índices de disrupção também nos permite investigar artistas ou grupos em particular que consolidaram ou desestabilizaram a trajetória do forró. Entretanto, dada a natureza da distribuição do índice, e considerando que as agregações por artista agrupariam um número bem maior de músicas do que, por exemplo, a agregação por álbum, uma estratégia diferente de sumarização do índice foi adotada. Conforme discutido no início deste capítulo, a distribuição dos índices de disrupção calculados nessa etapa da investigação se concentrava em valores negativos. Logo, a tarefa de traduzir o potencial inovador de um artista com base em seus índices agregados precisaria fazer uso de uma métrica de sumarização que considerasse que os eventos disruptivos (i.e., I_d altos) ocorrem dispersos ante uma grande maioria de eventos não disruptivos. Sendo assim, utilizamos o 95-percentil como medida de sumarização para os índices de disrupção agregados por artista.

Considerando essa definição anterior, a Tabela 5.4 retrata a lista ordenada dos dez artistas mais disruptivos do forró, de acordo com os dados coletados no *Dataset Forró em Vinil*. Um *ranking* mais completo, com os 30 artistas que mais desestabilizaram a linha criativa do forró, pode ser evidenciado no Tabela C.1 do Apêndice C. Ambas as listagens desconsideram artistas com menos de 30 músicas no *dataset*. Concluiu-se que artistas com poucas músicas não possuíam uma variabilidade de dados suficiente para a sumarização de um índice agregado que refletisse sua posição inovadora no cenário do forró.

Uma primeira constatação derivada desse resultado que chama a atenção é a ausência dos pioneiros do forró dentre os dez artistas mais disruptivos. Dada a reconhecida importância para a história do gênero atribuída a artistas com Marinês, Luiz Gonzaga e Jackson do Pan-deiro, idealizou-se em um primeiro momento que esses estariam entre os mais disruptivos. Mais uma vez, analisaram-se os dados calculados para encontrar uma resposta que justificasse essa peculiaridade. A razão pela qual os três artistas citados não figuram dentre os artistas mais disruptivos tem relação com a quantidade de músicas apresentadas por cada um no *dataset*. A Tabela 5.5 sumariza essa informação listando os dez artistas que possuem mais músicas no *Dataset Forró em Vinil*, dentre os quais figuram os três pioneiros mencionados. O elevado número de músicas desses artistas, aliado à distribuição das disrupções, faz com que suas disrupções sumarizadas sejam consideravelmente deduzidas, fazendo com que as

#	Artista	Índice de Disrupção
1	Os Nordestinos do Ritmo	0,64
2	Falamansa	0,53
3	Benedito Nunes	0,51
4	Trio Mossoró	0,50
5	Cezar do Acordeon	0,47
6	Ciço do Pará	0,47
7	Fuba de Taperoá	0,47
8	Zito Borborema	0,46
9	Pedro Sertanejo	0,46
10	Ze da Onça	0,45

Tabela 5.4: Dez artistas mais disruptivos do *dataset*. A lista considera apenas artistas com mais de 30 músicas nos dados e sumariza seus índices de disrupção por meio do 95-percentil.

mesmas não se equiparem às dos artistas listados na Tabela 5.4.

A presença da banda Falamansa nesse *ranking* também se destaca e motivou uma análise mais aprofundada. Falamansa, diferente da maioria dos artistas e bandas de forró – principalmente aquelas cobertas pelo *Dataset Forró em Vinil* – surgiu longe da região nordeste, berço do gênero musical. Criada em 1998 na cidade de São Paulo, a banda rapidamente atingiu considerável sucesso interpretando clássicos de Luiz Gonzaga e Jackson do Pandeiro com uma mistura do tradicional forró-pé-serra e forró universitário – vertente mais recente do gênero, nascida nos anos 70 e aprimorada a partir do início da década de 1990. Essa forte conexão com esse subgênero fica bastante evidente ao se verificarem as relações de similaridade das músicas do Falamansa. *Love sem amor* (2003), por exemplo, possui uma sonoridade semelhante e influenciou músicas sucessoras também pertencentes do movimento do forró universitário, como *Você sorriu* (Trio Virgulino) e *Forrobodó* (Trio Forrozão). Fatos como esse apontam para uma linha de argumentação baseada na constatação que Falamansa é disruptivo no contexto do forró universitário.

#	Artista	Número de Músicas
1	Luiz Gonzaga	845
2	Trio Nordestino	574
3	Dominginhos	546
4	Genival Lacerda	428
5	Marinês	414
6	Jackson do Pandeiro	347
7	Zé Duarte	345
8	Anastácia	338
9	Gerson Filho	327
10	Clemilda	315

Tabela 5.5: Dez artistas com mais arquivos de áudio contemplados pelo *Dataset Forró em Vinil*. Em ênfase estão alguns dos pioneiros do forró.

5.2.4 A Disrupção Feminina

De maneira complementar às agregações por álbum e por artista, conduziu-se também um estudo focado na disrupção agrupada nos diferentes gêneros. O objetivo dessa análise era investigar se existia alguma diferença nos níveis de disrupção apresentados por artistas homens e mulheres ao longo desse tempo, além de buscar indícios que sustentassem essas descobertas. A priori, este tipo de informação não estava coberta dentro o conjunto de metadados disponíveis nativamente nos áudios do *Forró em Vinil* coletados. Logo, um esforço extra de anotação manual guiado pelos nomes dos artistas precisou ser feito visando a incrementação dos metadados de cada música com o novo dado relativo ao gênero do cantor ou cantora. Uma vez que a anotação de composições interpretadas por grupos musicais compostos por vários artistas seria custoso e confusa (e.g., caso o grupo fosse composto por pessoas de ambos os gêneros), essas ocorrências em particular foram anotadas com o gênero *indefinido*. A distribuição de canções entre cada categoria é descrita na Tabela 5.6 e retrata uma grande maioria das músicas sendo interpretadas por homens. Essa estatística se deve ao fato de o forró ter surgido e se desenvolvido em uma época onde figurava uma sociedade machista, na qual as iniciativas artísticas eram na maioria das vezes uma atividade masculina.

Gênero	Número de Músicas no Dataset
Masculino	21.101
Feminino	2.391
Indefinido	2,113
Total	25.605

Tabela 5.6: Número de músicas do *dataset* por gênero.

Gênero	Índice de Disrupção
Feminino	0,26
Masculino	0,17
Indefinido	0,24

Tabela 5.7: Índices de disrupção agregados por gênero.

No que se refere à análise da disrupção agregada por gênero, o que se observa é que, conforme pode ser observado na Tabela 5.7, existe uma diferença entre o potencial disruptivo apresentado por homens e mulheres durante o período contemplado pelo *dataset*. A investigação mostra que, de acordo com os índices de disrupção coletados, as mulheres demonstram ter tido uma atividade disruptiva superior à dos homens. As principais responsáveis por esse nível de disrupção mais alto estão detalhadas na Tabela 5.8, tendo Marinês, mais uma vez, como artista mais disruptiva do mundo feminino do forró. O que pode-se observar por meio do detalhamento das disrupções desse gênero é uma forte rede de altas similaridades exclusiva entre músicas de mulheres. A música *Campina Grande* ($I_d = 0,6$), de Marinês, por exemplo, apresenta altas similaridades com músicas de congêneres que a sucederam, como *As Cangaceiras (É proibido cochilar)*, *Clemilda (Onde quer que eu beije)* e *Anastácia (Lamento de Saudade)*. O fator que mais contribui para a alta disrupção da canção de Marinês é que essas altas similaridades não se repetem com as músicas anteriores a *Campina Grande*. Essa intensa rede de colaborações entre mulheres – que pode ser vista em outros exemplos – parece ser uma das principais razões pelas quais as mesmas apresentam níveis disruptivos mais altos do que os dos homens.

#	Artista	Índice de Disrupção
1	Marinês	0,42
2	Anastácia	0,37
3	Irah Caldeira	0,35
4	Marinalva	0,34
5	Clemilda	0,17

Tabela 5.8: Cinco artistas mulheres mais disruptivas do *dataset*. A lista considera apenas artistas com mais de 30 músicas nos dados e sumariza seus índices de disrupção por meio do 95-percentil.

5.2.5 A Disrupção ao Longo dos Anos

Novamente, propõe-se a visualização das distribuições do índice de disrupção por meio da Figura 5.3, que exibe a evolução dos intervalos entre o 5-percentil (limite inferior) e 95-percentil (limite superior) com o passar dos anos. O gráfico aponta que a trajetória musical do forró alternou constantemente entre períodos disruptivos (picos no gráfico) com alguns intervalos de tempo com menos movimentação criativa (os vales). A respeito desses momentos nos quais a produção criativa se destacou dos demais, o gráfico externa que movimentos inovadores se concentraram em três épocas distintas. Além disso, por meio da análise estatística restrita a cada um desses intervalos, observou-se que os movimentos disruptivos também foram influenciados por artistas diferentes.

A Primeira Onda de Inovação (1960 a 1970)

A existência de um forte movimento inovador com natureza disruptiva durante as primeiras décadas do gênero é verificada nos dados agregados resultantes do novo cálculo do índice de disrupção. Essa primeira onda de inovação, que se inicia por volta de 1960 e dura até pouco depois de 1970 se mostra bastante consistente, com dois picos disruptivos curtos e um terceiro, mais longo, que perdurou por cerca de dez anos.

As informações relativas à disrupção, quando restringidas a esse período de tempo, identifica a influência dos pioneiros do forró sobre a carga disruptiva apresentada entre 1960 e 1970, algo que não havia sido observado nas informações gerais de disrupção exibidos pela

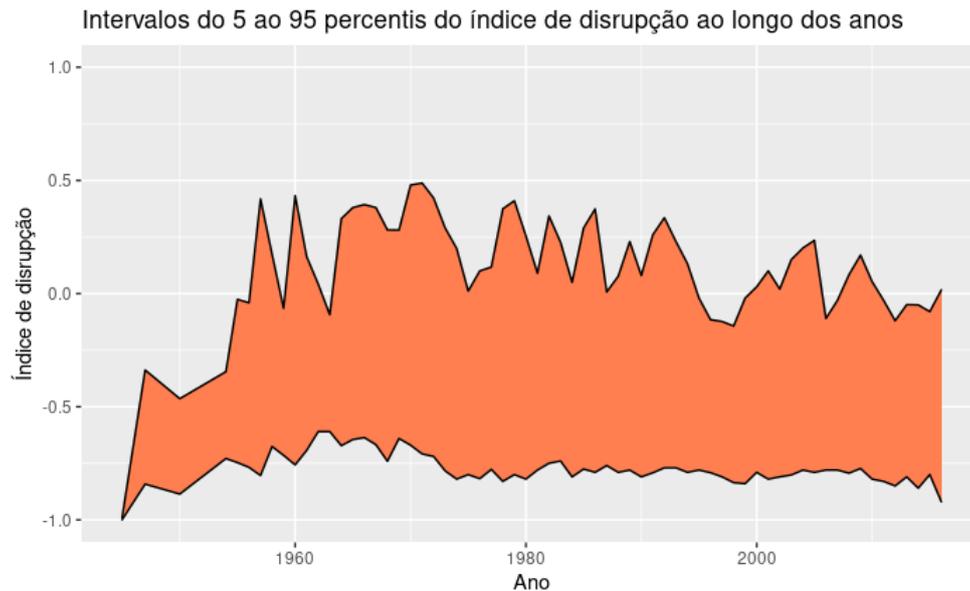


Figura 5.3: Distribuição das disrupções sumarizadas ao longo do tempo. Os intervalos representam o 5-percentil (limite inferior) e o 95 percentil (limite superior).

Tabela 5.4. Os seis artistas mais inovadores dessa janela de tempo, assim como seus respectivos intervalos 5-percentil a 95-percentil ano a ano seguem destacados na Figura 5.4. Além da presença de Marinês, Luiz Gonzaga e Jackson do Pandeiro, evidencia-se também a alto potencial disruptivo atribuído a outros pioneiros como Dominginhos, Abdias e Severino Januário, este último irmão de Luiz Gonzaga.

A Segunda Onda de Inovação (1980 a 1995)

Após um período de queda e manutenção de baixos níveis de disrupção entre 1970 e 1980, os 15 anos seguintes foram caracterizados por várias alternâncias de períodos curtos de média e baixa carga disruptiva. Embora que com níveis ligeiramente mais baixos do que os da primeira onda, os picos observados durante essa fase são representativos e apontam para um segundo momento inovador na história do forró. A essa altura, o tradicional *forró-pé-de-serra* já começava a sofrer suas primeiras mutações musicais, criando subgêneros como o forró universitário. O forró universitário nada mais é que o forró tradicional incrementado por outros ritmos e instrumentos além da zabumba, triângulo e sanfona [15]. Como o próprio nome diz, se originou a partir do momento em que o gênero foi levado para dentro das festas

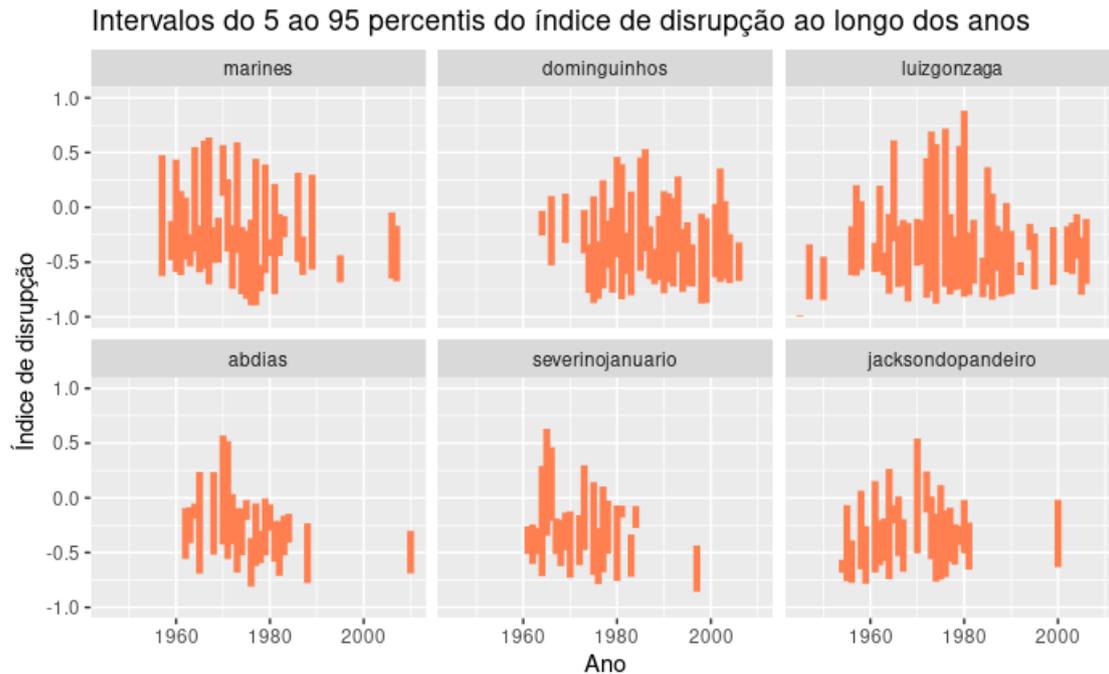


Figura 5.4: Distribuição das disrupções para os artistas mais disruptivos da primeira onda de inovação.

universitárias, inicialmente em 1970 [63], mas com um segundo momento mais forte a partir dos anos 90. O período no qual essa segunda onda de inovação se situa coincide com o desenvolvimento do forró universitário.

A listagem dos artistas mais disruptivos dessa geração ratifica a diferença entre esse segundo momento inovador e aquele influenciado pelos pioneiros. Apesar de ainda se encontrarem em atividade naquele momento, os condutores da primeira onda, como o próprio Gonzaga, Marinês e Dominginhos, não conseguiram manter seus níveis de disrupção elevados. Seu legado, nesse sentido, parece ter sido seguido por artistas como Genival Lacerda (que possui uma música dentro do *top-5* discutido anteriormente), Alcymar Monteiro, Anas-tácia e Flávio José, conforme ilustrado na Figura 5.5.

A Terceira Onda de Inovação (2000 a 2016)

Finalmente, o período iniciado pouco antes do início dos anos 2000 e que perdurou até 2016 (o ano do último disco do *Dataset Forró em Vinil*) também externa um comportamento inovador que, mesmo que discreto, merece referência. Esse último movimento disruptivo

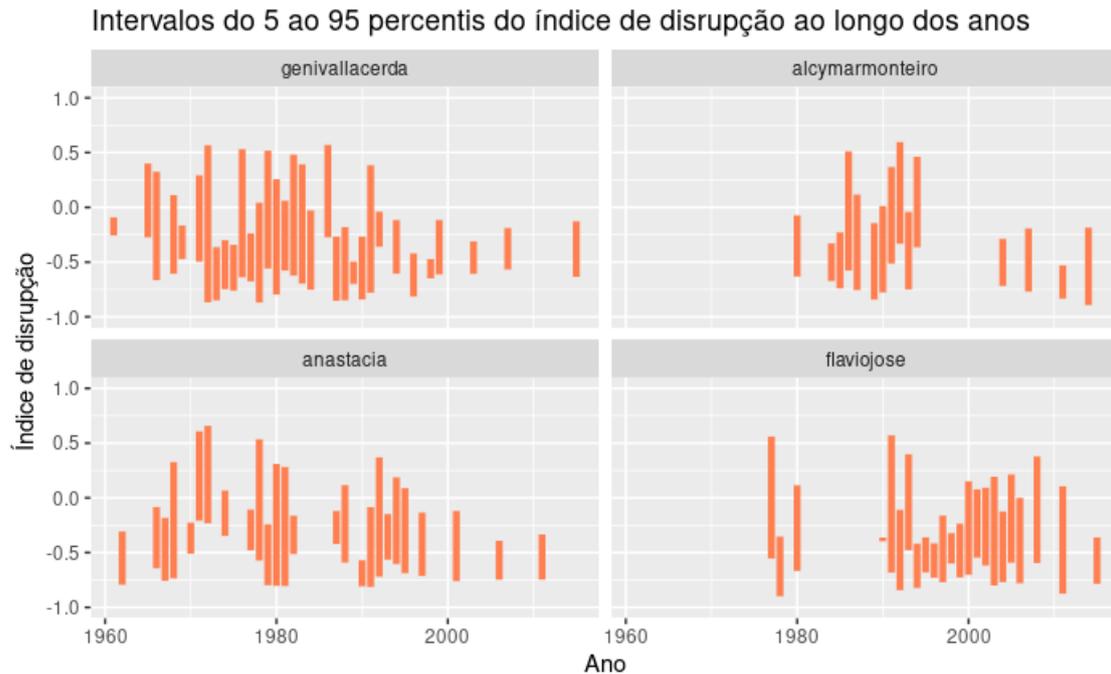


Figura 5.5: Distribuição das disrupções para os artistas responsáveis pela segunda onda de inovação.

apresenta dois picos, consideravelmente mais baixos que os das ondas anteriores, mas em níveis representativos em termos de disrupção.

O levantamento dos artistas mais disruptivos do forró no século XXI, exibido na Figura 5.6 confirma a menor magnitude da carga inovadora dessa era, exibindo poucos (embora que significativos) eventos disruptivos. Vale salientar que esse resultado pode ser justificado pelo fato de os artistas destacados nessa visualização não possuírem muitos álbuns no *dataset*, a contrário do que acontece com boa parte dos artistas mencionados nas outras ondas de inovação. É provável que a existência de mais álbuns destes últimos elevaria o potencial inovador traduzido nas composições a partir de 2000. Mesmo assim, é válido sublinhar as influências disruptivas exercidas por artistas como Falamansa, Trio Virgulino, Mastruz com Leite (que possui uma música dentre as 10 mais disruptivas: *Vaqueiro Apaixonado*), e Targino Gondim.

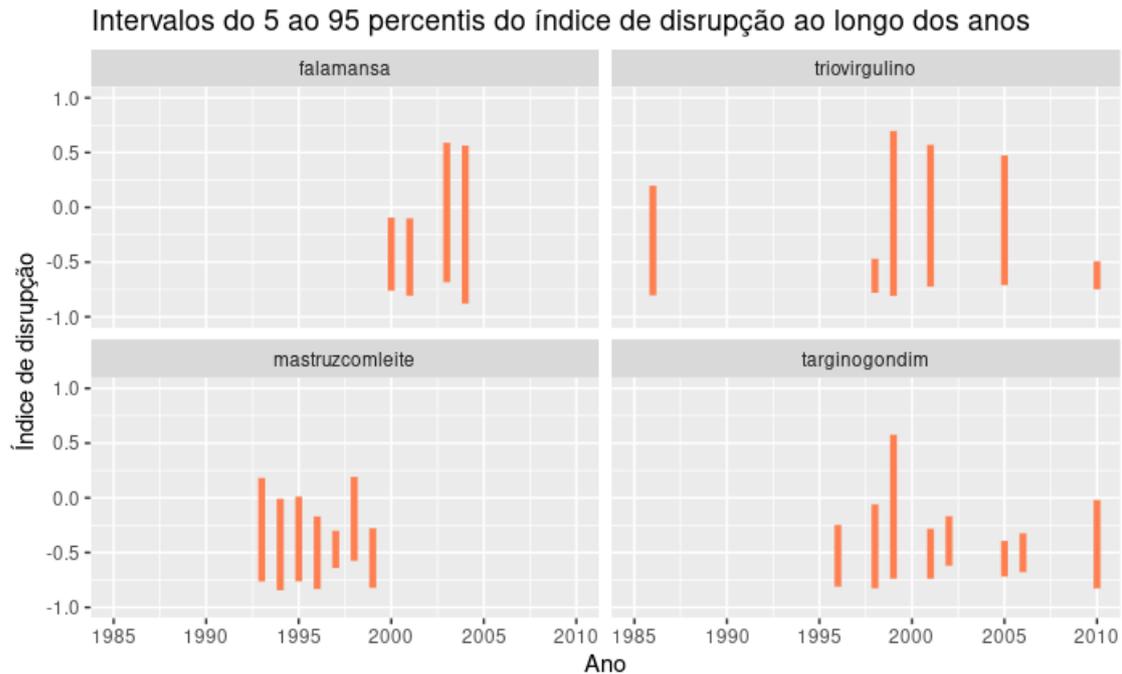


Figura 5.6: Distribuição das interrupções para os artistas responsáveis pela terceira onda de inovação.

5.3 Considerações Finais

Tanto a investigação preliminar sobre redes não ponderadas, a ser discutida no Apêndice A, quanto esse experimento, mais completo e profundo, são estudos complementares e contribuem na defesa das propriedades musicológicas associadas ao índice de interrupção como ferramenta modeladora da inovação musical. O experimento que acaba de ser descrito neste capítulo, em especial, explora o aprimoramento proposto ao índice de interrupção, expandindo sua aplicabilidade a redes ponderadas, algo inédito até o momento. Dessa forma, a primeira conclusão que se pode fazer é que esse aperfeiçoamento amplia ainda mais o conjunto de problemas que podem ser resolvidos por intermédio do uso do índice de interrupção.

Como o decorrer desse estudo de caso, foi possível confirmar algumas suspeitas, como é o caso da importância dos pioneiros do forró durante uma movimentação criativa inicial existente nas primeiras décadas de história do gênero. Com seus elevados potenciais disruptivos, Luiz Gonzaga, Marinês, Jackson do Pandeiro, dentre outros, foram responsáveis pela criação da primeira ponta da linha criativa do forró, dando início a um movimento majoritariamente

consolidador que perdura até os dias de hoje.

Adicionalmente, essa investigação conseguiu identificar também outros dois momentos inovadores presentes na trajetória do forró. O primeiro, com níveis de disrupção próximos ao movimento inicial, compreendido no intervalo entre 1980 e 1995 e influenciado por nomes como Anastácia, Flávio José, Alcymar Monteiro e Genival Lacerda. As descobertas provenientes da análise do índice de disrupção para esse período dão conta de uma nova era no forró, suportada pelos pioneiros e com o acréscimo de instrumentações mais robustas. O segundo momento inovador, bem mais discreto, é observado a partir do início dos anos 2000, com grupos e artistas como Falamansa, Trio Virgulino, Mastruz com Leite e Targino Gondim aplicando esforços na tentativa de, mais uma vez, inovar as bases do forró por meio de novos conceitos musicais. A quantidade de dados existente para esse último grupo, entretanto, se mostra insuficiente para a conclusão de outras razões que expliquem seus níveis disruptivos consideráveis.

Análises dos índices de disrupção agregados por álbuns, artistas e gêneros contribuíram ainda mais na descoberta de novos eventos inovadores presentes na história do forró. Essas investigações revelaram alguns fatos talvez escondidos dentro da rica trajetória do forró, como, por exemplo, o advento do forró instrumental, que teve como um dos precursores Pedro Sertanejo com seu álbum *Rato Molhado*. Além disso, as discussões disparadas pelas altas disrupções do Falamansa e das artistas do movimento feminino em geral consolidam ainda mais a noção de que o índice de disrupção é capaz de trazer à tona para a análise musicológica novas informações sobre os gêneros.

Todas as análises estatísticas realizadas e discutidas durante esse capítulo foram implementadas com o auxílio da linguagem de programação R ⁴. Todo o código criado durante essa etapa de análise pode ser verificado neste *notebook* ⁵.

⁴<https://www.r-project.org/>

⁵<https://rpubs.com/felipevieira/analise-indices-de-disrupcao>

Capítulo 6

Mapa da Inovação do Forró

As análises conduzidas no capítulo anterior exigiram a interpretação tanto da inovação apresentada por músicas quanto das influências exercidas entre estas, e ambas as tarefas se mostraram não triviais. Diferentemente de uma análise focada em artistas, por exemplo, na qual geralmente é mais fácil acessar informações a respeito destes sustentem esses eventos inovadores, numa investigação mais especializada como essa, é impraticável que se haja dados públicos sobre os contextos que envolveram as composições de todas as músicas. Esse fato dificulta consideravelmente a interpretação dos resultados traduzidos pelos índices de disrupção pois faz com que a única fonte de dados disponível para essa tarefa sejam os próprios áudios das músicas. Por esses e outro motivos, levantou-se a necessidade de um sistema de informações dedicado à navegação sobre os dados de disrupção obtidos por este trabalho, de forma que esse fosse destacado com uma série de ferramentas que facilitassem a filtragem de músicas de acordo com critérios úteis à pesquisa e também permitisse que os usuários escutassem os áudios com poucos cliques. Essas foram as motivações que culminaram na concepção e implementação do *Mapa da Inovação do Forró*.

6.1 Requisitos e Funcionalidades

O *Mapa da Inovação do Forró* é uma aplicação *web* desenvolvida no âmbito desta investigação com dois objetivos principais: auxiliar nas análises sobre inovação desencadeadas por esta investigação, e tornar mais didático e interativo o acesso às informações concluídas aqui, de forma que pessoas do mundo inteiro possam, a partir de agora, acessar o sistema e

navegar sobre dados relativos à inovação no forró. É uma aplicação escrita em Typescript ¹, auxiliada pelas bibliotecas React ² e Redux ³, alimentada pelos dados de áudio do *Dataset Forró em Vinil* e pelos resultados dos índices de disrupção calculados no Capítulo 5 deste documento. Tanto os áudios quanto os metadados das músicas e seus respectivos potenciais disruptivos são exibidos aos usuários de maneira interativa e filtrável dentro da plataforma.

A página principal do sistema – que pode ser diretamente acessada por meio do endereço <http://www.mapadainovacao.com> – é exibida na Figura 6.1. Nela é possível observar a listagem geral de todos os álbuns do *dataset*, com a possibilidade de expansão de uma área contendo todas as músicas de cada coleção. Já nesse ponto o usuário pode escutar quaisquer músicas que desejem, visto que cada música segue acompanhada de um *player* HTML responsável pela reprodução dos áudios. Sobre estes, previamente à implementação do sistema todas as músicas do *dataset* foram armazenadas em um *bucket* do serviço de armazenamento da Amazon: o Amazon S3 ⁴, e é direto dessa plataforma que as músicas são servidas à aplicação *web*.

No que se refere aos índices de disrupção, a ferramenta permite tanto a visualização dos índices obtidos para cada música, quanto uma sumarização por álbum, calculada por meio da média de todas as músicas da coleção. Além disso, é fornecida uma função de habilitar e desabilitar um filtro por disrupção, tornando possível definir um intervalo para o índice no qual se deseja focar. Ao habilitar o filtro e definir um intervalo, o sistema atualiza a listagem de álbuns e músicas, mantendo apenas aquelas que se encaixem no critério solicitado. Outros dois filtros são disponibilizados, podendo ser usados ou não conjuntamente com o intervalo de disrupção: década e texto livre, ambos disponíveis na barra de ferramentas no topo da página inicial, como também pode ser visto na Figura 6.1.

Outra funcionalidade presente no sistema é a possibilidade de detalhar mais informações de cada música, habilitando acesso a dados que não são exibidos na listagem da página inicial. Por meio da interação com um botão de informação exibido ao lado de cada música nessa primeira tela é possível o redirecionamento para uma segunda visualização, destacada na Figura 6.2, que lista alguns metadados básicos, como seu nome, artista, álbum e ano,

¹<https://www.typescriptlang.org>

²<https://pt-br.reactjs.org>

³<https://redux.js.org>

⁴<https://aws.amazon.com/pt/s3>

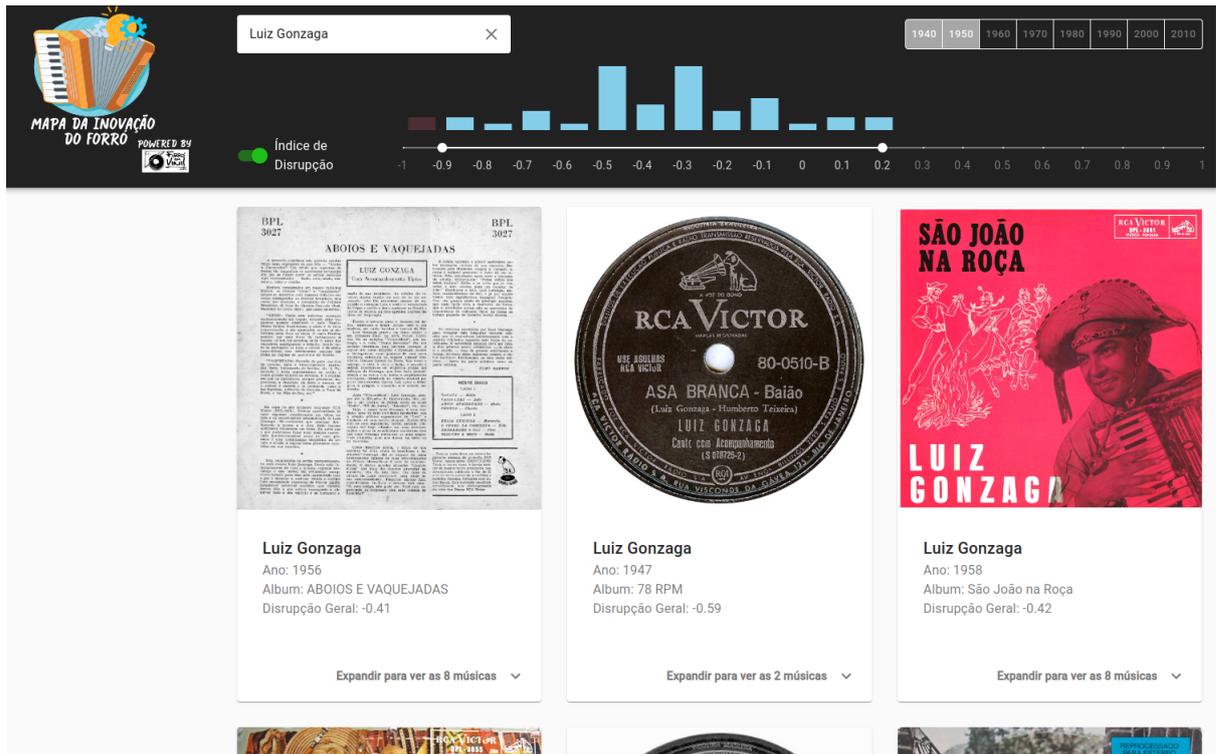


Figura 6.1: Página inicial da aplicação web *Mapa da Inovação do Forró*.

assim como o *player* com o áudio da música, mais uma vez. No tocante à *disrupção*, esse detalhamento traz uma noção nova e que merece uma menção: apesar de, até esse momento, o índice de *disrupção* ter sido tratado com uma métrica de natureza contínua, o *Mapa da Inovação Do Forró*, com mero intuito de visualização, sugere uma discretização da mesma. Isso se evidencia na área de *Estatísticas de Rede*, onde ao lado do índice de *disrupção* é exibida a subclasse semântica de *inovação* sugerida para aquela música. Definiu-se, empiricamente, que a subclasse de *inovação* de uma música a seria definida de acordo com a Fórmula 6.1:

$$subclasse_{inov}(a) = \begin{cases} disruptiva, & \text{se } I_d(a) > 0,3 \\ neutra, & \text{se } -0,3 \leq I_d(a) \leq 0,3 \\ consolidadora, & \text{se } I_d(a) < -0,3 \end{cases} \quad (6.1)$$

Além do próprio índice e da subclasse de *inovação* da música, são também detalhados os valores de n_i , n_j e n_k que compõem a fórmula do índice de *disrupção*.

Outra possibilidade muito útil disponibilizada por essa visualização é a listagem de músicas sucessoras que compartilham influências com a música selecionada (i.e, músicas do tipo i) e daquelas que não compartilham influências (i.e., músicas do tipo j). Essa funcionalidade em particular teve um papel fundamental durante as análises de disrupção propostas, principalmente naquilo que se refere a fornecer indícios que explicassem potenciais inovadores de músicas em particular.

The screenshot displays a music player interface with the following components:

- Header:** A back arrow and the text "Voltar".
- Album Cover:** A portrait of Luiz Gonzaga wearing a hat, with the text "sanfona do povo LUIZ GONZAGA" above it.
- Title and Artist:** "o jumento e nosso irmão" by Luiz Gonzaga.
- Album Info:** "Sanfona do povo (1974)".
- Player:** A play button, volume icon, and progress bar showing 00:00 / 02:51.
- Network Statistics:**
 - Estatísticas na rede**
 - Grau de entrada: 974
 - Grau de saída: 949
 - Grau na rede: 1923
 - Cálculo de disrupção**
 - O que é isso?
 - n_i : 99
 - n_j : 864
 - n_k : 11
 - $D_j = -0.8$ Consolidadora
- Successor Lists:**
 - Músicas sucessoras que não compartilham influências:**
 - Artist: Quinteto Violado, Música: Assum preto (04:55)
 - Artist: Jacinto Limeira, Música: Quem corre cansa (02:26)
 - Artist: Sabino do ar, Música: Baião laranj (00:00)
 - Músicas sucessoras que compartilham influências:**
 - Artist: Dominginhos, Música: sebastiana - coroné antônio b... (00:00)
 - Artist: Trio Nordestino, Música: Trio Nordestino - Forró pesado (00:00)
 - Artist: 1976, Música: Eu Toco As... (00:00)

Figura 6.2: Visualização de detalhamento de uma música no *Mapa da Inovação do Forró*.

Todas essas características supracitadas atribuem ao *Mapa da Inovação do Forró* um grande potencial, tanto no sentido de se tornar um grande catálogo musical (com áudio) de músicas de forró variando desde 1940 até 2016, quanto ao permitir que vários usuários naveguem e validem as informações exibidas no tocante aos potenciais inovadores apresentado por essas músicas durante esse período.

6.2 Considerações Finais

O transcorrer deste capítulo permitiu a apresentação do *Mapa da Inovação do Forró*, ferramenta que foi de fundamental importância no auxílio das análises sobre os resultados atingidos por essa pesquisa. Considera-se que, em um hipotético cenário no qual a ferramenta não existisse, o processo de interpretação das inovações calculadas em momentos anteriores teria que ter sido feito de maneira manual, afetando consideravelmente o andamento de todo o restante da pesquisa. De resto, é visto com muito bons olhos a disponibilização de uma ferramenta pública na internet onde qualquer pessoa possa acessar, manipular e validar os resultados práticos dessa pesquisa.

Capítulo 7

Conclusão e Trabalhos Futuros

Esta investigação propôs o aprimoramento da categorização e quantificação da inovação musical, utilizando para isso redes de similaridade ponderadas extraídas diretamente dos áudios das composições. A fim de atingir esse objetivo, um estudo de caso foi aplicado se utilizando de uma métrica capaz de mensurar níveis de disrupção apresentado por nós em uma rede. Tal experimentação necessitou da coleta de um conjunto de dados único da natureza, composto de informações de áudio referentes a 25.605 músicas de forró oriundas do *website Forró em Vinil* e curadas por meio de procedimentos de correção, de modo a manter as características almejadas para esse *dataset*.

Com a finalidade de construir redes de similaridade que alimentariam a análise das inovações, esforços foram empregados no tocante à validação de medidas de similaridade capazes de modelar as relações de influência entre representações vetoriais das músicas. Propôs-se que tal verificação fosse realizada em dois momentos, sendo o primeiro sediado sobre o próprio *Dataset Forró em Vinil*, e um segundo alimentado pelo *MagnaTagATune Dataset*, um conjunto de dados externo que possui informações de restrições de similaridade amplamente utilizadas pela comunidade de MIR. Essa metodologia concluiu que a similaridade por cosseno despontava como a candidata mais eficaz à tarefa de modelagem de similaridades para esse contexto específico.

Redes de similaridade não ponderadas foram então construídas para suportar a aplicação do índice de disrupção. A extração dos índices de disrupção a partir dessas redes, entretanto, não poderia ser feito por meio do cálculo original da métrica. Logo, esforços foram aplicados no sentido de aprimorar essa fórmula, fazendo-a suportar grafos cujas arestas eram anotadas

com pesos. Uma nova proposição para o cálculo do índice de disrupção foi então concebida para essas circunstâncias. Nesse momento faz-se uma ressalva para um experimento preliminar que motivou esses aprimoramentos sobre o índice de disrupção. Na primeira fase da pesquisa, essa métrica, em sua implementação original, foi aplicada sobre uma rede de similaridade não ponderada que conectava nós por meio da similaridade RBF. Discussões posteriores ao experimento levantaram indagações a respeito de limitações impostas pela conversão de uma rede ponderada em uma não ponderada. Essas reflexões culminaram num replanejamento e na reexecução do experimento assim como descrito no início do parágrafo.

Ambos os experimentos de aplicação e análise do índice de disrupção, tanto sobre redes não ponderadas quanto ponderadas, evidenciam o potencial musicológico associado à métrica, o que era um dos objetivos específicos da pesquisa. Prova disso são as descobertas feitas sobre os movimentos inovadores ocorridos durante a trajetória do forró, desde 1940 até próximo aos dias atuais. Os índices de disrupção agregados por diferentes épocas nos dois experimentos confirmam, por exemplo, a importância dos pioneiros do forró (Luiz Gonzaga, Marinês, Jackson do Pandeiro, dentre outros) nos esforços criativos iniciais. Além disso, o segundo experimento foi capaz de revelar a existência de outros dois fortes movimentos inovadores posteriores à década de 1970, exemplificando também como disruptivos nesses períodos artistas como Flávio José, Genival Lacerda, Falamansa, e outros. Os *rankings* de músicas mais disruptivas reforçam a importância desses artistas, também levantando motivos que alimentaram altas cargas criativas em cada um dos períodos. Os dados do índice de disrupção agregados complementam essa análise, levantando descobertas sobre artistas, álbuns e gêneros que tiveram papel de destaque no cenário inovador do forró.

Todas as informações de disrupção calculadas e discutidas durante o experimento sobre as redes ponderadas podem ser publicamente acessadas por meio de uma sistema criado exclusivamente para facilitar a visualização dos resultados encontrados. A aplicação *web Mapa da Inovação do Forró* está disponível no endereço <http://www.mapadainovacao.com> e é munida de um conjunto de ferramentas que permite aos usuários a possibilidade visualizar e filtrar dados de disrupção referentes às músicas do *Dataset Forró em Vinil*, além de ter acesso aos áudios das composições. Acredita-se que essa ferramenta, além de dar mais publicidade e tornar mais didático todo o material discutido nesta investigação, tem potencial para se tornar um meio de validar a longo prazo os resultados relativos à inovação

apresentada pelo forró durante essas sete décadas.

Sob um ponto de vista geral deste estudo, argumenta-se em favor da utilização do índice de interrupção como ferramenta única do tipo e capaz de modelar os comportamentos inovadores apresentados por músicas, álbuns e artistas durante as trajetórias musicais do gênero. Em especial, acredita-se que a proposição de uma nova estratégia de cálculo para o índice vem como forma de acrescentar ainda mais ao seu potencial, expandido os contextos nos quais a mesma pode ser utilizada.

7.1 Limitações e Trabalhos Futuros

Toda a metodologia aplicada nesta investigação foi conduzida de modo a mitigar ao máximo possíveis ameaças à validade. Entretanto, é relevante trazer à tona algumas limitações que merecem uma atenção especial a fim de generalizar melhor os resultados discutidos no transcorrer deste documento. A primeira delas diz respeito à qualidade dos áudios coletados para alguns álbuns do *Forró em Vinil*. Como o próprio nome deixa bem claro, algumas dessas gravações foram digitalizadas diretamente de mídias antigas, como discos de vinil, discos de 78 rotações e fitas cassete. Além disso, não havia por parte dos colaboradores do *website* a padronização e fiscalização dos níveis de volume mínimos aceitáveis para as músicas, então algumas gravações possuem volumes mais altos enquanto que outras são menos audíveis. Esses e outros fatores podem ter feito com que algumas canções que poderiam ter potencial disruptivo e influenciar na análise fossem ignoradas durante nosso estudo por conta desses fatores externos. Sugere-se aqui, portanto, a condução de um novo estudo cuja padronização do conteúdo de áudio seja ainda mais eficaz, de forma a minimizar o efeito da qualidade do áudio nas análises de interrupção sugeridas.

Além disso, e também relacionado ao item anterior, muito embora o estudo de caso proposto seja rico e tenha permitido a ampla exemplificação da utilidade do índice de interrupção, acredita-se que para uma melhor generalização dos resultados o mesmo precisa ser aplicado em outros gêneros musicais além do forró. Indo além, a aplicação de estudos de caso sobre outros gêneros musicais mais globalmente difundidos, como o *rock*, o *reggae* ou o *jazz*, por exemplo, pode permitir uma melhor validação dos níveis de inovação calculados por meio da comparação com análises musicológicas já feitas acerca das trajetórias desse gênero [70; 16;

66]. Algo dessa natureza foi buscada para o forró nesta investigação, porém a regionalidade do mesmo impediu que um *ground-truth* mais preciso fosse obtido.

Como pudemos observar, a nova proposição para a classificação dos sucessores dos nós focais (Fórmula 2.3) em redes ponderadas introduz o conceito do *LIMIAR* de similaridade. Esta pesquisa em particular utilizou uma metodologia personalizada para a definição desse número, mas defende-se também a experimentação com outras faixas de valores. Além disso, por se tratar de uma proposta nova, existe ampla margem para melhoria da mesma, principalmente no que se refere ao número de predecessores utilizados no cálculo da diferença com o passado do nó focal e da métrica de sumarização utilizada para resumir as similaridades individuais.

Similar ao que foi conduzido por Figueiredo e Andrade [22] em sua investigação, é de extrema importância confirmar mensurar a quantidade de informação nova que o índice de disrupção traz à análise de redes. Em especial, a análise de correlação entre os índices dos nós e outras métricas de centralidade (e.g., *Pagerank Centrality*, *Pagerank Centrality*, *Hub Score*) se faz necessária para concluir que essa nova métrica é, também do ponto de vista estrutural de redes, única naquilo que se propõe a fazer.

Finalmente, acredita-se que a inclusão de *features* de áudio de outras naturezas viriam a enriquecer ainda mais a rede de similaridades modelada, refletindo nas descobertas de inovação resultantes da aplicação do índice de disrupção. Mais especificamente, defende-se aqui a utilização do sinal de áudio puro (i.e., englobando todos os aspectos acústicos: melodia, ritmo, timbre, etc.) em conjunto com abordagens capazes de aprender a calcular distâncias entre essas representações (e.g., *similarity learning* ou *metric learning*) como forma de calcular índices de disrupção ainda mais completos e capazes de modelar todos os tipos de relações musicais entre músicas, álbuns e artistas com o passar do tempo.

Bibliografia

- [1] Fabio Aiolli. Efficient top-n recommendation for very large scale binary rated datasets. In *Proceedings of the 7th ACM conference on Recommender systems*, pages 273–280. ACM, 2013.
- [2] J Antoni and RB Randall. Unsupervised noise cancellation for vibration signals: part ii—a novel frequency-domain algorithm. *Mechanical Systems and Signal Processing*, 18(1):103–117, 2004.
- [3] J Antoni and RB Randall. Unsupervised noise cancellation for vibration signals: part i—evaluation of adaptive algorithms. *Mechanical Systems and Signal Processing*, 18(1):89–101, 2004.
- [4] Olivier Bachem, INF ETHZ, Mario Lucic, and ETHZ CH. Scalable and distributed clustering via lightweight coresets. *stat*, 1050:27, 2017.
- [5] Thierry Bertin-Mahieux, Daniel PW Ellis, Brian Whitman, and Paul Lamere. The million song dataset. 2011.
- [6] Jesús Bobadilla, Antonio Hernando, Fernando Ortega, and Abraham Gutiérrez. Collaborative filtering based on significances. *Information Sciences*, 185(1):1–17, 2012.
- [7] F Bonnardot, RB Randall, J Antoni, and F Guillet. Enhanced unsupervised noise cancellation using angular resampling for planetary bearing fault diagnosis. *International journal of acoustics and vibration*, 9(2):51–60, 2004.
- [8] Joseph L Bower and Clayton M Christensen. Disruptive technologies: catching the wave. 1995.

-
- [9] Sungkyun Chang, Juheon Lee, Sang Keun Choe, and Kyogu Lee. Audio cover song identification using convolutional neural network. *arXiv preprint arXiv:1712.00166*, 2017.
- [10] Kyunghyun Cho. Boltzmann machines and denoising autoencoders for image denoising. *arXiv preprint arXiv:1301.3468*, 2013.
- [11] Keunwoo Choi, George Fazekas, and Mark Sandler. Automatic tagging using deep convolutional neural networks. *arXiv preprint arXiv:1606.00298*, 2016.
- [12] Keunwoo Choi, György Fazekas, Mark Sandler, and Kyunghyun Cho. Convolutional recurrent neural networks for music classification. In *2017 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, pages 2392–2396. IEEE, 2017.
- [13] Keunwoo Choi, György Fazekas, Mark Sandler, and Kyunghyun Cho. Transfer learning for music classification and regression tasks. *arXiv preprint arXiv:1703.09179*, 2017.
- [14] Franz De Leon and Kirk Martinez. Enhancing timbre model using mfcc and its time derivatives for music similarity estimation. In *2012 Proceedings of the 20th European Signal Processing Conference (EUSIPCO)*, pages 2005–2009. IEEE, 2012.
- [15] Antonio Carlos de Quadros Junior and Catia Mary Volp. Forró universitário: a tradução do forró nordestino no sudeste brasileiro. *Motriz. Journal of Physical Education. UNESP*, pages 117–120, 2005.
- [16] Lisa Dettling. *Geography and Innovation in Rock and Roll*. PhD thesis, The Ohio State University, 2007.
- [17] Nat Dilokthanakul, Pedro AM Mediano, Marta Garnelo, Matthew CH Lee, Hugh Salimbeni, Kai Arulkumaran, and Murray Shanahan. Deep unsupervised clustering with gaussian mixture variational autoencoders. *arXiv preprint arXiv:1611.02648*, 2016.
- [18] Simon Dixon. Onset detection revisited. In *Proceedings of the 9th International Conference on Digital Audio Effects*, volume 120, pages 133–137. Citeseer, 2006.

- [19] Daniel PW Ellis. Classifying music audio with timbral and chroma features. 2007.
- [20] Daniel PW Ellis and Graham E Poliner. Identifying cover songs' with chroma features and dynamic programming beat tracking. In *2007 IEEE International Conference on Acoustics, Speech and Signal Processing-ICASSP'07*, volume 4, pages IV–1429. IEEE, 2007.
- [21] Felipe Falcao, Baris Bozkurt, Xavier Serra, Nazareno Andrade, and Ozan Baysal. A dataset of rhythmic pattern reproductions and baseline automatic assessment system. In *Proceedings of the 20th Conference of the International Society for Music Information Retrieval (ISMIR 2019): 2019 Nov 4-8; Delft, The Netherlands.[Canada]: ISMIR; 2019*. International Society for Music Information Retrieval (ISMIR), 2019.
- [22] Flavio Figueiredo and Nazareno Andrade. Quantifying disruptive influence in the all-music guide.
- [23] Russell J Funk and Jason Owen-Smith. A dynamic network measure of technological change. *Management Science*, 63(3):791–817, 2016.
- [24] Isak Gath and Amir B. Geva. Unsupervised optimal fuzzy clustering. *IEEE Transactions on pattern analysis and machine intelligence*, 11(7):773–780, 1989.
- [25] Zoubin Ghahramani. Unsupervised learning. In *Summer School on Machine Learning*, pages 72–112. Springer, 2003.
- [26] Spyros Gidaris, Praveer Singh, and Nikos Komodakis. Unsupervised representation learning by predicting image rotations. *arXiv preprint arXiv:1803.07728*, 2018.
- [27] Lovedeep Gondara. Medical image denoising using convolutional denoising autoencoders. In *2016 IEEE 16th international conference on data mining workshops (ICDMW)*, pages 241–246. IEEE, 2016.
- [28] Philippe Hamel, Matthew EP Davies, Kazuyoshi Yoshii, and Masataka Goto. Transfer learning in mir: Sharing learned latent representations for music audio classification and similarity. 2013.

- [29] Shunjie Han, Cao Qubo, and Han Meng. Parameter selection in svm with rbf kernel function. In *World Automation Congress 2012*, pages 1–4. IEEE, 2012.
- [30] Wei Han, Cheong-Fat Chan, Chiu-Sing Choy, and Kong-Pang Pun. An efficient mfcc extraction method in speech recognition. In *2006 IEEE international symposium on circuits and systems*, pages 4–pp. IEEE, 2006.
- [31] Yahong Han, Fei Wu, Dacheng Tao, Jian Shao, Yueting Zhuang, and Jianmin Jiang. Sparse unsupervised dimensionality reduction for multiple view data. *IEEE Transactions on Circuits and Systems for Video Technology*, 22(10):1485–1496, 2012.
- [32] Jonathan L Herlocker, Joseph A Konstan, and John Riedl. Explaining collaborative filtering recommendations. In *Proceedings of the 2000 ACM conference on Computer supported cooperative work*, pages 241–250, 2000.
- [33] André Holzapfel, Yannis Stylianou, Ali C Gedik, and Barış Bozkurt. Three dimensions of pitched instrument onset detection. *IEEE Transactions on Audio, Speech, and Language Processing*, 18(6):1517–1527, 2009.
- [34] Jesper Højvang Jensen, Mads Græsbøll Christensen, Manohar N Murthi, and Søren Holdt Jensen. Evaluation of mfcc estimation techniques for music similarity. In *2006 14th European Signal Processing Conference*, pages 1–5. IEEE, 2006.
- [35] Chaoya Jiang, Deshun Yang, and Xiaou Chen. Similarity learning for cover song identification using cross-similarity matrices of multi-level deep sequences. In *ICASSP 2020-2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, pages 26–30. IEEE, 2020.
- [36] Anssi Klapuri. Sound onset detection by applying psychoacoustic knowledge. In *1999 IEEE International Conference on Acoustics, Speech, and Signal Processing. Proceedings. ICASSP99 (Cat. No. 99CH36258)*, volume 6, pages 3089–3092. IEEE, 1999.
- [37] Gursimran Kour and Neha Mehan. Music genre classification using mfcc, svm and bpnn. *International Journal of Computer Applications*, 112(6), 2015.
- [38] Aswani Ch Kumar. Analysis of unsupervised dimensionality reduction techniques. *Computer science and information systems*, 6(2):217–227, 2009.

- [39] Edith Law, Kris West, Michael I Mandel, Mert Bay, and J Stephen Downie. Evaluation of algorithms using games: The case of music tagging. In *ISMIR*, pages 387–392. Citeseer, 2009.
- [40] Hsin-Ying Lee, Jia-Bin Huang, Maneesh Singh, and Ming-Hsuan Yang. Unsupervised representation learning by sorting sequences. In *Proceedings of the IEEE International Conference on Computer Vision*, pages 667–676, 2017.
- [41] Dawen Liang, Haijie Gu, and Brendan O’Connor. Music genre classification with the million song dataset. *Machine Learning Department, CMU*, 2011.
- [42] Blerina Lika, Kostas Kolomvatsos, and Stathes Hadjiefthymiades. Facing the cold start problem in recommender systems. *Expert Systems with Applications*, 41(4):2065–2073, 2014.
- [43] Quanzhong Liu, Chihau Chen, Yang Zhang, and Zhengguo Hu. Feature selection for support vector machines with rbf kernel. *Artificial Intelligence Review*, 36(2):99–115, 2011.
- [44] Beth Logan and Ariel Salomon. A music similarity function based on signal analysis. In *ICME*, pages 22–25, 2001.
- [45] Matthias Mauch, Robert M MacCallum, Mark Levy, and Armand M Leroi. The evolution of popular music: Usa 1960–2010. *Royal Society open science*, 2(5):150081, 2015.
- [46] Rudolf Mayer and Andreas Rauber. Multimodal aspects of music retrieval: Audio, song lyrics—and beyond? In *Advances in music information retrieval*, pages 333–363. Springer, 2010.
- [47] Brian McFee, Luke Barrington, and Gert RG Lanckriet. Learning similarity from collaborative filters. In *ISMIR*, pages 345–350, 2010.
- [48] Brian McFee and Gert Lanckriet. Mirex 2011 ams-audio similarity via metric learning.

- [49] Lindasalwa Muda, Mumtaj Begam, and Irraivan Elamvazuthi. Voice recognition algorithms using mel frequency cepstral coefficient (mfcc) and dynamic time warping (dtw) techniques. *arXiv preprint arXiv:1003.4083*, 2010.
- [50] Monica S Nagawade and Varsha R Ratnaparkhe. Musical instrument identification using mfcc. In *2017 2nd IEEE International Conference on Recent Trends in Electronics, Information & Communication Technology (RTEICT)*, pages 2198–2202. IEEE, 2017.
- [51] Mizuho Nishio, Chihiro Nagashima, Saori Hirabayashi, Akinori Ohnishi, Kaori Sasaki, Tomoyuki Sagawa, Masayuki Hamada, and Tatsuo Yamashita. Convolutional auto-encoder for image denoising of ultra-low-dose ct. *Heliyon*, 3(8):e00393, 2017.
- [52] Min Woo Park and Eui Chul Lee. Similarity measurement method between two songs by using the conditional euclidean distance. *Wseas Transaction On Information Science And Applications*, 10:12, 2013.
- [53] Jordi Pons and Xavier Serra. musicnn: Pre-trained convolutional neural networks for music audio tagging. *arXiv preprint arXiv:1909.06654*, 2019.
- [54] Alastair Porter, Mohamed Sordo, and Xavier Serra. Dunya: A system for browsing audio music collections exploiting cultural context. In *Britto A, Gouyon F, Dixon S. 14th International Society for Music Information Retrieval Conference (ISMIR); 2013 Nov 4-8; Curitiba, Brazil.[place unknown]: ISMIR; 2013. p. 101-6*. International Society for Music Information Retrieval (ISMIR), 2013.
- [55] Gang Qian, Shamik Sural, Yuelong Gu, and Sakti Pramanik. Similarity between euclidean and cosine angle distance for nearest neighbor queries. In *Proceedings of the 2004 ACM symposium on Applied computing*, pages 1232–1237, 2004.
- [56] Kamisetty Ramamohan Rao, Do Nyeon Kim, and Jae Jeong Hwang. Fast fourier transform: algorithms and applications. 2010.
- [57] Halfdan Rump, Shigeki Miyabe, Emiru Tsunoo, Nobutaka Ono, and Shigeki Sa-gayama. Autoregressive mfcc models for genre classification improved by harmonic-percussion separation. In *ISMIR*, pages 87–92. Citeseer, 2010.

-
- [58] Justin Salamon and Emilia Gómez. A chroma-based salience function for melody and bass line estimation from music audio signals. In *Proc. of Sound and Music Computing Conference (SMC)*, pages 331–336. Citeseer, 2009.
- [59] Suvash Sedhain, Scott Sanner, Darius Braziunas, Lexing Xie, and Jordan Christensen. Social collaborative filtering for cold-start recommendations. In *Proceedings of the 8th ACM Conference on Recommender systems*, pages 345–348, 2014.
- [60] Xavier Serra. The computational study of a musical culture through its digital traces. *Acta Musicologica*, 89(1):24–44, 2017.
- [61] Uri Shalit, Daphna Weinshall, and Gal Chechik. Modeling musical influence with topic models. In *International Conference on Machine Learning*, pages 244–252, 2013.
- [62] Diego Furtado Silva, Chin-Chia Michael Yeh, Gustavo EAPA Batista, Eamonn J Keogh, et al. Simple: Assessing music similarity using subsequences joins. In *ISMIR*, pages 23–29, 2016.
- [63] Expedito Leandro Silva. *Forró no asfalto: mercado e identidade sociocultural*. Annablume, 2003.
- [64] David Simonelli. Anarchy, pop and violence: Punk rock subculture and the rhetoric of class, 1976-78. *Contemporary British History*, 16(2):121–144, 2002.
- [65] Malcolm Slaney, Kilian Weinberger, and William White. Learning a metric for music similarity. In *International Symposium on Music Information Retrieval (ISMIR)*, volume 148, 2008.
- [66] Gareth Dylan Smith and Alex Gillett. Creativities, innovation, and networks in garage punk rock: A case study of the eruptörs. *Artivate*, 4(1):9–24, 2015.
- [67] Julius Orion Smith. *Mathematics of the discrete Fourier transform (DFT): with audio applications*. Julius Smith, 2007.
- [68] Xiaoyuan Su and Taghi M Khoshgoftaar. A survey of collaborative filtering techniques. *Advances in artificial intelligence*, 2009, 2009.

-
- [69] Vibha Tiwari. Mfcc and its applications in speaker recognition. *International journal on emerging technologies*, 1(1):19–22, 2010.
- [70] Peter Tschmuck. *Creativity and innovation in the music industry*. Springer, 2006.
- [71] George Tzanetakis. Computational ethnomusicology: a music information retrieval perspective. In *ICMC*, 2014.
- [72] Aaron Van den Oord, Sander Dieleman, and Benjamin Schrauwen. Deep content-based music recommendation. In *Advances in neural information processing systems*, pages 2643–2651, 2013.
- [73] Jean-Philippe Vert, Koji Tsuda, and Bernhard Schölkopf. A primer on kernel methods. *Kernel methods in computational biology*, 47:35–70, 2004.
- [74] Kris West, Stephen Cox, and Paul Lamere. Incorporating machine-learning into music similarity estimation. In *Proceedings of the 1st ACM workshop on Audio and music computing multimedia*, pages 89–96, 2006.
- [75] Brian Whitman and Steve Lawrence. Inferring descriptions and similarity for music from community metadata. In *ICMC*. Citeseer, 2002.
- [76] Daniel Wolff and Tillman Weyde. Learning music similarity from relative user ratings. *Information retrieval*, 17(2):109–136, 2014.
- [77] Lingfei Wu, Dashun Wang, and James A Evans. Large teams have developed science and technology; small teams have disrupted it. 2017.

Apêndice A

Índice de Disrupção em Redes de Similaridade Não-Ponderadas

Este apêndice trata de uma experimentação preliminar realizada com o índice de disrupção. Muito embora as duas investigações compartilhem uma parte considerável de suas metodologias, existem algumas diferenças importantes que precisam ser apontadas. Primeiramente, o planejamento desse experimento foi feito de forma a executá-lo sobre uma rede de similaridades não ponderada, assim como havia sido proposto em todos os estudos anteriores sobre o índice de disrupção. Além disso, por se tratar de um estudo feito em uma etapa anterior da pesquisa, este experimento não possuía os benefícios da validação da similaridade por cossenos - usada no experimento do Capítulo 5. Àquela altura única métrica de similaridade validade havia sido a similaridade RBF, e uma vez que sua eficácia havia sido comprovada, procedeu-se com sua utilização na construção da rede. A última diferença entre os dois experimentos diz respeito à versão do *Dataset Forró em Vinil*. A experimentação proposta nesse apêndice foi conduzida sobre a versão do *dataset* resultante da primeira etapa de correção, que culminou na construção de um conjunto de dados com 27.352 músicas, um pouco maior do que as 25.605 composições consideradas na investigação mais recente.

Exceto por essas três mudanças mencionadas, o restante do *design* experimental adotado nesse primeiro momento foi muito semelhante ao conduzido posteriormente. Em posse do *dataset* com as representações musicais e a métrica de similaridade que modelaria as relações entre as músicas, foi construída uma rede de similaridades sem a presença dos pesos nas arestas. O índice de disrupção foi, então, aplicado sobre essa rede e todas as discussões

relevantes foram levantadas e documentadas.

A.1 Construção da Rede de Similaridades

Conforme já descrito, a rede de similaridades a ser construída teria como nós as músicas do *Dataset Forró em Vinil*. Já a respeito das arestas: muito embora a similaridade RBF fosse capaz de modelar o nível de semelhança entre quaisquer pares de músicas, a escolha binária que implica na criação ou não de uma aresta entre essas duas composições na rede não era intuitiva. Foi necessária então a proposição de alguma metodologia que, dada a similaridade entre um par de músicas, definisse se aquele valor seria suficiente para a derivação de uma relação de influência entre ambas. Isso foi feito a partir da determinação de um limiar mínimo de similaridade, acima do qual pudesse-se afirmar que uma existia alguma relação entre tais músicas.

A fim de selecionar empiricamente esse limiar, mais uma vez foi feito uso de uma percepção musical óbvia análoga à proposta durante a validação descrita no Capítulo 5. Aqui, beneficiou-se do fato de que músicas de um mesmo álbum tendem a ser bastante similares entre si, o que torna as similaridades médias entre músicas de um mesmo álbum um bom candidato de limiar mínimo de similaridade a ser usado com o intuito de garantir as relações de influência. Para verificar qual seria o valor exato desse limiar dentro do *dataset*, foi necessária uma varredura sobre todos os álbuns do mesmo. Em cada iteração (i.e., cada álbum) obtinham-se todas as combinações de pares de música e calculavam-se as similaridades RBF para cada par. Ao final de cada iteração, as similaridades eram sumarizadas com a média e esse valor era salvo para posterior verificação. A varredura completa coletou 2.293 médias de similaridades por álbum, e o valor médio obtido para essa coleção foi de 0,897. Finalmente, aplicando uma aproximação direta desse valor, essa abordagem culminou em um valor para o limiar mínimo de similaridade de 0,90.

Adicionalmente, foi aplicada uma janela temporal dentro da qual duas músicas deveriam estar inseridas a fim de que uma aresta fosse criada entre ambas. Esse novo requisito foi idealizado com dois objetivos principais: primeiro, a utilização dessa abordagem limita uma distância temporal máxima entre duas músicas, simulando um fator de esquecimento que reflete o contexto musical, até certo ponto. Dado que o cenário musical é dinâmico, com

novas propostas de arranjos musicais, instrumentações e temáticas sociais sendo propostas a todo tempo, é real a constatação que a probabilidade de uma música m_2 influenciar de fato uma música m_1 diminui à medida que m_2 se afasta cronologicamente de m_1 . Além disso, a aplicação da janela temporal ajuda a garantir que todos os nós (músicas) da rede possuem um número semelhante de predecessores e sucessores. Essa garantia ajuda a assegurar um certo grau de justiça no momento do cálculo das disrupções para diferentes nós, uma vez que este depende diretamente do número de predecessores e sucessores. O tamanho dessa janela temporal foi ajustado de acordo com valores já utilizados por outros estudos [77], sendo determinado um intervalo de 10 anos dentro do qual duas músicas deveriam estar inseridas a fim de se criar uma conexão entre elas.

Consideradas todas as diretrizes definidas até agora, chega-se no ponto no qual já é possível realizar a construção da rede de similaridades com base no *Dataset Forró em Vinil*. A fim de atingir esse objetivo, varreu-se novamente o conjunto de músicas de forró contempladas pelo *dataset* em ordem cronológica (i.e., da música mais antiga para a mais recente). Para cada música s varrida, eram obtidas todas as músicas que precediam s cronologicamente. Analisando as similaridades entre s e esse subconjunto de músicas, criavam-se arestas entre s e s' apenas se a similaridade entre s e s' fosse maior que liminar mínimo de 0,90 e se ambas não fossem mais que 10 anos distantes no tempo. Esse procedimento garantia o cálculo das influências acústicas de cada entrada do *dataset*, de acordo com a similaridade RBF, e entregou, ao final de toda a varredura, a rede de similaridades necessária para o cálculo do índice de disrupção. Todo processo de construção da rede foi auxiliado pela biblioteca NetworkX¹, disponível para a linguagem de programação Python. Ademais, o grafo construído foi exportado em formato *Graph Exchange XML Format* (GEXF) para posteriores análises, tendo o arquivo um tamanho total de 489,3 megabytes (MB) e sendo também disponibilizado como parte do *Dataset Forró em Vinil*.

A.2 Características da Rede de Similaridades

Das 27.352 músicas contempladas pela versão do *Dataset Forró em Vinil* utilizada nesse experimento, 26.452 estavam incluídas na rede calculada, conectadas por meio de 5.728.466

¹<https://networkx.org>

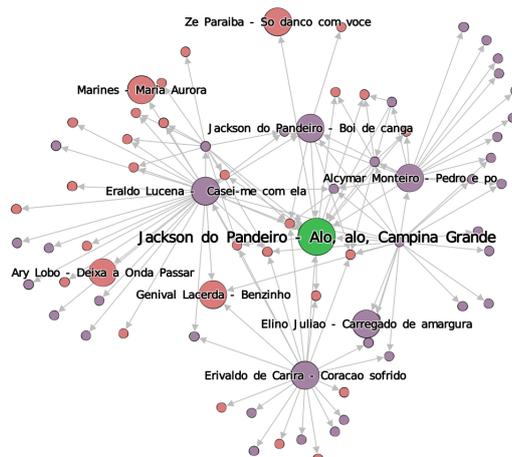


Figura A.1: Rede egocêntrica para *Alô, alô, Campina Grande*, de *Jackson do Pandeiro*. Os nós que precederam e sucederam o nó focal são representados em vermelho e roxo, respectivamente.

arestas dirigidas distintas. Essa pequena diferença entre o número total de músicas e a contagem real de nós da rede se explica pela última etapa do processo de montagem da mesma, consistente na remoção de nós desconexos (i.e., músicas que não eram suficientemente semelhantes a nenhuma outra). No que se refere à estrutura geral da rede, apesar serem evidenciadas pequenas sub-redes desconectadas do restante da macroestrutura, 98% de todos os nós estavam densamente conectados ao mesmo componente gigante. A estrutura dessa rede pode ser evidenciada na Figura A.1, que mostra a rede egocêntrica centralizada em torno da música *Alô, Alô, Campina Grande*, do cantor, compositor e multi-instrumentista paraibano Jackson do Pandeiro. A rede mostra o nó focal, cercado das suas influências predecessoras (em vermelho) a músicas que foram influenciadas pela composição de Jackson.

Algumas estatísticas da rede são sumarizadas pela Tabela A.1. Além disso, a distribuição dos graus de entrada e saída dos nós da estrutura está esquematizada na Figura A.2. Nela, conseguimos ver que ambas as distribuições são semelhantes, possuindo assimetria e enviesamento para a esquerda, concentradas em valores baixos (as maiores contagens ficam entre graus de entrada de 0 e 50 para ambas as distribuições).

Estatística da Rede	Valor
Número de Nós	26.452
Número de Arestas	5.728.466
Diâmetro	25
Densidade	0,008
Componentes Conectados	7914
Coefficiente de Clusterização Médio	0,203

Tabela A.1: Estatísticas da rede de similaridades construída.

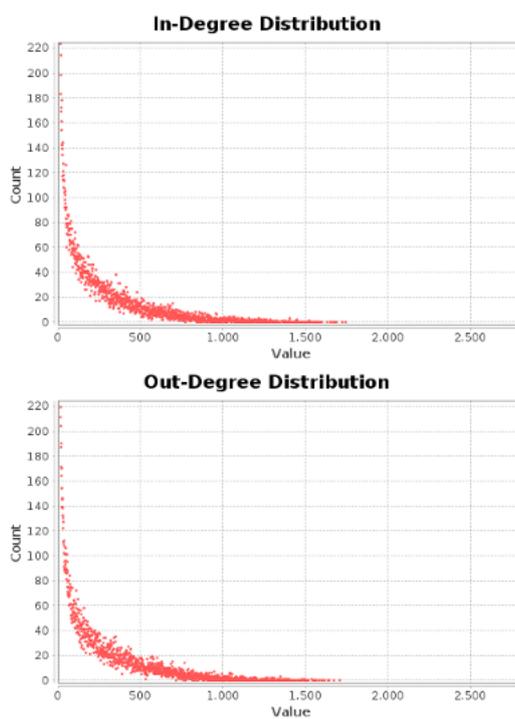


Figura A.2: Distribuição dos graus de entrada e saída da rede de similaridades.

A.3 Análise das Disrupções

A construção da rede de similaridades é a última etapa anterior à caracterização das inovações apresentadas por cada nó via aplicação do índice de disrupção. Dado que à essa altura da investigação essa rede já havia sido construída se utilizando das representações musicais do *Dataset Forró em Vinil*, foi então possível combinar essa estrutura com a fórmula descrita no Capítulo 2 a fim de derivar as métricas de disrupções para cada nó e disparar as devidas discussões envolvendo os potenciais inovadores de músicas e artistas presentes na história do forró.

Como discutido anteriormente, o cálculo do índice de disrupção conforme proposto por Funk e Owen-Smith depende de itens que precederam o nó focal do qual se deseja extrair a disrupção. Dessa forma, nós sem ou com poucos predecessores não possuem informação suficiente para a computação correta da métrica. Essa natureza do índice de disrupção faz com que sua aplicação não seja útil nas primeiras músicas do *dataset*, apesar de que as mesmas seguem sendo de grande utilidade no cálculo de disrupção de outros nós, pelo fato de serem predecessores dos mesmos. Logo, durante a análise das inovações dessa primeira rede, foram ignorados os cálculos de disrupção de músicas provenientes das duas primeiras décadas cobertas pelo *Dataset Forró em Vinil*: 1940 e 1950. Excluindo-se músicas dessa década inicial, todas as outras composições do *dataset* tiveram suas disrupções calculadas de acordo com as contagens dos sucessores do tipo i , j e k , como também explicado no Capítulo 2.

A.3.1 Músicas Mais Disruptivas

A primeira análise decorrente dos cálculos das disrupções se refere às músicas mais disruptivas dentre as presentes no *dataset*. A Tabela A.3 lista as cinco músicas mais disruptivas encontradas durante essa investigação, descrevendo seus metadados mais básicos (nome, artista e ano). Além disso, é possível verificar nessa tabela alguns esforços preliminares feitos no sentido de, mediante a escuta das músicas, buscar justificativas que pudessem explicar as altas disrupções encontradas. A primeira implicação desses resultados iniciais é que, apesar de a influência do artista em si não ser um requisito obrigatório para se determinar a disrupção a nível de músicas, é de certa forma significativo evidenciar que músicas de artis-

Música	Artista	Álbum (ano)	Índice de Disrupção & Comentários
<i>Padrinho Cícero do Juazeiro</i>	<i>Trio Juazeiro</i>	<i>Pedaço de fulô (1982)</i>	$D = 1$ ($n_i = 37, n_j = 0, n_k = 0$). Uma música rápida (batidas por minuto (BPM): 140) com um claro e complexo arranjo de sanfona. A rede egocêntrica desse nó evidencia conexões com múltiplas músicas de mesmos álbuns, o que pode indicar o surgimento de uma nova e disruptiva configuração acústica que foi adotada por sucessores, como <i>Clemilda e Roberto do Acordeon</i> .
<i>Namorada de João</i>	<i>Coroné Narcisinho</i>	<i>Forró do Serrado (1969)</i>	$D = 1$ ($n_i = 28, n_j = 0, n_k = 0$). Essa música traz um triângulo muito perceptível como parte da sua configuração percussiva, algo que não consegue ser percebido em muitas das músicas da mesma época. Triângulos dominantes também conseguem ser escutados em muitas das músicas que sucederam <i>Namorada de João</i> . como <i>Esse forró eu danço (Abdias - 1977)</i> .
<i>Sem vergonha</i>	<i>Marinês</i>	<i>Canção da fé (1972)</i>	$D = 1$ ($n_i = 24, n_j = 0, n_k = 0$). Marinês é uma das primeiras vozes femininas do forró. <i>Sem vergonha</i> , como muitas de suas músicas, apresenta uma junção de uma voz principal muito forte e <i>backing vocals</i> muito ativas, uma prática não muito comum naquele momento. Estratégia similar é utilizado por algumas de suas músicas sucessoras, como <i>Quebra-cabeça (Trio Nordestino - 1981)</i> .
<i>Derramaro o gai</i>	<i>Luiz Gonzaga</i>	<i>O nordeste na voz de Luiz Gonzaga (1962)</i>	$D = 1$ ($n_i = 22, n_j = 0, n_k = 0$). As refinadas melodias de sanfona são indubitavelmente o aspecto mais forte do trabalho de <i>Luiz Gonzaga</i> , e essa música é prova disso. <i>Derramaro o gai</i> tem inúmeras conexões disruptivas com outras músicas do mesmo álbum, além de similaridades com músicas de seu irmão, <i>Severino Januário</i> .
<i>Lembranças</i>	<i>Flávio José</i>	<i>Só confio em tu (1977)</i>	$D = 1$ ($n_i = 19, n_j = 0, n_k = 0$). Essa música apresenta um violão entre a instrumentação original do forró, algo raro na década de 1970. Músicas semelhantes de <i>Flávio José</i> solidificam essa ramificação criativa, imitada por artistas como <i>Marinês e Genival Lacerda</i> .

Tabela A.2: Cinco músicas mais disruptivas de acordo com a rede de similaridades não ponderada.

tas importantes no cenário musical – como Luiz Gonzaga, Marinês e Flávio José – estão presentes nesse *top-5*.

Nesse caso em especial, chama-se uma atenção especial para a música *Sem vergonha*, da cantora campinense Marinês. Marinês é reconhecidamente uma das primeiras vozes femininas do forró, em uma época na qual o gênero musical era composto apenas de homens. Sua própria história revela que, para poder participar dos antigos concursos de calouros organizados pelas saudosas rádios difusoras, Marinês (nome artístico de Inês Caetano de Oliveira) precisou mudar seu nome, a fim de que o pai – que desaprovava sua cantoria – descobrisse. Isso evidencia o quão raro era se ter mulheres cantando forró até décadas mais recentes, e serve de forte argumento para o fato de uma música de Marinês ser considerada disruptiva.

Seguindo adiante, é relevante destacar-se o papel desempenhado por Sivuca dentro da rede de similaridades, assim como o comportamento inovador apresentado por este, uma vez que o mesmo possui um número considerável de músicas com um índice de disrupção alto (oito músicas com $I_d \geq 0.5$). Severino Dias de Oliveira, ou Sivuca, é até os dias de hoje um dos mais completos artistas da música brasileira, e por que não mundial. Era um multi-instrumentista, maestro, cantor, compositor e orquestrador paraibano, globalmente aclamado por seu trabalho tanto no Brasil quanto no exterior. Muitas de suas músicas com alta disrupção dentro da rede de similaridades combinam elementos de vários outros gêneros musicais regionais, como o Choro e o Frevo, além de gêneros mais tradicionais, como o *Jazz* e o *Blues*. Verificou-se posteriormente que a riqueza acústica atribuída ao seu trabalho, aliada à singularidade das músicas compostas e executadas por Sivuca geraram inúmeras relações de similaridade internas entre suas músicas, e essas relações permaneciam exclusivas às suas próprias músicas, fazendo com que estas possuíssem alta disrupção. Essa descoberta peculiar é um exemplo claro de como o índice de disrupção pode ajudar a identificar e confirmar eventos significativos que residem ocultos nas histórias dos gêneros.

A.3.2 A Disrupção ao Longo dos Anos

Uma vez observadas as disrupções sob a ótica individual de cada música, seguimos em frente propondo uma análise mais agregada dos índices extraídos. Neste ponto almejou-se a utilização do índice de disrupção como ferramenta capaz de modelar como o fluxo criativo do Forró se desenvolveu com o passar de sete décadas. Mais especificamente, buscou-se, com

essa investigação, encontrar exatamente quando na trajetória histórica o gênero apresentou inflexões criativas (i.e., eventos inovadores), além de tentar revelar que eventos foram esses e o quão frequentes aconteciam com o passar dos anos. Destaca-se aqui novamente esse potencial descritivo apresentado pelo índice de disrupção, principalmente no que se refere à capacidade de revelar fatos por vezes escondidos nas histórias dos gêneros.

Uma exploração mais minuciosa sobre os dados agregados por década e artista observou que um grande número de músicas possuía I_d igual a 0 ou muito próximo de 0 (cerca de 35% das músicas possuíam índices de disrupção entre 0.1 e -0.1). Isso pôde-se também ser visualizado na distribuição dos índices de disrupção, ilustrado na Figura A.3, que exibe uma distribuição assimétrica e com forte concentração em valores baixos e negativos. Esse comportamento é bem diferente do observado na distribuição obtida no experimento do Capítulo 5 (Figura 5.2), onde é notável que a aplicação da nova estratégia durante o cálculo das disrupções gerou uma distribuição mais simétrica e bem distribuída. Após uma segunda análise, focada na estrutura da rede de similaridades, concluiu-se que essa constatação era resultante da alta densidade da rede construída. Fazendo um paralelo com a fórmula de I_d , detalhada pela Equação 2.1, o grande número de arestas apresentado pela rede gerava muitas conexões do tipo i e j – o que por si só poderia influenciar em altas disrupções, porém, ao mesmo tempo, gerava também inúmeras conexões do tipo k , ocasionando uma redução gradual nos índices obtidos e aproximando-os cada vez mais a 0. Por conta disso, a sumarização dos dados agregados evitou a utilização de métricas de centralidade como a média ou a mediana, as quais seriam muito influenciadas pelos valores baixo de disrupção e pouco acrescentariam à exploração. Ao invés disso, em todas as análises que serão discutidas a seguir a medida que foi utilizada para sumarizar valores de disrupção para diferentes épocas e artistas é o 95-percentil.

A Figura A.4 ilustra a distribuição dos índices de disrupção com o passar dos anos, exibindo uma representação gráfica dos intervalos do 5 ao 95 percentis. Em geral, observa-se que as mais altas disrupções do forró são majoritariamente concentradas nos primeiros anos da história do gênero, especialmente no intervalo entre 1960 e 1970. Consultando o *ranking* de disrupção para entender melhor esse resultado, observou-se que que essa alta carga criativa presente nesse período foi guiada por várias músicas disruptivas interpretadas por alguns dos pioneiros do forró, como Luiz Gonzaga, Jackson do Pandeiro e Marinês. Embora

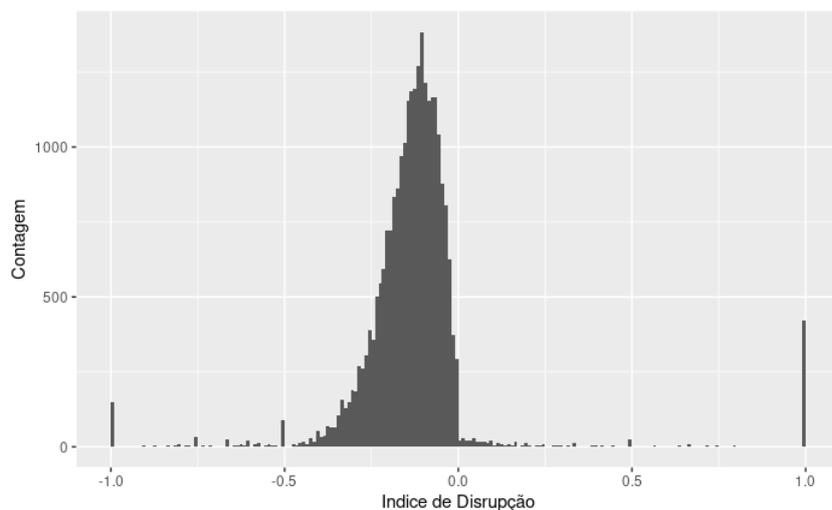


Figura A.3: Histograma dos índices de disrupção calculados pelo experimento.

possa parecer um resultado intuitivo do ponto de vista musical, além da confirmação dessa percepção, a descoberta revela a eficiência da abordagem de utilização das representações calculadas pelo *autoencoder* em conjunto com o uso da similaridade RBF na derivação de relações de similaridade. Prosseguindo na discussão a respeito da distribuição das disrupções, as décadas seguintes a 1970 também apresentam músicas disruptivas, como as próprias *Lembranças* (Flávio José), de 1977, e *Padrinho Cícero do Juazeiro* (Trio Juazeiro), de 1982, ambas partes do *top-5* de músicas mais disruptivas do *dataset*. Entretanto, a proporção desses eventos inovadores a partir de 1970 foi consideravelmente menor do que na década inicial.

Indo além, também foi conduzida uma investigação a nível de artistas com a função de revelar algumas informações referentes a artistas que abalaram a linha criativa do forró de acordo com os dados de disrupção coletados. Toda análise realizada é resumida na Figura A.5, que faz uso da mesma estratégia de visualização dos intervalos do 5 ao 95 percentis representado na Figura A.4 para sumarizar os níveis de disrupção apresentados pelos seis artistas mais disruptivos (i.e., aqueles com os índices de disrupção médios mais altos, consideradas todas as suas músicas) do *dataset*. Os resultados mostram, mais uma vez, Luiz Gonzaga e Marinês figurando entre os artistas mais disruptivos da história do forró, com uma alta produção criativa sendo constantemente apresentada até próximo da década de 1980, quando suas carreiras se encerraram (Gonzagão faleceu em 1989, e Marinês reduziu sua produção a partir do início da década de 1990). Seu legado inovador, entretanto, pa-

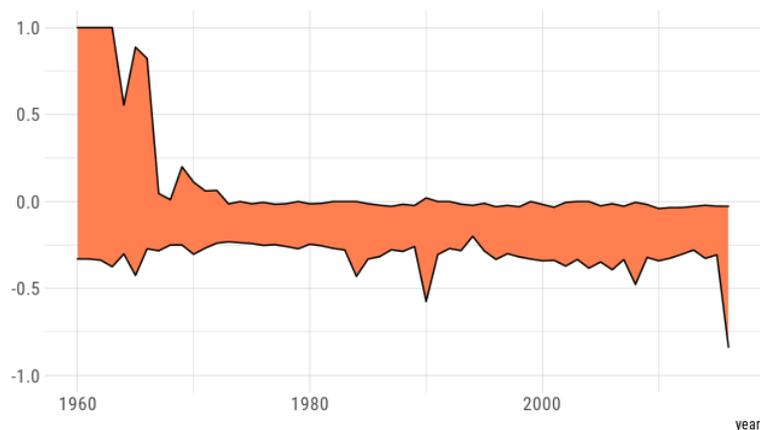


Figura A.4: Distribuição das disrupções sumarizadas ao longo do tempo. Os intervalos representam o 5-percentil (limite inferior) e o 95 percentil (limite superior).

rece ter sido seguido por Genival Lacerda, Flávio José e Dominginhos, os quais possuem carreiras ativas desde o final dos anos 1970 e alternam períodos disruptivos entre si desde então.

A.4 Considerações Finais

Em uma primeira experimentação feita com o índice de disrupção como originalmente proposto por Funk e Owen-Smith, foi necessária inicialmente a criação de uma rede de similaridades relacionando as músicas do *Dataset Forró em Vinil*. Essa estrutura foi construída a partir das representações musicais contempladas pelo conjunto de dados, em conjunto com a utilização de uma métrica de similaridade responsável pela derivação de relações de influência entre essas músicas. Com essa finalidade, nesse primeiro momento fez-se uso da similaridade RBF, uma vez que a mesma obteve desempenho satisfatório durante a validação em duas etapas proposta anteriormente. A combinação entre as representações musicais do forró e a similaridade RBF convergiram para a construção de uma densa rede de similaridades, composta por milhares de nós – representando as músicas – e milhões de arestas, ilustrando as relações de similaridade existentes entre essas músicas.

A fórmula original do índice de disrupção foi então aplicada sobre todos os nós da rede,

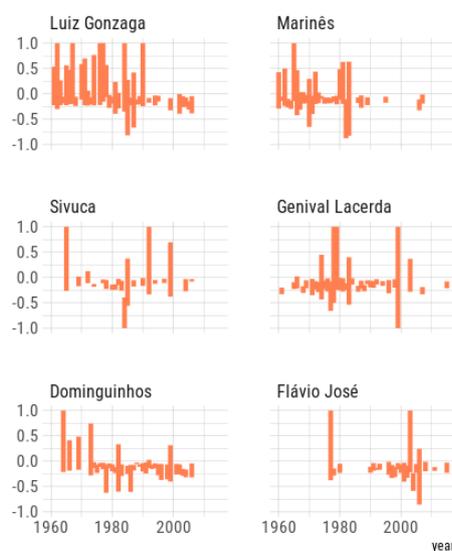


Figura A.5: Distribuição das disrupções sumarizadas ao longo do tempo para os seis artistas mais disruptivos do *Dataset* Forró em Vinil. Os intervalos representam o 5-percentil (limite inferior) e o 95 percentil (limite superior).

visando a cálculo dos níveis de inovação apresentados por cada uma dessas músicas. Feito isso, propôs-se uma análise sobre essas informações, o que foi feito em dois momentos: primeiramente observaram-se as disrupções individuais de cada música, a fim de descobrir quais delas apresentaram maiores índices de disrupção, aplicando também um esforço na busca por razões que suportassem essas descobertas. Em um segundo momento foi sugerida uma exploração dos índices agregados por época e artista, com o objetivo de entender em quais momentos da história o movimento criativo se mostrou mais intenso, além de listar os artistas que mais contribuíram para esses eventos. Dentre diversas descobertas, percebeu-se que os níveis mais altos de inovação do forró foram observados em suas décadas iniciais, em especial no intervalo que compreendeu 1960 e 1970, sendo esse movimento criativo majoritariamente conduzido por artistas de renome na história do gênero, como Luiz Gonzaga, Marinês e Jackson do Pandeiro.

A maior parte dos resultados discutidos durante esse capítulo, além de toda a metodologia explicada nos capítulos anteriores, foi publicada no artigo *Measuring Disruption in Song Similarity Networks* e apresentada na *International Society for Music Information Re-*

trieval Conference, 2020, que por conta da pandemia foi realizada remotamente, de maneira inédita. Durante as seções de apresentação, várias sugestões foram discutidas, tendo uma delas sido muito importante nos passos seguintes tomados no âmbito da pesquisa. Houve um certo consenso entre alguns participantes de que a abordagem de utilização de um limiar de similaridade a fim de realizar a criação das arestas entre os nós descartava informação de similaridade que poderia ser útil ao cálculo da disrupção. Além disso, apesar de a escolha desse limiar ter seguido uma certa lógica, ponderou-se que alguns efeitos inadequados enfrentados durante as análises poderiam ter sido minimizados se o valor do limiar tivesse sido melhor escolhido. Ao mesmo tempo, justificou-se essa estratégia adotada como sendo uma maneira de se adaptar à estrutura de rede exigida pela fórmula tradicional do índice de disrupção como proposto por Funk e Owen-Smith e aprimorado por outros pesquisadores. Até então, todas as experimentações feitas com o índice de disrupção se alimentavam de redes de influência com arestas não ponderadas. Após reflexão, viu-se a necessidade de aplicar novos aperfeiçoamentos sobre o cálculo do índice, de forma que o mesmo passasse a suportar também redes de similaridade com arestas ponderadas.

Apêndice B

30 Músicas Mais Disruptivas de Acordo com o Índice de Disrupção

A Tabela B.1 na página seguinte exibe o *ranking* com as 30 músicas mais disruptivas do *Dataset Forró em Vinil* de acordo com o índice de disrupção. Além disso, metadados relativos ao artista, álbum e ano associados a cada canção também são informados.

#	Música	Artista	Álbum	Ano	Índice de Disrupção
1	Pica Pau	Marinês	Meu Benzin	1966	0,96
2	Estrada de Canindé	Luiz Gonzaga	O Homem da Terra	1980	0,91
3	Flor do Limoeiro	Castanheiro	Caruaru	1973	0,88
4	Radinho de Pilha	Genival Lacerda	Não Despreze Seu Coroa	1979	0,88
5	Siri Jogando Bola	Luiz Gonzaga	O Homem da Terra	1980	0,87
6	Tão Sozinho	Diego Oliveira	Mais um Homem Apaixonado	2010	0,87
7	Forró Em Macururé	Severino Januário	Sanfoneiro Forte	1965	0,85
8	De Colégio a Propriá	Pedro Sertanejo	Rato Molhado	1967	0,85
9	Quem Manda Sou Eu	Zé Duarte	Forró Exportação	1985	0,85
10	Vaqueiro Apaixonado	Mastruz com Leite	Coisa Nossa	1993	0,85
11	A Festa do Milho	Luiz Gonzaga	Sanfona do Povo	1974	0,84
12	Forró Bom	Trio Estrela do Norte	Voltando pra Penedo	1982	0,84
12	Você Endoideceu Meu Coração	Os Nordestinos do Ritmo	Os Nordestinos do Ritmo	1994	0,84
14	Raio de Amor	Banda Kartuxo	Explosão do Forró	2010	0,83
15	Ciscadinho	Arlindo dos 8 Baixos	Mestre do Beberibe	1981	0,82
16	Vendendo Alegria	Trio Nordestino	Amor pra Dar	1983	0,82
17	Gosto Não Se Discute	Joci Batista	Se Divirta Conterrâneo	1971	0,81
18	Baião de Romeiro	Trio Nordestino	Amor pra Dar	1982	0,81
19	Você Fica Muito Mais Bonita	Trio Virgulino	O Beijo que Você me Deu	1999	0,81
20	Passei no Norte	Zé Paraíba	Forró de Latada	1975	0,80
21	Sanhauá	Sivuca	Um Pé no Asfalto, Um Pé na Buraqueira	1990	0,80
22	Sanfoneiro Zé Tatu - Forró no Escuro	Luiz Gonzaga	Quadrilhas e Marchinhas Vol. 2	1979	0,79
23	Forró Viola	Genival Lacerda	Hot Dog Baiano	1986	0,79
24	O Bom Mesmo é Te Amar	Os Nordestinos do Ritmo	Os Nordestinos do Ritmo	1994	0,79
25	Firim Firim Fom Fom	Novinho da Paraíba	Sucesso	1994	0,79
26	Carta Para os Meus Amores	Trio Sertanejo	Compacto Duplo	1072	0,78
27	Sanfoneiro Zé Tatu	Luiz Gonzaga	Sanfona do Povo	1974	0,78
28	Forró no Ceará	Zé Gonzaga	Asa Branca	1992	0,78
29	O Barulho da Lapa	José Bettio	O Sanfoneiro Mais Premiado do Brasil	1972	0,78
30	Marieta	Zé Duarte	Forró Exportação	1985	0,77

Tabela B.1: As 30 músicas mais disruptivas do *Dataset Forró em Vinil* de acordo com o índice de disrupção.

Apêndice C

30 Artistas Mais Disruptivos de Acordo com o Índice de Disrupção

A Tabela C.1 na página seguinte exhibe o *ranking* com os 30 artistas mais disruptivos do *Dataset Forró em Vinil* de acordo com o índice de disrupção. Os índices mostrados são as sumarizações aplicadas por meio do 95-percentil de todas as observações para cada artista.

#	Artista	Índice de Disrupção
1	Os Nordestinos do Ritmo	0,64
2	Falamansa	0,54
3	Benedito Nunes	0,51
4	Trio Mossoró	0,50
5	Cezar do Acordeon	0,46
6	Ciço do Pará	0,46
7	Fuba de Taperá	0,46
8	Zito Borborema	0,46
9	Pedro Sertanejo	0,46
10	Ze da Onça	0,45
11	Zé do Baião	0,44
12	Joãozinho do Exú	0,44
13	Geraldo Correia	0,44
14	Ary Lobo	0,43
15	Luiz Wanderley	0,43
16	Adelson Viana	0,42
17	Chico Sales	0,42
18	Marinês	0,42
19	Banda Kartuxo	0,41
20	Zenilton	0,41
21	Zé Cupido	0,40
22	Ceará da Bocada	0,40
23	Trio Virgulino	0,40
24	Flávio Leandro	0,38
25	Trio Forrozão	0,37
26	Coronel Ludgério	0,37
27	Anastácia	0,37
28	Alcymar Monteiro	0,35
29	Irah Caldeira	0,34
30	Genário	0,34

Tabela C.1: Os 30 artistas mais disruptivos do *Dataset Forró em Vinil*. Os índices mostrados são as sumarizações aplicadas por meio do 95-percentil de todas as observações para cada artista.

Apêndice D

30 Álbuns Mais Disruptivos de Acordo com o Índice de Disrupção

A Tabela D.1 da página seguinte exibe o *ranking* com os 30 álbuns mais disruptivos do *Dataset Forró em Vinil* de acordo com o índice de disrupção. Os índices mostrados são as sumarizações aplicadas por meio da média de todas as músicas de cada disco. Além disso, metadados relativos ao artista e ano associados a cada disco também são informados.

#	Álbum	Artista	Ano	Índice de Disrupção
1	Rato Molhado	Pedro Sertanejo	1967	0,51
2	Forró exportação	Zé Duarte	1985	0,44
3	Voltando para Penedo	Trio Estrela do Norte	1982	0,39
4	Sonhando Com Meu Bem	Marinês	1970	0,32
5	Chega de Promessa	Fuba de Taperoá	1993	0,28
6	Torrão de Ouro	Anastácia	1971	0,28
7	Forró Bom Danado	Benedito Nunes	1971	0,28
8	Vamos Xamegá	Anastácia	1972	0,27
9	Valor do Homem	Ary Lobo	1970	0,26
10	Entre na Nossa Quadrilha	Zé Cupido	1976	0,26
11	Quadrilhas e Marchinhas Juninas	Luiz Gonzaga	1965	0,25
12	No Oitão La de Casa	Zé do Baião	1969	0,25
13	Os Nordestinos do Ritmo	Os Nordestinos do Ritmo	1994	0,25
14	Festaça Computada	Grupo Coração do Brasil	1990	0,22
15	Na Ginga do Merengue	Abdias	1970	0,22
16	Amor de Primeira	Osvaldo Oliveira	1971	0,22
17	Chegou um Sanfoneiro	Marquinho	1982	0,21
18	Asa Branca	Zé Gonzaga	1992	0,21
19	Só pra Machucar	Marinês	1973	0,20
20	É Muita Cantiga Nordestina	Alventino Cavalcanti	1968	0,19
21	Um Baixinho e Seus 8 baixos	Geraldo Correia	1964	0,19
22	Enxugue o Rato	Marinalva	1986	0,19
23	Merengue Dela	Arlindo dos 8 Baixos	1986	0,19
24	Forró Classe A	Eraldo Lucena	1980	0,19
25	Ciço do Pará	Ciço do Pará	1977	0,17
26	A Gemedeira do Povo	Zenilton	1991	0,17
27	Saudade Nordestina	Helvidinho	1982	0,16
28	Cantigas e Cantorias	Alcymar Monteiro	1992	0,14
29	Zé da Onça	Forró Danado	1982	0,14
30	Amor pra Dar	Trio Nordestino	1983	0,13

Tabela D.1: Os 30 álbuns mais disruptivos do *Dataset Forró em Vinil*. Os índices mostrados são as sumarizações aplicadas por meio da média de todas as observações para cada disco.