

UNIVERSIDADE FEDERAL DO PARANÁ

ELDER GOMES DA SILVA

PREFERÊNCIA E EMOÇÃO EM AMBIENTES DE ESCUTA MUSICAL MEDIADOS PELA  
TECNOLOGIA

CURITIBA

2021

ELDER GOMES DA SILVA

PREFERÊNCIA E EMOÇÃO EM AMBIENTES DE ESCUTA MUSICAL MEDIADOS PELA  
TECNOLOGIA

Tese apresentada ao Programa de Pós-Graduação em Música da Universidade Federal do Paraná, Setor de Artes, Comunicação e Design, como requisito parcial à obtenção do título de Doutor em Música.

Orientador: Prof. Dr. Danilo Ramos

CURITIBA

2021

Catálogo na publicação  
Sistema de Bibliotecas UFPR  
Biblioteca de Artes, Comunicação e Design/Batel  
(Elaborado por: Karolayne Costa Rodrigues de Lima CRB 9/1638)

Silva, Elder Gomes  
Preferência e emoção em ambientes de escuta musical mediados pela tecnologia. / Elder Gomes Silva. – Curitiba, 2021.  
171 f.: il. color.

Orientador: Prof. Dr. Danilo Ramos.  
Tese (doutorado em Música) – Universidade Federal do Paraná, Setor de Artes, Comunicação e Design, Programa de Pós-Graduação em Música.

1. Música – Aspectos emocionais. 2. Preferência musical. 3. Inteligência artificial - Música. 4. Streaming (Música). I. Título.

CDD 781.6



MINISTÉRIO DA EDUCAÇÃO  
SETOR DE ARTES COMUNICAÇÃO E DESIGN  
UNIVERSIDADE FEDERAL DO PARANÁ  
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO  
PROGRAMA DE PÓS-GRADUAÇÃO MÚSICA -  
40001016055P2

## TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em MÚSICA da Universidade Federal do Paraná foram convocados para realizar a arguição da tese de Doutorado de **ELDER GOMES DA SILVA** intitulada: **PREFERÊNCIA E EMOÇÃO EM AMBIENTES DE ESCUTA MUSICAL MEDIADOS PELA TECNOLOGIA**, sob orientação do Prof. Dr. **DANILO RAMOS**, que após terem inquirido o aluno e realizada a avaliação do trabalho, são de parecer pela sua **APROVAÇÃO** no rito de defesa.

A outorga do título de doutor está sujeita à homologação pelo colegiado, ao atendimento de todas as indicações e correções solicitadas pela banca e ao pleno atendimento das demandas regimentais do Programa de Pós-Graduação.

CURITIBA, 06 de Maio de 2021.

Assinatura Eletrônica  
07/05/2021 23:53:13.0

**DANILO RAMOS**  
Presidente da Banca Examinadora

Assinatura Eletrônica  
13/05/2021 16:46:50.0

**JOSE EDUARDO FORNARI NOVO JUNIOR**  
Avaliador Externo (UNIVERSIDADE ESTADUAL DE CAMPINAS)

Assinatura Eletrônica  
10/05/2021 17:27:52.0

**GUILHERME GABRIEL BALLANDE ROMANELLI**  
Avaliador Interno (UNIVERSIDADE FEDERAL DO PARANÁ)

Assinatura Eletrônica  
10/05/2021 20:47:33.0

**LUIS FELIPE OLIVEIRA**  
Avaliador Externo (UNIVERSIDADE FEDERAL DO MATO GROSSO DO  
SUL)

Para Adélia.

## AGRADECIMENTOS

Ao PPGMúsica/UFPR, em especial ao meu orientador Prof. Dr. Danilo Ramos, à Prof.<sup>a</sup> Dr.<sup>a</sup> Rosane Cardoso e à Prof.<sup>a</sup> Dr.<sup>a</sup> Valéria Lüders, pelo suporte no decorrer desta pesquisa.

Aos membros da banca – Prof. Dr. Guilherme Romanelli, Prof. Dr. José Eduardo Fornari Novo Jr. e Prof. Dr. Luis Felipe Oliveira –, por aceitarem avaliar este trabalho e pelas importantes contribuições durante a qualificação e defesa desta tese.

À Ufac, pelo apoio à qualificação de seu quadro docente em serviço, sobretudo aos colegas do Centro de Educação, Letras e Artes e do Curso de Licenciatura em Música.

Aos colegas do GRUME e do PPGMúsica/UFPR, em especial ao Eduardo Mello, ao Jean Pscheidt, à Teresa Piekarski e ao Vinicius Bastos.

À Adriane, à Aline, ao Marcelo e ao Sandro: vocês são pessoas incríveis.

À minha família, em especial à Márcia, à Adélia, aos meus pais e minhas irmãs, pelo amor incondicional em todos os momentos.

*And no one showed us to the land  
And no one knows the where's or why's  
But something stirs, and something tries  
And starts to climb toward the light.*

Echoes  
– Pink Floyd

## RESUMO

Esta tese teve como objetivo geral investigar a preferência musical de usuários de uma rede social voltada para o compartilhamento de suas escolhas musicais, no intuito de compreender alguns dos processos relacionados aos seus hábitos de escuta. A hipótese da pesquisa foi de que as variáveis descritas na Nova Estética Experimental de Daniel Berlyne e na Teoria Unificada das Emoções Musicais sintetizada por Patrik Juslin poderiam influenciar a preferência musical dos ouvintes no contexto da música difundida pelos serviços de *streaming* na medida em que afetariam diretamente a popularidade das faixas musicais. Para tanto, três mecanismos psicológicos subjacentes às emoções musicais (reflexo do tronco cerebral, pareamento rítmico e contágio emocional), além de variáveis derivadas de componentes da Nova Estética Experimental foram empregados como preditores da preferência utilizando recursos de inteligência artificial, notadamente a mineração de dados e aprendizagem de máquina. Os dados foram coletados com auxílio do *Goliath Toolbox*, uma ferramenta desenvolvida no decorrer desta pesquisa para Matlab R2017b destinada a minerar dados na Last.Fm API e nos bancos de dados da MetaBrainz Foundation. Posteriormente, as simulações foram elaboradas e analisadas com utilização do *software* Orange Data Mining 3.26 e Python 3.6.6. O estudo I apresenta os detalhes do desenvolvimento do Goliath Toolbox. O estudo II, por sua vez, apresenta a simulação da preferência musical, empregando um algoritmo de redes neurais artificiais. Os dados foram coletados junto à Last.Fm API e à AcousticBrainz; posteriormente, tabulados, processados e submetidos à simulação. A análise dos dados revelou a possibilidade de predição da preferência a partir das variáveis elencadas ( $R^2=0,900$  na etapa de treinamento). O estudo III testou a simulação da preferência musical utilizando recursos experimentais com a participação de humanos. Os dados foram extraídos da Last.Fm API e da AcousticBrainz utilizando um parâmetro de geolocalização (dados referentes a usuários brasileiros) e, posteriormente, submetidos à mesma simulação do Estudo II. Os dados obtidos por meio da implementação da simulação foram comparados com os resultados observados durante um experimento, no qual 89 ouvintes realizavam um teste de escolha forçada referente a preferência musical. Os resultados mostraram incompatibilidade entre os resultados da simulação e o teste de escolha forçada ( $D=0,8$ ,  $p<0,000$ ). Finalmente, o estudo IV procurou implementar uma regressão linear para estimar a popularidade das faixas musicais. Os dados foram coletados reiteradamente durante três anos (2018, 2019 e 2020) e, posteriormente, submetidos a uma simulação utilizando um algoritmo de regressão linear. Os resultados da implementação sugerem um comportamento análogo à hipótese da rainha vermelha descrita por Van Valen no contexto da pesquisa em biologia evolutiva e da teoria dos jogos na década de 1970, em que as faixas se encontram crescendo em popularidade continuamente enquanto concorrem pelos mesmos nichos de mercado.

**Palavras-chave:** música e emoção; preferência musical; inteligência artificial.

## ABSTRACT

This thesis aimed to investigate the musical preference of users of a social network focused on sharing their choices, to understand some of the processes related to their listening habits. The hypothesis was that the variables described in Daniel Berlyne's New Experimental Aesthetics and in the Unified Theory of Musical Emotions synthesized by Patrik Juslin may influence musical preference, insofar as they directly affect the popularity of the musical tracks accessed by streaming. For this, three psychological mechanisms underlying musical emotions (brainstem reflex, rhythmic entrainment and emotional contagion), in addition to variables derived from the components of the New Experimental Aesthetics were used as predictors of preference using artificial intelligence resources, notably data mining and machine learning. The data were collected with the aid of the Goliath Toolbox, a tool developed in Matlab R2017b during this research designed to mine data in the Last.Fm API and in the databases of the MetaBrainz Foundation. Subsequently, the simulations were developed and analyzed using Orange Data Mining 3.26 and Python 3.6.6. Study I present the details of the development of the Goliath Toolbox. Study II, in turn, presents the simulation of musical preference, using an artificial neural network algorithm. Data were collected from Last.Fm API and AcousticBrainz; subsequently, tabulated, processed, and submitted to simulation. Data analysis revealed the possibility of prediction of preference based on the variables listed ( $R^2 = 0,900$  in the training stage). Study III sought to test the simulation of musical preference using experimental resources with the participation of humans. The data were extracted from Last.Fm API and AcousticBrainz using a geolocalization parameter (data referring to Brazilian users) and, subsequently, submitted to the same simulation of Study II. The data obtained through the implementation of the simulation were compared with the results observed during an experiment, in which 89 listeners performed a forced choice test regarding musical preference. The results showed incompatibility between the results of the simulation and the forced choice test ( $D = 0,8, p < 0,000$ ). Finally, Study IV sought to implement a linear regression to estimate the popularity of musical tracks. Data were collected repeatedly for three years (2018, 2019 and 2020) and subsequently subjected to a simulation using a linear regression algorithm. The results of the implementation suggest a behavior analogous to the red queen hypothesis described by Van Valen in the context of research in evolutionary biology and game theory in the 70s, in which the tracks are growing in popularity continuously while competing for them niche markets.

**Keywords:** music and emotion; musical preference; artificial intelligence.

## LISTA DE FIGURAS

<b>Figura 1.</b> Relação entre emoção e preferência a partir dos estudos de Juslin, Harmat e Eerola (2014) e Juslin, Barradas e Eerola (2015).....	35
<b>Figura 2.</b> Curva de Wundt aplicada à Nova Estética Experimental.....	39
<b>Figura 3.</b> Exemplo de respostas no formato JSON.....	60
<b>Figura 4.</b> Exemplo de respostas no formato XML.....	60
<b>Figura 5.</b> Cenário de pesquisa.....	62
<b>Figura 6.</b> Procedimentos para recuperação de dados.....	63
<b>Figura 7.</b> Pseudocódigo para a função <i>glochart()</i> .....	65
<b>Figura 8.</b> Rede artificial multicamadas ( <i>perceptron</i> ).....	73
<b>Figura 9.</b> Histograma da popularidade ( $n=1462$ ) observada na amostra obtida da rede social <i>Last.Fm</i> .....	76
<b>Figura 10.</b> Histograma da preferência musical ( $n=1462$ ) observada na amostra obtida da rede social <i>Last.Fm</i> .....	77
<b>Figura 11.</b> Resultados obtidos durante a etapa de predição da preferência musical ( $n=1462$ , $R^2=0.9002$ ).....	78
<b>Figura 12.</b> Histograma da popularidade ( $n=2224$ ), observando-se assimetria à direita.....	89
<b>Figura 13.</b> Histograma dos resultados da simulação (preferência musical predita), sugerindo uma distribuição gaussiana (média = 0.20406, desvio-padrão = 0.00866615).....	90
<b>Figura 14.</b> Histograma da preferência musical referente aos participantes do estudo de adequação ( $n=89$ ).....	91
<b>Figura 15.</b> Gráfico da preferência musical dos participantes do estudo de adequação ( $n=89$ ).....	92
<b>Figura 16.</b> Histograma da distribuição da popularidade em agosto de 2020.....	98
<b>Figura 17.</b> Histograma da distribuição dos resultados da simulação.....	98
<b>Figura 18.</b> Popularidade observada entre agosto de 2018 e agosto de 2020.....	99
<b>Figura 19.</b> Evolução da popularidade observada, considerando o caso de <i>Escape (The Piña Colada Song) versus Chamber of Reflection</i> .....	100
<b>Figura 20.</b> Evolução da popularidade simulada, considerando o caso de <i>Escape (The Piña Colada Song) versus Chamber of Reflection</i> .....	100
<b>Figura 21.</b> Resultados da simulação (regressão linear, $n=255$ ).....	102
<b>Figura 22.</b> Fontes de variação na preferência musical.....	106
<b>Figura 23.</b> Lista de adjetivos utilizada para designar as expressões musicais.....	112

## LISTA DE TABELAS

<b>Tabela 1.</b> Conceitos relacionados à emoção que serão utilizados nesta pesquisa.....	26
<b>Tabela 2.</b> Conceitos relacionados à preferência que serão utilizados nesta pesquisa.....	28
<b>Tabela 3.</b> Síntese dos desfechos do dilema do prisioneiro, em anos.....	42
<b>Tabela 4.</b> Exemplo de conjunto de dados sobre a avaliação de canções.....	49
<b>Tabela 5.</b> Projetos disponibilizados pela MetaBrainz Foundation.....	51
<b>Tabela 6.</b> Diferentes maneiras de indexar um mesmo objeto a partir da combinação de artista/faixa .....	53
<b>Tabela 7.</b> Funções incluídas no <i>Goliath Toolbox</i> .....	64
<b>Tabela 8.</b> Variáveis independentes selecionadas para a composição da simulação de RNA.....	74
<b>Tabela 9.</b> Descrição das variáveis empregadas na simulação ( $n=2214$ ).....	75
<b>Tabela 10.</b> Resultado da avaliação da implementação da simulação computacional da preferência musical ( $i=5000$ ).....	79
<b>Tabela 11.</b> Exemplos de faixas incluídas na simulação.....	80
<b>Tabela 12.</b> Escala de Preferência Musical – STOMP.....	88
<b>Tabela 13.</b> Exemplos de faixas incluídas na simulação (amostra de usuários brasileiros).....	91
<b>Tabela 14.</b> Resultado da avaliação da implementação da simulação computacional da popularidade ( $n=570$ ).....	101
<b>Tabela 15.</b> Exemplos de faixas incluídas na simulação da popularidade.....	103
<b>Tabela 16.</b> Escolha de programas da <i>Boston Symphony Orchestra</i> .....	114

## SUMÁRIO

<b>APRESENTAÇÃO</b> .....	13
<b>INTRODUÇÃO</b> .....	17
<b>1. FUNDAMENTAÇÃO TEÓRICA</b> .....	23
<b>1.1 Emoção e preferência: principais definições</b> .....	24
<i>1.1.1 Emoção</i> .....	24
<i>1.1.2 Preferência</i> .....	26
<b>1.2 As emoções e a Teoria Unificada de Patrik Juslin</b> .....	29
<b>1.3 A Nova Estética Experimental de Daniel Berlyne</b> .....	36
<b>1.4 Os processos de tomada de decisão</b> .....	40
<b>1.5 Sistemas complexos e paradigmas computacionais</b> .....	42
<i>1.5.1 Sistemas complexos e propriedades emergentes</i> .....	42
<i>1.5.2 Inteligência artificial e cognição musical: machine learning e music data mining</i> .....	44
<i>1.5.3 Last.Fm</i> .....	46
<i>1.5.4 MetaBrainz Foundation</i> .....	50
<b>1.6 Popularidade e mercados de nicho</b> .....	54
<b>2. ESTUDOS EMPÍRICOS</b> .....	57
<b>2.1 Estudo I: Goliath Toolbox – uma ferramenta para mineração de dados musicais no Matlab</b> .....	58
<i>2.1.1 Introdução</i> .....	58
<i>2.1.2 Características técnicas do Goliath Toolbox</i> .....	59
<i>2.1.3 Cenário de implementação do Goliath Toolbox</i> .....	61
<i>2.1.4 Discussão</i> .....	65
<i>2.1.4.1 Aspectos éticos e jurídicos</i> .....	66
<i>2.1.4.2 Aspectos técnicos</i> .....	67
<b>2.2 Estudo II: simulação da preferência musical por meio do uso de redes neurais artificiais</b> .....	69
<i>2.2.1 Introdução</i> .....	69

2.2.2 Metodologia.....	70
2.2.3 Resultados.....	74
2.2.4 Discussão.....	80
<b>2.3 Estudo III: Testagem da simulação da preferência musical entre ouvintes brasileiros.....</b>	<b>85</b>
2.3.1 Introdução.....	85
2.3.2 Metodologia.....	86
2.3.3 Resultados.....	89
2.3.4 Discussão.....	93
<b>2.4 Estudo IV: Simulação da popularidade musical em cenários de competição pela preferência na música popular compartilhada por streaming.....</b>	<b>96</b>
2.4.1 Introdução.....	96
2.4.2 Metodologia.....	96
2.4.3 Resultados.....	97
2.4.4 Discussão.....	103
<b>3. DISCUSSÃO GERAL.....</b>	<b>110</b>
<b>4. CONSIDERAÇÕES FINAIS.....</b>	<b>118</b>
<b>REFERÊNCIAS.....</b>	<b>121</b>
<b>APÊNDICES.....</b>	<b>136</b>
<b>APÊNDICE A – GOLIATH TOOLBOX.....</b>	<b>137</b>
<b>APÊNDICE B – TUTORIAL.....</b>	<b>153</b>

# APRESENTAÇÃO

O primeiro marco da minha trajetória musical se deu aos meus nove anos, no colégio, onde tive a oportunidade de participar de projetos relacionados a bandas escolares. Quando integrante da Fanfarra Municipal João Elias Margutti, em Santa Cruz das Palmeiras – pequena cidade do interior do Estado de São Paulo –, ganhei, dos meus pais, meu primeiro trompete. À época, primeiramente tive aulas de música na Banda Municipal; posteriormente, no Conservatório Municipal Cacilda Becker, em Pirassununga – cidade vizinha. Alguns anos depois, participei da Fanfarra Municipal de Casa Branca.

Na minha adolescência, participar de bandas e fanfarras era uma opção vantajosa para quem morava em uma cidade pequena. Em primeiro lugar, passávamos a pertencer a um grupo social formado por outros jovens com, mais ou menos, a mesma idade. Em segundo lugar, tínhamos a oportunidade de viajar e conhecer outras localidades, e até mesmo cidades mais distantes. Ainda, para alguns de nós, essa prática representava uma chance – mesmo que remota – de colocação profissional.

A música ocupava um tempo considerável da minha vida. Paralelamente à participação nas fanfarras, me envolvi em outros projetos: tentei aprender violão com professores particulares e em ações comunitárias da Igreja Católica; depois, aos 16 anos, estudei piano durante alguns meses. Contudo, percebi que meu maior interesse era os instrumentos de sopro e, mais do que isso, fazer música juntamente com outras pessoas – algo que as bandas me possibilitavam desde o início.

Com as fanfarras, participávamos anualmente de um verdadeiro circuito de competições e apresentações. Estas, em sua maioria, se davam devido a comemorações cívicas – como aniversários das cidades, Dia da Pátria, Proclamação da República, dentre outras; já os concursos tinham outro caráter: em geral, eram organizados por uma associação e tinham etapas a serem cumpridas durante o ano (preliminares e finais). Nesses concursos, éramos avaliados por critérios que iam desde disciplina até a elaboração dos arranjos das obras apresentadas.

Participamos de várias competições, dentre estaduais e nacionais. Ganhamos algumas, perdemos outras. Durante o tempo em que estive nas fanfarras, entre 1995 e 2003, conheci cidades como São Paulo (SP), Goiânia (GO), e Campo Grande (MS), para citar os concursos mais importantes.

É interessante observar que, em geral, o movimento das bandas e fanfarras é flexível com relação ao repertório. Lembro-me de que, no início da adolescência (por volta de 1999), conheci o rock justamente por meio de uma dessas agremiações: em uma das nossas viagens, ouvi uma banda marcial tocando uma música da banda *Queen*. Ao voltarmos para Santa Cruz das Palmeiras, o maestro me emprestou o CD *Greatest Hits II*, lançado em 1991. Ouvi aquele disco no microsistema da minha irmã e fiz uma cópia em fita K7, como era comum na época.

As fanfarras se tornaram, literalmente, espaços de trocas. Compartilhávamos e copiávamos CDs e repassávamos informações sobre artistas. Depois das competições, tínhamos a missão de

buscar referências do que acabáramos de ouvir. Às vezes, essa pesquisa era na música de concerto; em outras, na MPB, ou ainda no rock progressivo.

Quando contava com 17 anos, meus amigos partiam para a faculdade. Alguns para Engenharia, outros para Direito. Eu não sabia, ao certo, o que cursar, uma vez que meu interesse sempre havia sido pela música. Mas não por qualquer prática musical: eu queria estudar algo que me permitisse falar de pessoas fazendo música – como nas trocas que tínhamos nas fanfarras. Eu queria observar como e o que as pessoas fazem com relação à música. Mas, para mim, este curso não existia. Acabei desistindo da música e investindo na minha segunda opção, a Física. Foi quando, no momento da inscrição para o vestibular da Universidade Federal de São Carlos (UFSCar), eu soube que a instituição estava inaugurando um curso em Educação Musical. Então, optei pelo curso de Licenciatura em Música com habilitação em Educação Musical e desisti da Física, curso para o qual, inclusive, cheguei a ser aprovado em outra universidade pública.

Tão logo iniciei o curso superior, comecei a participar da Orquestra Experimental da UFSCar, dirigida pela Prof.<sup>a</sup> Dr.<sup>a</sup> Ilza Zenker Leme Joly. O Curso de Licenciatura em Música mudou minha forma de pensar e de me relacionar com a música, ampliando significativamente o leque de possibilidades de atuação profissional. Naquela época, eu não sabia o que fazia um educador musical – apenas sentia que minha relação com a música não era a de um intérprete ou a de um compositor. E, à medida que o tempo passava e transcorria minha trajetória na graduação, eu percebia que a Educação Musical estava muito além do que eu almejava no início daqueles estudos.

Em 2006, já próximo da formatura e juntamente com uma equipe multidisciplinar, participei de um projeto com pessoas em situação de rua no município de São Carlos. O trabalho consistia em acessar memórias associadas à música e relacionadas a eventos da história de vida daquelas pessoas. Os músicos citados pelos participantes eram identificados e, então, na semana seguinte, levávamos CDs ou DVDs para atividades de apreciação musical – quando também conduzíamos uma nova conversa sobre outras músicas e músicos, sempre a partir das memórias daqueles indivíduos. Considero que este projeto foi importante na minha trajetória porque foi a primeira vez em que percebi o papel que a emoção ocupa na vida das pessoas, a riqueza de detalhes das memórias e a capacidade de se emocionar novamente, dentre outros elementos afetivos presentes naquelas experiências.

Em 2007, ao terminar a graduação, já tinha como meta a carreira acadêmica, o que significava que meu próximo investimento deveria ser o Mestrado. Contudo, em junho de 2008, soube de um concurso para professor do magistério superior na Universidade Federal do Acre; era pouco tempo entre as inscrições e as provas e, além disso, estava sem dinheiro. De todo modo, como viajar de ônibus não era um problema (havia sido “treinado” na época das fanfarras), decidi me inscrever e aceitar o desafio: fiz a inscrição e parti no dia seguinte. Cheguei a Rio Branco depois de três dias de viagem, um antes do início das provas. E qual não foi a minha surpresa ao saber que o concurso havia

sido cancelado enquanto eu estava a caminho... à época não havia 3G e as informações circulavam mais devagar.

Alguns meses depois, em dezembro daquele ano, o concurso foi reaberto e eu decidi tentar mais uma vez. Depois de mais uma longa viagem de ônibus, as provas foram realizadas normalmente e fui aprovado em primeiro lugar. Contava com 21 anos.

Entre 2009 e 2021, muitas coisas aconteceram. Conheci minha esposa e nos casamos; fiz o mestrado (2012 – 2014) estando afastado de minhas atribuições docentes, quando estudei música e emoção no repertório brasileiro sob orientação do Prof. Dr. Danilo Ramos; minha filha, Adélia, nasceu; e, finalmente, iniciei o doutorado. O resultado deste investimento dos últimos quatro anos, em paralelo às minhas atividades docentes na área de Educação Musical, é apresentado a seguir.

# INTRODUÇÃO

Neste trabalho realizado no Programa de Pós-Graduação em Música da Universidade Federal do Paraná são apresentados os resultados de uma pesquisa situada na linha Educação Musical/Cognição, circunscrita à música, emoção e preferência musical. Trata-se de uma pesquisa interdisciplinar, que dialoga especialmente com as áreas de cognição e computação musical.

De modo geral, a definição de emoção empregada aqui está de acordo com Juslin (2019), segundo o qual o termo é utilizado para se referir a uma reação afetiva breve, mas intensa, que geralmente envolve uma série de subcomponentes – sentimento subjetivo, excitação fisiológica (*arousal*<sup>1</sup>), expressão, tendência de ação e regulação – que são mais ou menos sincronizados. Ainda para Juslin (2019), emoções se concentram em “objetos” (causas) específicos e podem durar alguns minutos ou várias horas. Funcionalmente, a emoção está descrita em teorias evolucionistas como um traço adaptativo: o medo, por exemplo, permite o evitamento em situações de perigo, promovendo a sobrevivência do indivíduo (Belzung, 2007). Já a preferência musical, por sua vez, é definida como ato de escolha entre dois ou mais estímulos musicais (Hargreaves, North & Tarrant, 2006).

Conforme Juslin e Sloboda (2010) alguns dos principais tópicos de interesse para a área da música e emoção são as possíveis contribuições da tecnologia, a pesquisa em ambientes reais e a regulação emocional coletiva em sistemas dinâmicos. As questões destacadas pelos autores representam diversos desafios para os pesquisadores da área, em grande parte pelas limitações instrumentais dos laboratórios de pesquisa. São exemplos destes desafios a mensuração de emoções em tempo real e os estados emocionais experienciados e modificados coletivamente.

Estudos que envolvem hábitos de escuta, em particular, são difíceis de serem reproduzidos em condições experimentais e podem não representar a realidade da experiência musical dos ouvintes e dos músicos (Becker, 2010). Além disso, a escolha do repertório pelo pesquisador pode interferir nos resultados encontrados em estudos sobre preferência, uma vez que nem sempre os critérios de seleção deste material são claros (Becker, 2010; Hargreaves, North & Tarrant, 2006) e, na maior parte dos casos, as aferições estão relacionadas a pequenos trechos de uma obra (Schubert, 2006). Ademais, a forma de mensuração das emoções também se mostra um fator relevante para a obtenção dos dados, variando conforme a técnica empregada (Ramos & Lamur, 2015).

Neste sentido, a música popular adquire uma importância particular para os pesquisadores interessados na temática dos hábitos de escuta, uma vez que é comumente associada a um tipo de produção destinada à circulação em massa e cujos registros principais são gravados com auxílio da tecnologia e organizado por uma indústria (Tagg, 2003). Segundo Huron (2001), nos EUA, essa indústria chegou a ser mais rentável que a indústria farmacêutica, demonstrando estar no centro da vida cotidiana de parte da população.

---

<sup>1</sup> *Arousal* é definido como o estado de excitação fisiológica e está relacionado à atividade do sistema nervoso autônomo.

Por definição, a expressão “hábito de escuta musical” faz referência, aqui, ao conceito de *habitus* empregado por Bourdieu (1989). Em suas palavras,

Sendo as minhas posições próximas das de Chomsky que elaborava, por então, e quase contra os mesmos adversários, a noção de *generative grammar*, eu desejava por em evidência as capacidades “criadoras”, ativas, inventivas, do *habitus* e do agente (que a palavra *hábito* não diz), embora chamando a atenção para a ideia de que este poder gerador não é o de um espírito universal, de uma natureza ou de uma razão humana, como em Chomsky – o *habitus*, como indica a palavra, é um conhecimento adquirido e um *haver*, um capital [...]. (Bourdieu, 1989, p. 61).

Hábitos musicais, de um modo geral, e hábitos de escuta musical, de modo específico, seriam, portanto, constructos culturais elaborados socialmente, que permitiriam trocas entre indivíduos ou grupos, com potencial geração de novas disposições (Becker, 2010).

Para Hinds Junior (2002), os estudos em cultura popular carregam certa ambiguidade. Alguns pesquisadores, em especial os latino-americanos, costumam se referir à cultura popular como relacionada à cultura de tradição oral ou folclórica. Já os pesquisadores nativos de língua inglesa se referem habitualmente à cultura de massas. Neste trabalho, o foco de investigação das emoções e das preferências musicais dos ouvintes participantes da pesquisa reside particularmente sobre esta segunda acepção, cuja popularidade musical parece ser uma métrica significativa. Isto porque, segundo Hinds Junior (2002), a popularidade da arte consiste em uma condição *sine qua non* da cultura popular, sendo uma das métricas mais importantes a serem consideradas na análise da relevância de uma obra neste contexto.

Desse modo, o objetivo geral desta pesquisa foi investigar a preferência musical de usuários de uma rede social voltada para o compartilhamento de suas escolhas musicais, no intuito de compreender alguns dos processos relacionados aos seus hábitos de escuta.

Os objetivos específicos, portanto, podem ser elencados da seguinte forma:

- Identificar os processos relacionados à tomada de decisão social no ambiente dos serviços de compartilhamento de música digital (*streaming*<sup>2</sup>), em especial no que diz respeito à escolha musical que compõe os hábitos de escuta;
- Examinar a atuação das variáveis relacionadas à Nova Estética Experimental proposta por Daniel Berlyne (1971; 1973) e à Teoria Unificada das Emoções Musicais sintetizada por Patrik Juslin e colaboradores (Juslin, 2016; Juslin, Barradas & Eerola, 2015; Juslin & Isaksson, 2014; Juslin, Harmat & Eerola, 2014; Juslin, 2013a; Juslin, 2013b; Juslin & Västfjäll, 2008) no contexto da formação da preferência entre usuários de uma rede social;

---

<sup>2</sup> *Streaming* é um tipo de serviço de distribuição de digital de conteúdo multimídia, como Netflix (vídeo) e Spotify (áudio).

- Compreender a evolução da popularidade em cenários econômicos complexos, envolvendo preferências de usuários, sistemas de recomendação e os mercados de nicho (Anderson, 2017).

A hipótese central da pesquisa era a de que as variáveis descritas poderiam influenciar a preferência musical dos ouvintes no contexto da música difundida pelos serviços de *streaming* na medida em que afetariam diretamente a popularidade das faixas musicais. Nesse sentido, a implementação do estudo foi subdividida em quatro etapas, a saber:

- (a) Desenvolvimento de uma aplicação para mineração de dados musicais no ambiente do Matlab R2017b intitulada *Goliath Toolbox* para a recuperação de informações contidas nas bases de dados da *Last.Fm API*<sup>3</sup> e da *MetaBrainz Foundation*<sup>4</sup>;
- (b) Simulação computacional da preferência musical de usuários da rede *Last.Fm*<sup>5</sup> a partir de preditores derivados da Nova Estética Experimental de Daniel Berlyne (1971; 1973) e da Teoria Unificada das Emoções Musicais sintetizada por Patrik Juslin e seus colaboradores (Juslin, 2016; Juslin, Barradas & Eerola, 2015; Juslin & Isaksson, 2014; Juslin, Harmat & Eerola, 2014; Juslin, 2013a; Juslin, 2013b; Juslin & Västfjäll, 2008), utilizando dados coletados com auxílio do *Goliath Toolbox* e algoritmos de redes neurais artificiais;
- (c) Testagem de adequação da simulação descrita na etapa anterior junto a uma amostra brasileira, contando com a participação de agentes humanos, conforme recomendação da literatura científica especializada (Russel & Norvig, 2013);
- (d) Simulação da popularidade de faixas em cenários evolutivos, de acordo com estimativas temporais.

A Teoria Unificada das Emoções Musicais está fundamentada em uma perspectiva oriunda da cognição musical, levando em conta uma perspectiva evolutiva (Juslin, 2019; Juslin, 2013a; Juslin & Västfjäll, 2008). Segundo Juslin (2013a, p. 240),

O ponto de partida é uma *perspectiva evolutiva*. Eu suponho que as emoções são adaptativas devido à sua capacidade para avaliar rapidamente o que está acontecendo no meio ambiente, para que o organismo possa escolher uma ação adequada em condições limitadas de tempo, conhecimento ou capacidade de processamento, com base, ao menos em parte, em que tipos de atividade foram adaptadas no passado.

---

<sup>3</sup> Disponível em <<https://last.fm/api>>.

<sup>4</sup> Disponível em <<https://metabrainz.org/>>.

<sup>5</sup> Disponível em <<https://last.fm/>>.

De modo semelhante, a Nova Estética Experimental de Daniel Berlyne (1973; 1971) encontra-se circunscrita à psicobiologia, buscando contribuições na evolução e na psicofísica. Um dos principais conceitos da teoria – *arousal* ou “estado de ativação fisiológica” relacionado ao sistema nervoso autônomo – é assim apresentado:

O ser humano e os animais superiores podem ser considerados como possuídos, em determinado momento, de um nível particular de *arousal* ou “ativação [fisiológica]”. Essa posição ao longo desta dimensão pode ser mais ou menos considerada como uma medida de como ele está acordado, alerta ou excitado. Quando ele detém uma saúde normal, baixos níveis de *arousal* podem ser encontrados enquanto dorme e, durante suas horas de vigília, o *arousal* sofrerá variações dentro da faixa intermediária. Ele será relativamente baixo enquanto está relaxando e descansando, mas poderá subir quando é alertado, ou em um estado emocional ou sobre a influência de algo que lhe deixe com raiva. Seu *arousal* alcançará níveis extremos apenas em circunstâncias extraordinárias, tais como um frenesi violento, paixão ou fúria (Berlyne, 1971, p. 65).

Berlyne (1969) não opera com o conceito formal de emoção, dando maior atenção a noção de *arousal*. Segundo o autor,

As palavras “emoção” e “emotividade” foram retiradas da linguagem cotidiana, o que significa que devem ser tratadas com seriedade, mas com cautela. Se a linguagem comum atribui um rótulo a certos fenômenos psicológicos, observados ou inferidos, temos boas bases para supor que existem problemas importantes e que devem ser identificados e estudados. Por outro lado, certamente não é seguro presumir que as palavras do cotidiano dividem o mundo natural de uma forma que conduza ao entendimento científico. Com muita frequência, são vestígios de teorias filosóficas e psicológicas obsoletas. Um aviso de que a emoção não era uma “categoria conceitual” adequada para a psicologia foi atribuído algum tempo atrás por Duffy (1934, 1941a, 1941b). Ela afirmou que os chamados estados emocionais diferem apenas em grau de outros estados psicológicos e que melhores maneiras de classificar o comportamento podem ser encontradas. Entre as dimensões que ela sugeriu estavam duas que representavam uma presciência notável, a saber, “manutenção da direção” e “nível de energia”. Vários anos depois, os neurofisiologistas demonstraram que as vias sensoriais específicas que transmitem informações sobre a localização, intensidade e qualidade dos receptores para locais precisos no sistema nervoso central são suplementados por estruturas difusas que são acionadas por uma ampla variedade de estímulos e que, por sua vez, transmitem excitação para pontos amplamente dispersos. Termos como ativação e excitação vieram em amplo uso para se referir a variações na extensão em que as estruturas difusas foram mobilizadas. Eles correspondem ao que Duffy chamou de nível de energia, enquanto os caminhos específicos eram considerados responsáveis pela direção do comportamento (Berlyne, 1969, p. 1059).

North e Hargreaves (2008) apontaram para a necessidade de conciliar as teorias da preferência com as teorias da emoção. Com efeito, ambas foram selecionadas devido à aparente compatibilidade entre as abordagens. Como será discutido posteriormente, a Nova Estética Experimental pressupõe que o *arousal* seja uma variável relacionada à preferência estética; nota-se, neste ponto, uma possível

associação entre as propostas, uma vez que o *arousal* é um componente importante da experiência emocional, segundo a própria Teoria Unificada das Emoções Musicais<sup>6</sup>.

Para elaboração das simulações computacionais, foi adotado o paradigma da emergência em sistemas cognitivos complexos. Para El-Hani e Queiroz (2005, p. 11), propriedades emergentes podem ser definidas como “[...] uma certa classe de propriedades de nível superior que se relacionam de uma certa maneira à microestrutura de uma classe de sistemas”. Neste escopo, foram considerados os elementos neurobiológicos relacionados à emoção e à preferência estética, bem como os padrões de popularidade e preferência obtidos através de serviços de *streaming*. As simulações foram elaboradas utilizando o *software* Orange Data Mining 3.26 (Demšar et al., 2013), baseado em linguagem Python 3.x, além de módulos específicos de programação científica.

Esta tese está organizada da seguinte maneira: o capítulo I apresenta a fundamentação da pesquisa, privilegiando as definições dos principais conceitos, a Nova Estética Experimental, a Teoria Unificada das Emoções Musicais e o estudo dos sistemas complexos empregando paradigmas computacionais. Ainda nesta parte do texto, foram incluídas uma apresentação sobre a tomada de decisão e as recentes discussões sobre popularidade e mercados de nicho. O capítulo II, por sua vez, contém o escopo de cada uma das etapas desempenhadas para realização da pesquisa, considerando as respectivas discussões para cada estudo, de maneira individual. No capítulo III, encontra-se uma discussão geral dos resultados obtidos nos quatro estudos, que traz reflexões acerca dos processos psicológicos relacionados à preferência, conformidade, competição e familiaridade. Finalmente, no capítulo IV são apresentadas as considerações finais, onde a hipótese é revisitada e são apresentadas as direções futuras.

---

<sup>6</sup> Platz e Kopiez (2013), ao analisarem a entrada de palco em performances ao vivo, elencam o papel de variáveis como comunicação corporal, persuasão, atratividade e *expertise* do intérprete. Tais variáveis seriam igualmente importantes para a comunicação durante a performance ao vivo.

# **1. FUNDAMENTAÇÃO TEÓRICA**

## 1.1 Emoção e preferência: principais definições

### 1.1.1 Emoção

A partir dos componentes comportamental/expressivo, fisiológico e cognitivo/subjetivo, a definição operacional de experiência emocional apresentada por Kleinginna e Kleinginna (1981 como citado em Belzung, 2007, p. 16) elenca quatro elementos que concorrerem para este conceito. São eles: (a) indução de experiências (tais como sentimentos de alerta, prazer ou desprazer); (b) geração de processos cognitivos (como, por exemplo, reorientações pertinentes no plano perceptivo, avaliações, categorizações); (c) ativação de ajustes fisiológicos (como no caso da reação de fight-flight-freeze); e (d) indução de comportamentos (quase sempre expressivos, orientados para um fim e adaptativos).

De modo geral, a definição de emoção (*emotion*) se diferencia de outras taxonomias empregadas na linguagem coloquial para definir experiências que possuem alguma afinidade, tais como a motivação, o afeto, o sentimento e o humor. Segundo Reeve (2006), a motivação (*motivation*) diz respeito ao direcionamento e engajamento em determinada tarefa. Estudos nesta área buscam esclarecer os motivos pelos quais o indivíduo realiza determinada ação e, por conseguinte, porque estas ações podem variar de intensidade entre diferentes pessoas em circunstâncias semelhantes. Emoção e motivação também parecem estar relacionadas em sua origem etimológica (do latim *movere*) ao sentido de movimento, indicando um estado de ação.

Em relação ao afeto (*affect*), diferentes definições são empregadas na literatura científica. Meyer (1956) o define como a “emoção sentida” (*emotion felt*), que difere da “emoção percebida” (*perceived emotion*). Belzung (2007), por sua vez, diferencia afeto e emoção apenas em função de suas intensidades (fraca para o afeto, forte para a emoção). Juslin e Scherer (2005), por outro lado, atribuem um sentido amplo ao termo, isto é, empregam afeto para definir genericamente uma categoria de experiências que envolvem emoção e humor, como na expressão “ciências afetivas” (*affective sciences*). Uma definição ampla para o termo também é apresentada por Juslin (2019). Segundo o autor,

Este termo é usado como um termo genérico que cobre todos os estados avaliados – ou “valenciados” (positivo/negativo) [...]. O termo denota tais fenômenos em geral. Se não for essa a intenção, um termo mais preciso [...] é usado em seu lugar. (Juslin, 2019, p. 25).

Já o sentimento (*feeling*), por sua vez, está ligado ao componente subjetivo da experiência emocional, como descrito por Engelman (1986) e Belzung (2007). Esta definição ocupa um lugar importante no contexto do modelo James-Lange (Lent, 2005; Plutchik, 1980) e da hipótese do marcador somático apresentada por António Damásio (2011), uma vez que ambos estão relacionados à percepção das alterações que ocorrem no corpo do indivíduo. Para Belzung (2007, p. 18),

O sentimento distingue-se da emoção no sentido em que ele designa mais particularmente a componente subjetiva, sentida, da emoção e não se refere às componentes comportamentais e fisiológicas. Tendo em conta os muitos debates sobre a existência desta componente subjetiva nos animais, emprega-se este termo sobretudo para designar estados emocionais humanos.

Finalmente, o humor (*mood*) é formalmente definido como um processo lento, duradouro e pouco intenso, ao contrário das emoções, que tendem a ser rápidas, passageiras e muito intensas (Keltner & Lerner, 2010; Belzung, 2007; Juslin & Scherer, 2005; Meyer, 1956). De forma análoga ao humor, Engelman (1986) emprega a expressão “estados de ânimo”. As pesquisas que se apropriam do termo “emoção” no campo da música utilizam-se comumente da definição de *mood*, evidenciando aspectos intrinsecamente relacionados à obra musical. Segundo Fornari (2013, p. 142-143), *moods* são frequentemente criados a partir de períodos mais extensos de escuta musical, encontrando-se relacionados ao tamanho da obra ou performance. Seus efeitos, portanto, podem persistir por longos períodos e serem verificados na análise de variações de ritmos biológicos individuais.

Notações expressivas da partitura musical que evidenciam o caráter da obra ou da seção, por sua vez, também possuem forte correlação com o conteúdo semântico utilizado para definir as emoções (Juslin, 2013b). Termos triviais como *dolce*, *grave* e *scherzando* são fortemente associados na música de concerto ocidental a emoções como tranquilidade, tristeza e alegria, respectivamente (Juslin, 2013b).

Para Kivy (1990 apud Peretz, 2010), duas perspectivas distintas podem ser identificadas quando se aborda a questão das emoções musicais (*musical emotions*), ou seja, emoções comunicadas intrinsecamente pela música. De um lado, há pesquisadores que sustentam que a música expressa emoções sem induzi-las (os chamados “cognitivistas”). Em uma visão oposta, há aqueles que defendem que a música induz emoções nos ouvintes (os chamados “emotivistas”). Segundo Peretz (2010), embora a maior parte dos psicólogos experimentais sejam “cognitivistas” por padrão, a ideia de que a música possa induzir emoções tem ganhado cada vez mais adeptos.

Para facilitar a compreensão das definições das ideias relacionadas à emoção apresentadas nesta seção, a tabela a seguir apresenta uma síntese dos principais conceitos.

**Tabela 1**

Conceitos relacionados à emoção que serão utilizados nesta pesquisa

Conceitos	Referências	Definições
Motivação	Reeve (2006)	Função psicológica relacionada ao direcionamento e engajamento durante a atividade humana
Afeto	Juslin e Scherer (2005); Juslin (2019)	Definição genérica de experiências de natureza emocional
Sentimento	Damásio (2011)	Componente subjetivo da experiência emocional
Humor	Belzung (2007); Juslin e Scherer (2005)	Alteração afetiva lenta, duradoura e pouco intensa
Estados de ânimo	Engelmann (1986)	Cf. humor
<i>Mood</i>	Fornari (2013)	Eventos afetivos que acompanham a escuta musical por períodos mais longos, como a duração de uma obra ou performance
Emoção	Belzung (2007); Juslin (2019)	Alteração afetiva intensa, rápida e passageira

Fonte: Autor (2021).

Uma vez que foram apresentadas as definições relacionadas à emoção, na próxima seção serão apresentadas as definições relacionadas à preferência, a fim de oferecer uma compreensão da terminologia adotada no decorrer desta pesquisa.

### 1.1.2 Preferência

Hargreaves, North e Tarrant (2016) descrevem a preferência (*preference*) como a escolha entre dois ou mais estímulos musicais em um momento específico, ao passo que o gosto (*taste*) está ligado aos padrões temporais de preferência exibidos pelo indivíduo. A preferência, neste sentido, poderia depender de um ato de escolha. Desta forma, como ato de escolha, a preferência parece estar relacionada ao julgamento e à tomada de decisão, estando o gosto, por sua vez, situado em longos períodos, podendo perdurar durante fases mais extensas da vida do indivíduo<sup>7</sup>. Isto explicaria, por exemplo, o interesse dos pesquisadores pela associação entre preferência musical e personalidade (Nave et al., 2018; Pimentel et al., 2014; Quadros-Júnior & Brito, 2012; Rentfrow, Goldberg & Levitin, 2011; Pimentel et al., 2009; Pimentel & Donnely, 2008; Pimentel, Gouveia & Pessoa, 2007; Pimentel, Gouveia & Vasconcelos, 2005).

<sup>7</sup> Vale destacar que, em língua portuguesa, o verbo “preferir” é regido como transitivo direto e indireto (e. g., *quem prefere, prefere isso A aquilo*), indicando o ato de escolha (cf. Haury, 2015). Contudo, em linguagem coloquial, é comum a utilização com o sentido de *gostar*, com regência de verbo transitivo direto (e. g., *eu prefiro isso*).

A tomada de decisão (*decision making*), por sua vez, está circunscrita à habilidade dos indivíduos para processar múltiplas alternativas e escolher (*to choice*) o melhor curso de ação (Sanfey, 2007), tendo sido investigada sob uma perspectiva multidisciplinar e constituindo muitas vezes um campo de pesquisas próprio envolvendo a neurociência, a psicologia, a economia, a estatística e a computação, dentre outras disciplinas. Como os resultados das decisões muitas vezes são desconhecidos, os indivíduos devem considerar a carga de incerteza ao fazer seus julgamentos (*judgments*); além disso, estratégias adaptativas são necessárias, uma vez que as relações de ação/resultado mudam com certa frequência, tornando o estudo e a modelagem da tomada de decisão desafiadores (Lee, 2008).

De modo geral, estudos no campo da pesquisa sobre a preferência musical têm procurado considerar, em maior ou menor grau, a música, o contexto/situação de escuta e as características individuais dos ouvintes. O modelo do *feedback* recíproco (Hargreaves, North & Tarrant, 2016; Hargreaves, 2012) é particularmente relevante sob este aspecto, ainda que não seja direcionado especificamente para a modelagem da preferência, mas de respostas genéricas à música. Segundo Hargreaves, North e Tarrant (2016, p. 304), a maneira como a música é processada sofre influência das variáveis envolvidas nos três componentes em interação de qualquer experiência musical, quais sejam, a pessoa (ouvinte, compositor, improvisador ou executante), a música e o contexto de escuta. Os autores denominaram esse fenômeno como modelo do *feedback* recíproco porque cada um dos três componentes pode exercer uma influência simultânea sobre os demais, e essas influências mútuas são bidirecionais em cada caso.

Contudo, poucos estudos investigaram a tomada de decisão em cenários envolvendo práticas musicais ou hábitos de escuta. Civai, Teodorini e Carrus (2020), por exemplo, realizaram um estudo entre domínios diferentes (música e linguagem) procurando evidenciar aspectos relacionados à expectativa na música e na tomada de decisão em contextos sociais (*social decision-making*). Os resultados do estudo não demonstraram evidências significativas de um mecanismo de expectativa compartilhado entre os domínios. Lefford e Thompson (2018) observaram a tomada de decisão em um ambiente de trabalho de músicos de estúdio, buscando descrever os processos decisórios e a resolução de problemas por meio de um estudo etnográfico. Os resultados encontrados pelos autores sugerem que a produção musical envolve reflexões metacognitivas<sup>8</sup>. Berns e colaboradores (2010) analisaram a prática de avaliação (*rating*) de obras musicais por adolescentes. Os autores identificaram áreas cerebrais relacionadas à música e à tomada de decisão em contextos sociais.

Konečni (2010) pressupõe que emoções sentidas pelos ouvintes em situações de escuta modulam o ato de escolha musical, mas também estas escolhas poderiam modular as emoções. De

---

<sup>8</sup> De acordo com os autores, metacognição envolve a avaliação de sua própria cognição ou pensamento (Lefford & Thompson, 2018).

acordo com o autor, ouvintes que sentem raiva no momento da escuta, por exemplo, tendem a escolher trechos de baixa complexidade musical, ocasionando transformações em seus estados emocionais. Segundo o *prototypical emotion-episode model* (PEEM), um determinado evento pode desencadear um processo perceptivo/cognitivo particular, cuja resposta fisiológica poderá, por sua vez, desencadear experiências emocionais distintas que subsidiarão comportamentos individuais dando início a novos eventos e comportamentos.

O *prototypical emotion-episode model* (Konečni, 2010) e o modelo do *feedback* recíproco (Hargreaves, North & Tarrant, 2016; Hargreaves, 2012) parecem estar associados a um mecanismo de causalidade circular presente em sistemas complexos (Vernon et al., 2015), conforme será apresentado na seção 5 deste capítulo. Com efeito, ambos são influenciados mutuamente pelas partes que os compõem (i. e., no PEEM, os ouvintes escolhem as faixas que ouvirão em função das emoções sentidas e as faixas influenciam suas emoções; no modelo do *feedback* recíproco, o contexto é afetado pelos ouvintes, que interferem na música criada/produzida/executada/escolhida).

A tabela a seguir apresenta o resumo das principais definições relacionadas à preferência e à tomada de decisão.

**Tabela 2**

Conceitos relacionados à preferência que serão utilizados nesta pesquisa

Conceitos	Referências	Definições
Preferência	Hargreaves, North e Tarrant (2016)	Ato de escolha entre dois ou mais estímulos musicais
Gosto	Hargreaves, North e Tarrant (2016)	Padrão de preferência podendo perdurar durante períodos temporais extensos da vida do indivíduo
Tomada de decisão	Sanfey (2007)	Habilidade dos indivíduos para processar múltiplas alternativas e realizar suas escolhas
Escolha	Sanfey (2007)	Ato de seleção durante o processo decisório
Julgamento	Lee (2008)	Avaliação do cenário que requer a decisão

Fonte: Autor (2021).

Uma vez que os conceitos de emoção e preferência tenham sido devidamente definidos, a próxima seção contém os elementos para a compreensão dos fundamentos da Teoria Unificada das Emoções Musicais de Patrik Juslin, com o intuito de favorecer a abordagem com a qual se trabalha nesta tese.

## 1.2 As emoções e a Teoria Unificada das Emoções Musicais de Patrik Juslin

Após um longo período de esquecimento desde René Descartes (Damásio, 2011), o interesse pelo estudo das emoções foi redescoberto em 1872 com a publicação de “A expressão das emoções nos homens e nos animais”, de Charles Darwin (Belzung, 2007). Castilho e Martins (2012) sugerem que este seja um dos principais trabalhos do autor dedicado ao estudo da espécie humana, embora suas hipóteses evolucionistas tenham sido apresentadas em seus livros anteriores (“A origem das espécies”, de 1859, e “A origem do homem e a seleção sexual”, de 1871). Para os autores, Darwin teria se inspirado na obra do anatomista Charles Bell (1774-1842), que havia sugerido a existência de músculos faciais destinados exclusivamente à expressão de emoções, levando a uma série de questionamentos acerca de seu papel no contexto da seleção natural descrita anteriormente por Darwin.

A publicação de “A expressão das emoções nos homens e nos animais” aqueceu um extenso debate acerca das emoções e dos afetos, o que permitiu a elaboração de diversas teorias destinadas a explicar o que são, para que servem e como ambos podem ser expressos. Plutchik (1982) descreve ao menos quatro tradições epistemológicas que sucederam de imediato o trabalho de Darwin: além da tradição evolucionista propriamente dita, devem ser destacadas a tradição psicofisiológica alinhada aos trabalhos de William James (1842-1910), a tradição derivada da neurologia e da neurofisiologia, representada por Walter Cannon (1871-1945), e, finalmente, a tradição dinâmica psicanalítica liderada pelo seu expoente, Sigmund Freud (1856-1939).

Segundo Plutchik (1982, p. 531), Darwin assumiu a continuidade de expressões entre animais e humanos (como no caso do aparecimento das presas do lobo estando relacionada ao sorriso de escárnio do adulto humano). O autor também destaca que muitas espécies de animais – o que inclui os seres humanos – mostram-se aparentemente maiores para expressar a raiva, devido a ereção dos pelos (ou penas) corporais, mudanças posturais e expansão pulmonar. Estas emoções, para Darwin, aumentariam as chances de sobrevivência e constituiriam reações apropriadas a eventos que ocorrem no ambiente. Para Plutchik (1982), as contribuições de Darwin influenciaram substancialmente o desenvolvimento da etologia – uma ramificação da zoologia que trata dos instintos animais.

Em meados de 1890, William James e Carl Lange propuseram, de forma independente, um modelo teórico para explicar as emoções, reivindicando a continuidade do trabalho de Darwin (Toassa, 2012). Em linhas gerais, o modelo James-Lange está baseado na existência de dois componentes principais: a reação fisiológica e o sentimento. A reação fisiológica seria controlada pela exposição ao estímulo desencadeante, ao passo que o sentimento estaria relacionado à percepção subjetiva da própria reação, acentuando ou atenuando-a (Damásio, 2011; Belzung, 2007; Lent, 2005). Plutchik (1982) apresenta o modelo James-Lange como um problema ambíguo do tipo “ovo-galinha”:

no contexto das experiências emocionais, qual seria o evento de primeira ordem – as reações fisiológicas ou o sentimento subjetivo?

Nas palavras de James (1890 como citado em Damásio, 2011, p. 127-128),

É-me muito difícil, se não mesmo impossível, pensar que espécie de emoção de medo restaria se não se verificasse a sensação de aceleração do ritmo cardíaco, de respiração suspensa, de tremura dos lábios e de pernas enfraquecidas, de pele arrepiada e de aperto no estômago. Poderá alguém imaginar o estado de raiva e não ver o peito em ebulição, o rosto congestionado, as narinas dilatadas, os dentes cerrados e o impulso para a ação vigorosa, mas, ao contrário, músculos flácidos, respiração calma e um rosto plácido?

Embora representasse uma ideia genuína a seu tempo, a contribuição de William James destacava apenas aquilo que mais tarde se convencionou denominar sistema nervoso autônomo, em detrimento do importante papel do sistema nervoso central no processamento das informações e controle operacional do corpo. Vale destacar que o lobo límbico teria sido descrito apenas em 1878, por Paul Broca, e que o sistema límbico é uma definição formulada em 1952 (Afifi & Bergman, 2007; Belzung, 2007).

Conforme sugere Damásio (2011, p. 128), o principal problema no modelo James-Lange parece ter sido o fato de esses autores terem atribuído pouca ou nenhuma importância ao processo de avaliação mental da situação que provoca a emoção. De acordo com Damásio, este tipo de explicação proposta por William James faz sentido para as emoções mais básicas que os indivíduos experimentam no início da vida, mas parece pouco plausível para as emoções complexas, que os leva à reorientação cognitiva durante determinado contexto. Além disso, James não teria estipulado um mecanismo alternativo ou suplementar para criar um sentimento correspondente ao corpo excitado pela emoção, mantendo-o sempre interposto ao processo.

Outra possibilidade de contestação do modelo James-Lange advém da análise de casos relacionados a indivíduos que sofreram lesões medulares ocasionando disfunções do sistema nervoso autônomo. Este foi o principal argumento de Cannon (Plutchik, 1982), que, ao realizar estudos com modelos animais, observou que estes conseguiam expressar devidamente as emoções, mesmo que possuíssem alguma lesão que inviabilizava a atuação do sistema nervoso autônomo em regiões do abdômen. Para este autor, perceber as modificações corporais parece não ser necessário para a gênese das emoções (Belzung, 2007).

O modelo de Cannon, portanto, se volta para o papel do sistema nervoso central como entidade responsável pela regulação emocional, em especial a área do hipocampo (Plutchik, 1982). À época de Cannon, a maior parte dos neurofisiologistas, como Korbinian Brodmann, Paul Broca, Karl Wernicke e outros, estava preocupada em localizar áreas funcionais do encéfalo. Este grupo de

pesquisadores ficou conhecido como localizacionistas. Entretanto, com o tempo, perspectivas diferentes da organização do sistema nervoso foram apresentadas, como nos estudos dos distribucionistas, preocupados com o processamento distribuído e paralelo das redes ou circuitos neurais. Avanços neste sentido têm sido alcançados, por exemplo, nos estudos da dor fantasma e da plasticidade neuronal (Nicoletti, 2011; Ticianeli & Baraúna, 2002).

A tradição dinâmica psicanalítica tem sua origem nas investigações de Freud a respeito da histeria. Segundo Plutchik (1982), Freud pressupôs que pacientes histéricos com paralisia ou perda sensorial poderiam ser “curados” através de hipnose combinada com ab-reação, ou seja, uma técnica anterior à psicanálise relacionada à catarse. Isso influenciou diretamente sua teoria sobre as emoções, que foi ressignificada a partir da compreensão de que as emoções podem ser expressas, modificadas, transformadas, reprimidas e distorcidas de diferentes formas<sup>9</sup>.

Para Plutchik (1982), embora eventualmente conflitantes entre si, as quatro tradições representam importantes contribuições para a uma compreensão abrangente das emoções e devem ser incorporadas a uma teoria geral destinada a explicá-las, em maior ou menor grau. O paradigma vigente costuma evidenciar os componentes fisiológicos, expressivos, comportamentais, cognitivos e subjetivos (Belzung, 2007), tratando-os quase sempre de forma indissociável.

Com efeito, a teoria psicoevolucionista de Plutchik (1980; 1982) assume a existência de dois tipos principais de emoções, as chamadas emoções básicas ou primárias e as emoções complexas ou secundárias<sup>10</sup>, em uma perspectiva categórica. Para o autor, as emoções básicas são inatas e apresentam uma função adaptativa, de forma que são compartilhadas entre culturas distintas e entre alguns animais. São exemplos de emoções básicas a alegria, cujo aprendizado é inato, e o nojo, compartilhado entre certas espécies e responsável pela segurança alimentar (Damásio, 2011). As emoções complexas, por sua vez, seriam desenvolvidas social e culturalmente a partir de estruturas emocionais anteriores (emoções primárias) apresentando ausência ou diminuição de sua importância adaptativa, a exemplo do orgulho ou da inveja.

Para diferenciar as camadas emocionais básicas e complexas, Plutchik (1982) adota três dimensões: pureza, intensidade e polaridade. A pureza diz respeito a como determinada emoção se apresenta em seu estado puro, distinguindo-se naturalmente das demais (por exemplo, a alegria). A intensidade, por sua vez, diz respeito à forma como determinadas emoções podem variar em graus diferentes (por exemplo, o medo e o pânico). Por fim, a polaridade trata do modo como determinada emoção se “aproxima” ou se “distancia” das demais (por exemplo, o dipolo alegria/tristeza).

---

<sup>9</sup> Posteriormente, Freud substituirá a hipnose dando lugar à sua psicanálise (cf. Darriba & Bosse, 2013).

<sup>10</sup> Segundo Plutchik (1982), a noção de emoções primárias e secundárias não foi proposta originalmente pelo autor e encontra paralelos com os trabalhos precedentes de Spinoza, Hobbes, Darwin, James e McDougall.

De forma semelhante, a Teoria Unificada das Emoções Musicais está baseada em um modelo de múltiplas camadas emocionais e tem sido empregada para explicar o uso de mecanismos psicológicos subjacentes que operam durante um evento musical (Juslin, 2016; Juslin, Barradas & Eerola, 2015; Juslin & Isaksson, 2014; Juslin, Harmat & Eerola, 2014; Juslin, 2013a; Juslin, 2013b; Juslin & Västfjäll, 2008). Tal teoria pressupõe que as emoções desencadeadas pela música podem ser distribuídas em camadas básicas (e, portanto, supostamente universais) até camadas emocionais mais complexas e culturalmente específicas (Juslin, 2013a; Juslin, 2013b). Desta forma, as emoções poderiam variar de acordo com o tipo de mecanismo acionado durante um evento musical específico<sup>11</sup> (Juslin, Harmat & Eerola, 2014; Juslin, 2012; Juslin & Västfjäll, 2008).

Os mecanismos subjacentes às emoções são considerados dispositivos de processamento de informações em diferentes níveis do cérebro, utilizando tipos distintos de informação para guiar o comportamento futuro. Como estes mecanismos dependem de funções de origem evolucionária distintas, cada mecanismo terá características únicas. No entanto, a ativação das emoções é marcada pela redundância funcional, que é caracterizada pela utilização de vários processos no sistema nervoso central, podendo ser encontrada em sistemas emocionais que empregam vários mecanismos para processar eventos críticos. Tais sistemas possuem a vantagem de apresentar resultados robustos durante o processamento da informação, mesmo quando algum mecanismo falha em responder a algum evento. Por outro lado, a redundância funcional pode fornecer resultados conflitantes, levando à ocorrência de emoções mistas (Juslin, 2013a).

As versões mais recentes desta teoria consideram oito mecanismos subjacentes relacionados às emoções desencadeadas em música que podem ser descritos através do acrônimo BRECVEMA, em que B indica reflexo do tronco cerebral (*Brain stem reflex*), R indica pareamento rítmico (*Rhythmic entrainment*), E indica condicionamento avaliativo (*Evaluative conditioning*), C indica contágio emocional (*emotional Contagion*), V indica imaginário visual (*Visual imagery*), E indica memória episódica (*Episodic memory*), M indica expectativa musical (*Musical expectancy*) e A indica julgamento estético (*Aesthetic judgment*) (Juslin, 2016; 2013a; Juslin, Harmat & Eerola, 2014). De acordo com Juslin, Harmat e Eerola (2014), as definições dos mecanismos são:

- Reflexo do tronco cerebral (***Brain stem reflex***): resposta fisiológica de atenção para características acústicas simples, como aumento de intensidade ou andamento;
- Pareamento rítmico (***Rhythmic entrainment***): ajuste gradual do ritmo corporal interno (por exemplo, frequência cardíaca) por meio do ritmo externo da música;

---

<sup>11</sup> A expressão “evento musical” é empregada aqui como em Juslin (2013a), o qual leva em conta os aspectos musicais propriamente ditos, a experiência do ouvinte e a situação em que ocorre a atividade de escuta. Uma analogia com o modelo de feedback recíproco apresentado por Hargreaves, North e Tarrant (2006) parece promissora.

- Contágio emocional (*Contagion*): mimetismo de expressões emocionais percebidas semelhantes às expressões emocionais da voz humana;
- Condicionamento avaliativo (*Evaluative conditioning*): pareamento regular entre um trecho musical e um estímulo positivo ou negativo, ligado a uma associação condicionada;
- Imaginário visual (*Visual imagery*): projeção de imagens internas de caráter emocional pelo ouvinte através de um mapeamento metafórico das estruturas musicais;
- Memória episódica (*Episodic memory*): recuperação consciente de registros particulares importantes ou marcantes do passado do ouvinte ocasionada pela música;
- Expectativa musical (*Musical expectancy*): reação do ouvinte ao desdobramento gradual da estrutura musical e sua continuação esperada ou não;
- Julgamento estético (*Aesthetic judgment*): avaliação subjetiva do valor estético da música baseada em um conjunto de critérios balanceados.

De acordo com Juslin (2013a), o reflexo do tronco cerebral, o pareamento rítmico e o contágio emocional sofrem menor influência da cultura e do aprendizado, sendo considerados, portanto, mecanismos de natureza filogenética. O reflexo do tronco cerebral envolve o processamento de informações em áreas do mesencéfalo e do núcleo do tálamo, com foco na percepção de mudanças ou eventos no ambiente proximal. O pareamento rítmico, por sua vez, envolve uma rede neural cerebelar e de regiões sensório-motoras, cuja função é facilitar a coordenação motora durante tarefas de atividades físicas. Por fim, o contágio emocional é subsidiado pelos neurônios-espelho contidos em regiões pré-motoras, na região frontal inferior do hemisfério direito e no núcleo basal. Além disso, o contágio emocional também fortalece a coesão grupal e a interação social. Com a exceção deste, os outros dois mecanismos (reflexo do tronco cerebral e pareamento rítmico) têm seu desenvolvimento antes do nascimento e estão ligados a reações fisiológicas (*arousal*). O desenvolvimento do contágio, por sua vez, ocorre durante o primeiro ano de vida e está ligado ao amadurecimento das emoções básicas do indivíduo (alegria, raiva, tristeza, tranquilidade, dentre outras) (Juslin, 2013a). Estas emoções são caracterizadas por continuidade filogenética, desenvolvimento precoce, distintos substratos neurais, acurácia na comunicação facial e vocal entre culturas, percepção categórica de expressões faciais, *clusters* envolvendo termos afetivos e tempo de reação reduzido em tarefas de decisão envolvendo conteúdo lexical derivado das categorias emocionais (Juslin, 2013b). Os três mecanismos estariam ligados a representações de movimento e manifestações sensório-motoras (Juslin, 2013a).

Os demais mecanismos (condicionamento avaliativo, imaginário visual, memória episódica, expectativa musical e julgamento estético) são fortemente influenciados pela cultura e pelo aprendizado social, estando ligados ao processamento que ocorre em áreas límbicas e corticais

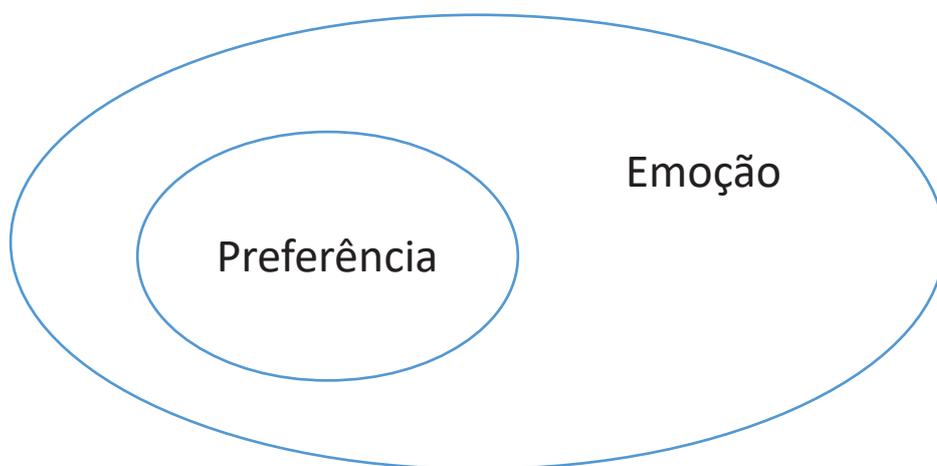
superiores. Desta forma, parecem se desenvolver posteriormente (a partir dos três anos de idade) e depender menos dos elementos psicoacústicos e estruturais da música (com exceção, talvez, da expectativa musical, conforme sugere Meyer, 1956) (Juslin, 2013a).

Juslin, Harmat e Eerola (2014) realizaram um estudo cujo objetivo foi manipular alguns dos mecanismos subjacentes às emoções musicais, notadamente o reflexo do tronco cerebral, o contágio emocional, a expectativa e a memória episódica, incluindo em seu instrumento de medida – uma escala emocional do tipo *likert* – medidas de valência afetiva (“O quanto você gostou da música?”), *Arousal* (“Você sentiu arrepios durante a escuta musical?”) e familiaridade (“Você estava familiarizado com a música?”). Participaram do estudo 20 estudantes do ensino superior, dentre os quais 60% tocavam ao menos um instrumento e, destes, 40% receberam educação musical. O estudo contou com a apresentação de trechos de “*Prayer*”, de “*Jewish Life nº 1*” (Ernest Bloch), e uma citação de “*Binary Sunset*” (John Williams). O material musical direcionado à memória episódica foi reconhecido como familiar, contrastando especialmente com os resultados obtidos pela avaliação dos trechos relacionados ao contágio emocional e à expectativa musical. Em relação à valência, os trechos relacionados à expectativa musical apresentaram os menores escores, contrastando com o contágio emocional e a memória episódica, que apresentaram os maiores escores. Ainda em relação à valência, respostas dos ouvintes aos trechos musicais utilizados para o acionamento do reflexo do tronco cerebral apresentaram resultado semelhante à expectativa, contrastando com o contágio e a memória episódica. Além disso, os resultados sugerem que os relatos dos ouvintes indicaram que a versão do reflexo do tronco cerebral foi a que lhes causou mais surpresa; a versão de contágio emocional despertou mais tristeza; a versão da memória episódica despertou mais alegria e nostalgia; e a versão da expectativa musical despertou a maior irritação.

Posteriormente, Juslin, Barradas e Eerola (2015) utilizaram um procedimento semelhante, investigando os mesmos mecanismos psicológicos em sessenta ouvintes, cuja maioria era estudante. Dentre os participantes, 63% tocavam ao menos um instrumento e 55% receberam alguma educação musical. O objetivo principal do estudo foi manipular os quatro mecanismos por meio de uma seleção cuidadosa de peças ecologicamente válidas. Foram empregadas dezesseis peças musicais, sendo quatro para cada mecanismo. São elas: reflexo do tronco cerebral – “Sinfonia nº 2” (Johannes Brahms), “Sinfonia nº 10” (Gustav Mahler), “O Pássaro de Fogo” (Igor Stravinsky) e “Sinfonia nº 94” (Joseph Haydn); contágio emocional – “*Prayer*”, de “*Jewish Life nº 1*” (Ernst Bloch), “Concerto para Dois Violinos em Lá Menor, Op. 3, nº 8” (Antonio Vivaldi), “Vocalise, Op. 34, nº 14” (Sergei Rachmaninoff) e “*Heart’s Ease (Three Lyrics nº 1)*” (Frank Bridge); memória episódica – “Marcha Nupcial em Dó Maior” (Felix Mendelssohn-Bartholdy), “*Sommar, Sommar, Sommar*” (Sten Carlberg), “*Den Blomstertid Nu Kommer*” (Israel Kolmodin) e “*Studentsangen*” (Prins Gustaf); expectativa musical – “Sinfonia dos Salmos” (Igor Stravinsky), “Suíte Lírica” (Alban Berg), “Três

Peças para Orquestra, Op. 6” (Alban Berg) e “Sagração da Primavera” (Igor Stravinsky). O reflexo do tronco cerebral e a memória episódica não apresentaram correlação significativa em relação à valência e à familiaridade musical. O contágio emocional, por sua vez, apresentou uma correlação fraca em relação à valência, mas não à familiaridade. Por fim, a expectativa apresentou uma correlação inversa fraca para valência e familiaridade. Como no estudo anterior, os relatos dos ouvintes revelaram que as músicas selecionadas para o reflexo do tronco cerebral despertaram a maior surpresa; as condições de teste do contágio despertaram mais tristeza; as condições da memória episódica despertaram mais nostalgia e felicidade; e as condições de expectativa musical despertavam a maior ansiedade. A importância destes estudos reside em seus potenciais para demonstrar a especificidade dos mecanismos para evocar determinadas emoções, abrindo portas para novas compreensões acerca das emoções musicais.

Nos estudos de Juslin, Harmat e Eerola (2014) e Juslin, Barradas e Eerola (2015), a preferência – relacionada à valência afetiva – parece depender das emoções comunicadas em especial pelo mecanismo de contágio emocional. A Figura 1 apresenta um diagrama de Venn ilustrando esta relação:



**Figura 1.** Relação entre emoção e preferência a partir dos estudos de Juslin, Harmat e Eerola (2014) e Juslin, Barradas e Eerola (2015).  
Fonte: Autor (2021).

Tendo sido apresentados os fundamentos da Teoria Unificada das Emoções Musicais, bem como os mecanismos psicológicos que a compõem, na próxima seção será apresentada a Nova Estética Experimental de Daniel Berlyne.

### 1.3 A Nova Estética Experimental de Daniel Berlyne

O surgimento da Estética Experimental se confunde com a história do surgimento da psicologia moderna, tendo em Gustav Fechner (1801-1887) seu principal expoente, sem ignorar as contribuições de Wilhelm Wundt (1832-1920) e, indiretamente, de Hermann von Helmholtz (1821-1894), Carl Stumpf (1848-1936) e William James (1842-1910). Fechner teria precedido os estudos experimentais do que mais tarde constituiria a chamada psicologia científica, a partir dos trabalhos de James e Wundt, este último envolvido com as pesquisas de von Helmholtz sobre a percepção. Em geral, a concepção de psicologia enquanto ciência revela um projeto de distanciamento de suas bases metafísicas: James define a psicologia como uma ciência da natureza, reconhecendo os processos fisiológicos relacionados aos fenômenos psicológicos, ao passo que Wundt a define como uma ciência empírica cujo objeto de estudo seria a experiência interna ou imediata do indivíduo (Araújo, 2009; Abib, 2009; Gjerdingen, 2002; Berlyne, 1973; 1971).

Segundo Hargreaves (1986), o estudo da estética possui duas matrizes principais: a estética especulativa, relacionada à filosofia, à história, à crítica de arte e a todas as questões abstratas de nível superior que dizem respeito ao significado e à natureza da arte; e a estética empírica relacionada ao estudo científico do processo de apreciação. De acordo com o autor, a estética empírica possui ainda duas abordagens distintas, sendo uma centrada na obra de arte e outra na resposta estética.

No século XIX, por volta de 1860, Fechner realizou estudos pioneiros naquilo que denominou Estética Experimental, uma das mais antigas áreas de estudo da moderna psicologia (Berlyne, 1973). A Estética Experimental emprega uma abordagem empírica centrada na resposta estética. Em seu livro *Vorshule der ästhetik*, publicado em 1876, Fechner concentra-se na chamada “estética inferior”, ou seja, os aspectos rudimentares da preferência relacionados a formas, sons e cores simples. Para o autor, a compreensão destes aspectos rudimentares poderia fornecer a base para a elaboração da “estética superior”, isto é, das questões relacionadas à estética especulativa. Em geral, Fechner pressupôs que os estímulos eram mais prazerosos quanto mais distantes dos extremos (por exemplo, sons não tão fortes e nem tão fracos), embora seus resultados tenham sido consideravelmente inconclusivos (Hargreaves, 1986).

Até a primeira parte do século XX, as pesquisas sobre a Estética Experimental consistiam em indagar os participantes sobre os estímulos de que gostavam ou preferiam após a realização da tarefa de apreciação. Em geral, estes estímulos eram elaborados artificialmente ou extraídos de obras de arte genuínas, quando não se tratava da própria obra (Berlyne, 1973)<sup>12</sup>. Estudos que empregam estímulos

---

<sup>12</sup> Berlyne (1971) relata, por exemplo, o episódio ocorrido em 1871 em que Fechner se envolveu na análise da apreciação de duas versões da obra *Darmstadt Madonna*, exibidas em um museu de Dresden, na Alemanha. Fechner convidou os visitantes a avaliar a obra, porém, poucos participaram do estudo e a maior parte falhou em fornecer os dados

artificiais são denominados “experimentais” ou “sintéticos”, ao passo que estudos que empregam obras originais são denominados “analíticos” ou “naturalísticos” (Hargreaves, 1986).

No âmbito da Estética Experimental, são descritos três tipos principais de métodos de pesquisa: a *escolha*, quando o participante deve escolher entre dois ou mais estímulos; a *produção*, quando os participantes devem produzir um artefato (desenhando ou compondo, por exemplo); e o *uso*, quando os participantes são solicitados a analisar a funcionalidade da obra/estímulo (como empregar uma trilha sonora para uma cena, por exemplo) (Berlyne, 1971).

Um aspecto conflitante em relação à Estética Experimental diz respeito à associação indireta entre preferência estética e prazer. Os estudos pioneiros de Fechner, bem como aqueles que se seguiram no início do século XX, não ofereceram respostas convincentes para a compreensão da relação entre preferência e hedonismo, embora este fosse um ponto central da teoria vigente. Foi apenas na década de 1970, com as contribuições de Daniel Berlyne (1924-1976) e o surgimento da chamada Nova Estética Experimental, que estas questões começaram a ser esclarecidas. Berlyne (1973) incluiu um novo grupo de variáveis no estudo da Estética Experimental, dentre elas, as variáveis colativas ou estruturais, as variáveis ecológicas e as variáveis psicofisiológicas e, em especial, o *arousal*, indiretamente relacionado às emoções.

Um dos elementos fundamentais na Nova Estética Experimental de Berlyne (1971; 1973) diz respeito ao sistema de recompensas<sup>13</sup> descrito por Olds e Milner (1954) por meio de estudos experimentais com modelos animais. Após a implantação de microeletrodos em modelos animais, os pesquisadores realizaram a estimulação elétrica de determinadas regiões do encéfalo, especialmente àquelas regiões do que viria a ser denominado sistema mesolímbico, isto é, o núcleo acumbens, o hipotálamo, a área tegmentar ventral e o córtex pré-frontal. Os pesquisadores observaram a ocorrência de prazer entre os animais, que novamente procuravam pelo estímulo. Sabe-se, hoje, que o sistema mesolímbico descrito por Olds e Milner (1954) cumpre uma importante função no comportamento sexual, no comportamento motivado (incluindo o desenvolvimento de dependência química e abuso de substâncias psicoativas) e na ocorrência de prazer (Lent, 2005).

Uma revisão produzida por Chanda e Levitin (2013) revelou evidências neuroquímicas significativas da ação da música sobre regiões límbicas e mesolímbicas. Em geral, estas vias utilizam neurotransmissores, como dopamina, opioides, cortisol, serotonina e oxitocina. Foi observado aumento do cortisol quando da presença de música estimulante e, em situações pós-cirúrgicas,

---

corretamente. Embora o controle experimental de Fechner tenha sido consideravelmente frágil, sua inovação metodológica ao tentar conduzir um estudo em campo é de importância reconhecida.

<sup>13</sup> Olds e Milner (1954) empregam o termo reforço positivo (*positive reinforcement*). Berlyne (1971) esclarece sua opção pela adoção do termo recompensa (*reward*) para designar especificamente o reforço positivo e diferenciá-lo do reforço negativo (*punishment*), considerando que se trata de sistemas de processamento antagônicos.

diminuição de cortisol na presença de música relaxante. Os demais neurotransmissores sofreram aumento em outras condições experimentais (por exemplo, quando os participantes escolheram suas músicas preferidas) em resposta à atividade do tronco encefálico<sup>14</sup>.

Berlyne (1971) supôs que as variáveis derivadas da Nova Estética Experimental possuíam alguma relação com a preferência na medida em que se relacionavam funcionalmente com o sistema mesolímbico, atribuindo um papel fundamental ao *arousal* e ao valor hedônico. Segundo o autor:

Há ao menos três razões para acreditar que o valor hedônico de uma obra depende de quão estimulante ou desestimulante ela é. Primeiro, eventos prazerosos ou recompensadores parecem sempre produzir mudanças nos níveis de *arousal* ou “direcionamento” (para usar um termo antigo que, ao menos em alguns aspectos, significa o mesmo que *arousal*). Um organismo frequentemente parece muito excitado e perturbado antes de receber uma recompensa, especialmente quando ele tem estado sujeito a uma condição adversa como raiva ou medo. A aplicação da recompensa (comida, um sinal seguro) então produz uma mudança abrupta para repouso e tranquilidade. Em outras ocasiões, um evento recompensador, em vez de reduzir o *arousal*, faz do organismo mais excitado, ao menos por um momento. Segundo, [...] as partes do cérebro que controlam a flutuação de *arousal* e as partes do cérebro que controlam a recompensa e a punição dependem em grande medida de suas sobreposições, e, em que pese serem distintas, estão localizadas nas proximidades uma da outra, conectadas plenamente entre si. Terceiro, as características em que são articulados o prazer e o desconforto de um estímulo são precisamente aquelas que determinam como o *arousal* é influenciado e, por isso, nós temos denominado tais características de “potencial de *arousal*” [<sup>15</sup>]. Estas características incluem propriedades psicofisiológicas, como intensidade, cor e frequência. Também incluem propriedades ecológicas envolvendo associação, seja inerente ou aprendida, com condições úteis ou ameaçadoras à sobrevivência e ao bem-estar. Mais significante de todas para a estética, elas incluem propriedades colativas ou estruturais, tais como novidade-familiaridade, simplicidade-complexidade, clareza-obscuridade e previsibilidade-imprevisibilidade (Berlyne, 1971, p. 81).

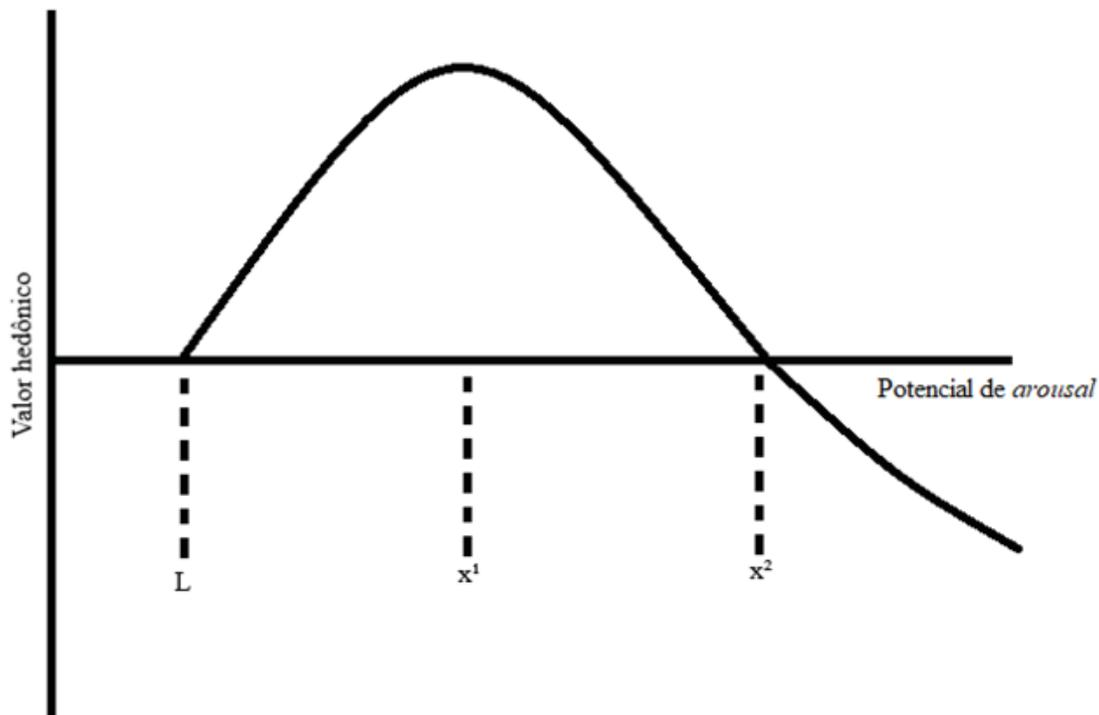
Baseado no estudo sobre prazer e consciência de Wundt (1874 como citado em Berlyne, 1971), bem como na própria tradição da Estética Experimental de Fechner (Berlyne, 1973), o autor estimou que a distribuição do potencial de *arousal* de um determinado estímulo descreve uma

---

<sup>14</sup> O sistema mesolímbico é constituído principalmente vias dopaminérgicas, ou seja, fibras de neurônios que utilizam a dopamina como principal neurotransmissor. Por isso a dopamina tem sido frequentemente associada ao reforço positivo (recompensa). Os opioides, por sua vez, são neurotransmissores relacionados à analgesia e ao sistema de recompensas, como a dopamina. Seus receptores encontram-se situados no córtex cerebral, na medula espinhal, no tálamo e no sistema límbico. O cortisol, produzido nas glândulas suprarrenais por meio da liberação de corticotrofina pela hipófise, está relacionado ao estresse e à adaptação fisiológica a situações de ameaça, tendo receptores em diferentes áreas do cérebro, em especial no hipocampo (que opera no sistema de recompensas como antagonista, ou seja, como reforço negativo) e no córtex pré-frontal. A serotonina é sintetizada pelo triptofano, um aminoácido essencial que depende da ingestão alimentar. Os corpos celulares dos neurônios da via serotoninérgica se encontram situados no tronco encefálico, espalhando-se para diversas partes do cérebro (diencéfalo, hipocampo, amígdala, córtex frontal). Por fim, a ocitocina é um hormônio hipotalâmico, relacionado a uma série de mecanismos de sobrevivência, como a empatia (Chanda & Levitin, 2013; Belzung, 2007; Lent, 2005).

<sup>15</sup> Para Berlyne (1971), é útil a definição de um potencial de *arousal*, ou seja, a “força psicológica” de um estímulo que pode desencadear uma variação fisiológica no organismo. O potencial de *arousal*, portanto, é uma estimativa referente ao estímulo e não propriamente aos efeitos no organismo.

trajetória que se assemelha a uma curva normal (ou “gaussiana”) em relação ao valor hedônico. Baixos limiares de potenciais de *arousal* correspondem à indiferença. Na medida em que o potencial de *arousal* aumenta, também aumenta o valor hedônico positivo, até seu nível máximo. Na Nova Estética Experimental, os estímulos que alcançam o nível máximo de potencial de *arousal* são denominados de “sublimes”. Se, ao contrário, o potencial de *arousal* de um estímulo continuar a aumentar, o julgamento de valor hedônico diminuirá até atingir valores negativos, ocasionando a rejeição (Figura 2).



**Figura 2.** Curva de Wundt aplicada à Nova Estética Experimental.

Nota: “L” se refere ao limiar de potencial de *arousal* necessário para que um estímulo ocasione valor hedônico. “x<sup>1</sup>” diz respeito a um estímulo situado no ponto ótimo da curva, ou seja, cujo potencial de *arousal* ocasiona os maiores valores hedônicos positivos (estímulo “sublime”). “x<sup>2</sup>”, por sua vez, diz respeito a um estímulo situado próximo ao limiar de transição para valores hedônicos negativos.

Fonte: adaptado de Berlyne (1971).

Estudos demonstraram uma relação de tendência linear entre o potencial de *arousal* e as variáveis que compõem a Nova Estética Experimental, notadamente as variáveis colativas (Ramos & Bueno, 2012; Ramos, 2008; Hargreaves, 1986; Cupchik & Berlyne, 1979; Berlyne, 1970). O incremento das variáveis psicofisiológicas (por exemplo, aumento da intensidade, altura ou andamento) ocasiona o aumento proporcional do potencial de *arousal*. De forma semelhante, o incremento das variáveis ecológicas (por exemplo, sinais de segurança, convivência, dentre outras) e colativas (por exemplo, complexidade, familiaridade/novidade, redundância/incerteza, dentre outras) estão diretamente relacionadas à variação proporcional do potencial de *arousal*.

Ressalta-se, entretanto, que as variáveis devem ser escolhidas pelo pesquisador e que essa escolha interfere na orientação do modelo, especialmente no caso das variáveis colativas. A novidade e a familiaridade, por exemplo, são variáveis colativas inversamente proporcionais, ou seja, quanto maior a novidade, menor a familiaridade. Se, durante o delineamento experimental, o pesquisador adota a novidade como variável independente, então, hipoteticamente, o potencial de *arousal* deverá ser proporcional em relação à sua variação. Se, por outro lado, adota como variável independente a familiaridade, então o potencial de *arousal* deverá se apresentar inversamente proporcional. Como destacado por Berlyne e Parham (1968) e Hargreaves (1986), uma parte considerável das variáveis colativas são influenciadas pelo tempo: a familiaridade, por exemplo, aumenta proporcionalmente ao tempo de exposição do indivíduo ao estímulo (e, portanto, inversamente para a novidade). Presumivelmente, este fenômeno também pode ocorrer no caso dos dipolos simplicidade/complexidade e previsibilidade/imprevisibilidade, especialmente se os fatores complexidade e expectativa forem considerados dependentes do aprendizado social e da exposição à cultura.

Após apresentar os elementos de uma teoria da preferência – a Nova Estética Experimental de Daniel Berlyne –, na próxima seção será apresentada uma revisão acerca dos processos de tomada de decisão.

## **1.4 Os processos de tomada de decisão**

Segundo Lee (2008), o processo de tomada de decisão em contextos sociais é um dos comportamentos mais complexos investigados pelos pesquisadores da área, uma vez que, frequentemente, requer que os animais reconheçam acuradamente as intenções de outros e ajustem estratégias comportamentais rapidamente. Particularmente, entre os humanos, pode haver cooperação ou competição, e vários fatores contextuais influenciam na determinação do ponto limite em que estão dispostos a sacrificar seus ganhos pessoais para aumentar ou diminuir o bem-estar dos outros.

Sanfey (2007) descreve três tópicos importantes para os estudos contemporâneos em tomada de decisão: (a) recompensa social: em geral, baseados nos estudos neobehavioristas que buscam compreender como o sistema de escolha está correlacionado com o sistema de recompensa; (b) competição, cooperação e coordenação: uma vez que os modelos clássicos ignoram o papel das emoções, novos modelos têm sido propostos para explicar o papel das emoções negativas que contribuem para resultados de inequidade e não-reciprocidade, o que ocorre quando indivíduos tendem a encorajar a punição para restabelecer a igualdade e/ou reciprocidade (por exemplo, no caso de um agente agir de forma desigual com seus pares, estes tendem a puni-lo como forma de correção para restabelecimento da equidade); (c) raciocínio estratégico: como os indivíduos processam suas

intenções e as intenções das pessoas com quem interagem (processo chamado na literatura científica de teoria da mente – *theory of mind* ou simplesmente ToM –, ou seja, como os indivíduos elaboram uma teoria da mente para explicar as intenções dos outros). Algumas áreas cerebrais relacionadas à ToM estão igualmente relacionadas à rede de modo padrão, que ainda é pouco conhecida (cf. Levitin, 2015); pessoas com autismo e outros transtornos psiquiátricos e neurológicos (como esquizofrenia) apresentam déficits em ToM, o que poderia ocasionar dificuldades em cenários de tomada de decisão.

O estudo de Lerner e seus colaboradores (2015) demonstrou um crescimento exponencial pelo tópico emoção e tomada de decisão a partir do final do século XX. Os autores definiram oito temáticas de interesse buscando descrever a forma como as emoções podem influenciar as decisões, propondo um modelo geral para sintetizar os achados. O modelo de Lerner e seus colaboradores (2015) se baseia em uma avaliação (consciente ou inconsciente) das emoções sentidas, que, por sua vez, podem ser influenciadas pelas características do indivíduo, das opções disponíveis e dos fatores incidentais. Além das emoções, o indivíduo também leva em conta suas próprias características e as características das opções disponíveis para tomar suas decisões, buscando um resultado esperado diante do cenário em questão.

Para modelar os cenários decisórios, alguns pesquisadores recorrem à teoria dos jogos para simular problemas que requerem julgamento e decisão em condições definidas. Segundo Sanfey (2007), a teoria dos jogos é um conjunto de estratégias que procuram compreender e explicar situações em que agentes devem interagir. Neste sentido, a teoria dos jogos oferece uma diversidade de tarefas e fontes de dados em adição aos modelos para a investigação das trocas sociais. Em sua formulação original, a teoria dos jogos busca encontrar as estratégias para as quais um grupo de agentes deve convergir, na medida em que tentam maximizar seus próprios ganhos, chamados também de *payoffs* (Lee, 2008).

Em um artigo redigido em uma única página, John Nash (1949) estabeleceu a ideia do que mais tarde ficou conhecido como “equilíbrio de Nash”. Segundo Lee (2008), o equilíbrio de Nash se refere a um conjunto de estratégias de jogo a partir do qual nenhum jogador individual pode aumentar seus ganhos mudando suas estratégias de forma unilateral. Em certos casos (mas não todos), o equilíbrio de Nash pressupõe a existência de jogos de soma-zero, ou seja, jogos em que o resultado entre aquilo que os jogadores ganharam e perderam é igual a zero (Nash, 1949). Isso ocorre porque o sistema encontra-se fechado, em perfeito equilíbrio: para que o jogador “A” ganhe “X” pontos, nos jogos de soma-zero é necessário que o jogador “B” perca a mesma quantidade de pontos.

Para ilustrar um exemplo de aplicação de teoria dos jogos e equilíbrio de Nash, é possível analisar o cenário de aplicação do chamado “dilema do prisioneiro”. No caso em questão, dois prisioneiros se encontram isolados e sem contato mútuo. Ao serem indagados, têm a opção de (a) se entregar ou (b) entregar o colega. Se alguém entrega o colega (delator), é liberado da pena e o colega

delatado recebe três anos de punição. Por outro lado, se ninguém se entrega e ninguém delata, ambos recebem dois anos de punição para pressioná-los à delação. Caso ambos se entreguem ou se delatem, recebem apenas um ano de punição, uma vez que não é possível saber quem é o culpado já que um dos dois necessariamente estará mentindo. A Tabela 3 apresenta a síntese dos desfechos (*payoffs*) do dilema do prisioneiro:

**Tabela 3**

Síntese dos desfechos do dilema do prisioneiro, em anos.

	<b>Alguém delata</b>	<b>Ninguém delata</b>
<b>Alguém delata</b>	(1,1)	(3,0)
<b>Ninguém delata</b>	(0,3)	(2,2)

Nota: (prisioneiro 1, prisioneiro 2).

Fonte: Adaptado de Lee (2008).

Como pode ser observado na tabela acima, o equilíbrio de Nash está presente, uma vez que o aumento de *payoffs* (maximização) depende das ações de outros jogadores com os quais os indivíduos não estão em contato. Observe-se, também, que a soma-zero não está necessariamente presente.

## 1.5 Sistemas complexos e paradigmas computacionais

### 1.5.1 Sistemas complexos e propriedades emergentes

No contexto da pesquisa em música e emoção, particularmente o que diz respeito à Teoria Unificada das Emoções Musicais baseada nos mecanismos psicológicos subjacentes evocados durante uma escuta musical (Juslin, Harmat & Eerola, 2014; Juslin, 2013a; Juslin & Västfjäl, 2008), a relação entre as propriedades emergentes e os sistemas cognitivos que lhes subsidiam ocupa um lugar central na simulação das respostas emocionais dos indivíduos. Isto porque, ao relacionar determinadas respostas emocionais a mecanismos específicos, como, por exemplo, o reflexo do tronco cerebral, é necessário compreender minuciosamente o funcionamento e a operação deste sistema (no caso, o funcionamento do sistema nervoso autônomo, mas, também, o registro e a recuperação das memórias episódicas, o pareamento rítmico, a projeção do imaginário visual, dentre outros mecanismos recorrentes).

Não obstante, uma questão relevante no estudo da filosofia da ciência diz respeito à emergência e seus correlatos, como as características de propriedades emergentes em sistemas complexos de que trata esta seção.

Em seu Dicionário de Filosofia, Bunge (2002, p. 113) emprega duas abordagens para conceituar a noção de emergência. A primeira é uma abordagem estática, que define uma propriedade emergente a partir da condição em que “[...] se e somente se [tal propriedade] não for dominada por

qualquer componente do sistema”. Neste caso, podem ser tomados como exemplos a percepção (ou seja, uma propriedade que emerge do sistema nervoso) ou mesmo a estrutura social (uma propriedade que emerge de sistemas sociais constituídos por indivíduos). Por outro lado, o autor também considera uma abordagem dinâmica, que está baseada na hipótese de que “[...] todos os sistemas são formados pela assembleia (natural ou artificial) de suas componentes” e encontram-se em transformação permanente. Desta forma, a emergência pode se referir tanto ao desenvolvimento individual (ontogenia), quanto à história (em particular, a evolução): a linguagem, por exemplo, pode ser compreendida como uma propriedade emergente que se desenvolve por volta do último trimestre de gestação, porém, é provável que tenha emergido originalmente na África com o surgimento do *Homo sapiens*, cerca de 200 mil anos atrás (Mithen, 2007). Embora o emergentismo ofereça uma forma de agrupar as concepções filosóficas de emergência baseadas no materialismo, isto é, a noção de um substrato material concreto que possibilite a emergência de propriedades abstratas, é importante diferenciar a noção de emergência do materialismo clássico reducionista (também denominado mecanicismo), uma vez que as características destas propriedades não estão contidas nas partes ou componentes do sistema que lhe dão origem (Bunge, 2002, p. 114). Por este motivo, Teixeira (2011) situa o emergentismo no contexto do materialismo não-reducionista, compatível com as teorias da mente contemporâneas.

De acordo com Nicolelis (2011, p. 34-35), a neurociência do século XX falhou em não possuir um paradigma claro para lidar com a complexidade emergente dos circuitos neurais formados pelos milhões de neurônios interligados e interagindo entre si. Sabe-se, agora, que sistemas formados por grandes números de componentes – como movimentos populares, mercados financeiros, a Internet, o sistema imune e o clima, dentre outros – podem ser classificados como “complexos”, isto é, entidades cujas propriedades fundamentais emergem do funcionamento das partes individuais, mas não se restringem a estas. Para Nicolelis (2011), o cérebro humano é um modelo arquetípico de sistema complexo, contendo 86 bilhões de neurônios e suas conexões (Lent et al., 2012), conjuntamente proporcionando mudanças fisiológicas a cada milissegundo.

Segundo Menezes-Filho (2003, p. 36-37), a metodologia tradicionalmente adotada para o estudo dos fenômenos naturais tende a analisá-los por etapas, dividindo os fenômenos em partes menores. Para o autor, não parece haver grandes empecilhos para problemas de pesquisa lineares, quando a causalidade pode ser devidamente estabelecida. Contudo, isto se mostra inoperante nos casos de comportamento global de sistemas cujo funcionamento não pode ser obtido a partir da simples soma das partes. Menezes-Filho (2003) pontua que o adjetivo “complexo” tem o sentido de destacar a constituição de inúmeras partes de comportamento simples que se influenciam em uma intrincada rede de conexões sistêmicas. A análise deste tipo de sistema emprega com frequência o uso de computadores, uma vez que permite o tratamento irreduzível de seus componentes.

A influência mutual entre as partes componentes de um sistema complexo *per se* em prol de um comportamento organizado é denominada auto-organização. Em geral, comportamento auto-organizado pode ser definido quando as partes do sistema buscam a organização, sendo originalmente estudado na física de partículas, porém de grande interesse para a biologia e outros sistemas, incluindo os sociais (Vasconcellos, Rodrigues & Luzzi, 2015). Comportamentos auto-organizados podem se apresentar de diferentes formas, como, por exemplo, a *autopoiesis* ao nível bioquímico ou mesmo através da causalidade circular (também denominada causação contínua recíproca), quando ambos os componentes são contínua e simultaneamente afetados pela atividade do outro componente atribuído (Vernon et al., 2015).

### *1.5.2 Inteligência artificial e cognição musical: machine learning e music data mining*

Embora não constitua uma temática recente, a emergência de propriedades de sistemas cognitivos complexos ainda representa um grande desafio para a comunidade científica, em especial aos pesquisadores das ciências cognitivas (Jordan, Srinivasan & van Leeuwen, 2015; Carvalho, Varenne & Braga, 2014). Em geral, um sistema cognitivo complexo envolve um grande número de outros sistemas subsidiários. Desta forma, a simulação deste tipo de sistema quase sempre recorre à computação para o desenvolvimento de perspectivas fidedignas, o que se mostra evidente nos avanços da inteligência artificial, da aprendizagem de máquina e, mais recentemente, da chamada computação cognitiva. Para Lamb e seus colaboradores:

Modelos de computação para sistemas complexos que contemplem cognição devem então observar e responder às várias dimensões, individuais e coletivas, e interagir com o mundo exterior. A construção de sistemas complexos cognitivos, considerando habilidades integradas de percepção, comunicação e cooperação são ainda incipientes. Para responder a este desafio, é necessário dominar e compreender os modelos da cognição. A ciência cognitiva é construída sobre a psicologia, filosofia, linguística, neurociência, antropologia, computação e inteligência artificial. Portanto, modelos e sistemas que tenham como objetivo modelar a interação homem-máquina com eficiência, adaptabilidade e usabilidade devem considerar aspectos cognitivos. Devemos então modelar aspectos internos e externos ao sistema, como adaptabilidade e aprendizagem, abstração lógico-matemática adequada e mecanismos de raciocínio computacionalmente tratáveis (Lamb, 2007, p. 2115).

Para Russell e Norvig (2013), a inteligência artificial pode ser definida por um conjunto de estratégias computacionais ligadas à compreensão do pensamento, do comportamento, do desempenho humano e da racionalidade. Segundo os autores, cada estratégia envolve um método

diferente, considerando, por exemplo, a necessidade de hipóteses e confirmação experimental para abordagens centradas em seres humanos ou a combinação de matemática e engenharia para abordagens de natureza racionalista. Com efeito, embora constituam campos de atuação e pesquisa distintos, as ciências cognitivas eventualmente fazem uso de simulações oriundas da inteligência artificial e das técnicas da psicologia experimental para construir teorias a respeito do funcionamento da mente, permitindo o desenvolvimento concomitante de ambas as áreas.

Um dos principais paradigmas para o estudo da inteligência artificial foi desenvolvido por Alan Turing (1912-1954), em 1950, no seu artigo intitulado *Computing Machinery and Intelligence*. Embora a ideia de máquinas jogando xadrez fosse um factóide do século XVIII no caso conhecido como “mecânico turco” (Atkinson, 1998), Turing (1950) recuperou esta questão pressupondo uma série de requisitos necessários para uma definição operacional de inteligência artificial que ficaram conhecidos como Teste de Turing. De acordo com Russel e Norvig (2013), são requisitos para que um computador passe no Teste de Turing: (a) o processamento de linguagem natural para a comunicação entre humanos e máquinas, (b) a representação do conhecimento para armazenamento de informação, (c) o raciocínio automatizado para utilização das informações armazenadas e (d) o aprendizado de máquina (*machine learning*) para se adaptar a novas circunstâncias e para detectar e extrapolar padrões.

De acordo com Paluszek e Thomas (2017), o aprendizado de máquina constitui um campo da ciência da computação independente da inteligência artificial em que os dados preexistentes são utilizados para prever cenários futuros, uma vez que sua aplicação nem sempre está relacionada ao desenvolvimento de sistemas inteligentes autônomos, podendo se relacionar, eventualmente, com rotinas estatísticas. Segundo essa perspectiva, três elementos são importantes para o aprendizado de máquina: os dados, para qual toda atividade de aprendizado é direcionada; os modelos derivados de agentes humanos ou, em alguns casos, emergentes do aprendizado da máquina; e, por fim, o treinamento, que consiste no aprendizado propriamente dito a partir de um algoritmo específico.

Segundo os autores, o aprendizado pode ser supervisionado – quando o agente humano treina previamente a máquina através de um conjunto de dados de exemplo (e. g. redes neurais artificiais, regressões lineares, previsões baseadas em algoritmos bayesianos) –, não-supervisionado – quando não há treinamento anterior (e. g. *clustering*, reconhecimento de padrões, processamento de imagens) –, semi-supervisionado – quando apenas uma parte dos dados é usada para treinamento (e. g. *co-training*) – e recursivo ou *online* – quando os dados são coletados e processados na Internet (e. g. filtros de *spam*).

De acordo com Kim (2017), a modelagem constitui o produto do aprendizado de máquina, mesmo que não exclusivo da inteligência artificial. Por exemplo, as leis de Newton modelam matematicamente equações derivadas de eventos físicos relacionados à dinâmica independentemente

do uso de computadores. No entanto, em algumas aplicações (e. g. física quântica), a mecânica newtoniana e o pensamento lógico não são suficientes para a modelagem, uma vez que as relações entre as variáveis nem sempre são evidentes. Exemplos de aplicações complexas que fazem uso de aprendizado de máquina são as tarefas de reconhecimento de padrões (*pattern recognition*), como faces, palavras e sons.

Paluszek e Thomas (2017) definem a mineração de dados (*data mining*) como uma tarefa que compõe o aprendizado de máquina, sendo uma das primeiras atividades relacionadas à moderna visão de aprendizado, surgida em meados de 1980. Segundo Lima (2009), a mineração de dados está ligada à descoberta de conhecimento (*knowledge discovery*) em grandes conjuntos de dados (*big data*), sendo amplamente utilizada na indústria e no comércio como estratégia para tomadas de decisão de mercado<sup>16</sup>. Diante disso, Han, Kamber e Pei (2012) empregam a expressão *knowledge discovery in data*, ou simplesmente KDD, como sinônimo para mineração de dados.

Embora a mineração de dados não possa ser considerada uma atividade recente em virtude de sua história, deve-se considerar as evidências de que as estratégias baseadas em mineração de dados possam estar se tornando cada vez mais eficientes devido ao incremento qualitativo e quantitativo das bases de dados de alta disponibilidade. Desta forma, a mineração de dados musicais (*music data mining*) tem recebido especial atenção dos pesquisadores da música (cf. Weihs et al., 2017; Li, Ogihara & Tzanetakis, 2011).

Detalhes sobre a implementação da aplicação para recuperação de informações musicais serão apresentados no capítulo II desta tese. A seguir, serão apresentadas a rede Last.Fm e a MetaBrainz Foundation.

### 1.5.3 Last.Fm

Last.Fm é uma rede social digital pertencente à CBS Corporation, através de sua divisão CBS Interactive<sup>17</sup>. Seus serviços compreendem um sistema de recomendações baseado no gosto musical de seus usuários, sendo possível registrar e explorar as preferências musicais por meio do uso de um aplicativo de *scrobbler* (*audioscrobbler*), compartilhar as preferências com outras pessoas

---

<sup>16</sup> Movimento que defende a perspectiva de uma quarta etapa da revolução industrial levada a cabo no fim do século XX, a chamada Indústria 4.0 está fundamentalmente baseada em *big data*, mineração de dados e inteligência artificial. Tais técnicas parecem ter aplicações imediatas na indústria e nas tomadas de decisão em ambientes de negócios e só recentemente têm sido utilizadas como recursos também para instrumentação científica e elaboração de delineamentos em pesquisas comportamentais com foco na produção acadêmica. Com isso, o mercado mundial tem valorizado cada vez mais profissionais com conhecimento em estatística, computação, *machine learning*, *deep learning* e *data science*. Empresas como Facebook, por exemplo, possuem seu próprio departamento de pesquisas (cf. Kramer et al., 2014). O Brasil, por sua vez, possui uma agenda governamental para a Indústria 4.0, que pode ser acessada em <<http://www.industria40.gov.br/>>.

<sup>17</sup> Disponível em <<https://www.cbscorporation.com/portfolio/cbs-interactive/>>.

cadastradas na rede, descobrir novas músicas e artistas por meio do sistema de recomendação e encontrar outros usuários com gostos musicais semelhantes (Amaral & Aquino, 2009; Lima, 2009).

*Scrobbler* consiste no registro de dados sobre os hábitos dos usuários. A Last.Fm emprega o aplicativo *Audioscrobbler* para registrar os hábitos de escuta musical dos usuários de sua rede, coletando dados a partir de computadores e dispositivos móveis em que esteja instalado. O *Audioscrobbler* está atualmente disponível para as versões correntes dos sistemas operacionais Windows, Linux, MacOS, iOS e Android, registrando dados de atividades no *Youtube*<sup>18</sup>, *Spotify*<sup>19</sup>, *Deezer*<sup>20</sup>, *Google Play Music*<sup>21</sup>, *Tidal*<sup>22</sup>, *SoundCloud*<sup>23</sup>, *Mixcloud*<sup>24</sup>, *Sonos*<sup>25</sup>, *Hype Machine*<sup>26</sup>, *8tracks*<sup>27</sup>, *Bandcamp*<sup>28</sup> e *Pandora*<sup>29</sup>.

Para registro das atividades, o *Audioscrobbler* considera dois requisitos: a faixa (*track*) deve possuir mais de 30 segundos de duração e ela deve ser executada pelo usuário por pelo menos a metade de sua duração total ou quatro minutos. Atividades de escuta de usuários cadastrados que não atendam a estes requisitos não são contabilizadas pelo aplicativo.

Os principais registros obtidos pelo software compreendem dados sobre os usuários, artistas, álbuns, faixas, indexadores (tags) e geolocalização, além de um identificador estabelecido pela enciclopédia *MusicBrainz* conforme será descrito posteriormente. Os registros permitem visualizar os padrões de escolha dos usuários, verificar os *rankings* de popularidade de artistas entre usuários de um país ou o número de vezes que uma faixa foi executada, além de outros relatórios fornecidos pelo serviço. Alguns dados podem ser visualizados pelo usuário em seu perfil ou abertamente na página da Last.Fm, enquanto os demais podem ser recuperados através da Last.Fm API, com o cadastro de uma API Key.

O sistema de recomendação da Last.Fm está baseado em folksonomia, descrita como uma “taxonomia popular” de objetos digitais (Bezerra, Guerra & Silva, 2017; Carvalho & Macedo, 2014; Andrews & Pane, 2013; Ferreira, Tacla & Silva, 2012; Brandt & Medeiros, 2010; Cazella, Nunes & Reategui, 2010; Santini & Souza, 2010; Amaral & Aquino, 2009; Figueira-Filho, Geus & Albuquerque, 2008). Estes objetos podem ser indexados pelos usuários através de etiquetas (*tags*), como, por exemplo, na prática de *hashtaging* no Twitter ou Facebook, quando uma postagem é

---

<sup>18</sup> Disponível em <<https://www.youtube.com/>>.

<sup>19</sup> Disponível em <<https://www.spotify.com/>>.

<sup>20</sup> Disponível em <<https://www.deezer.com/>>.

<sup>21</sup> Disponível em <[https://play.google.com/store/music?hl=pt\\_BR/](https://play.google.com/store/music?hl=pt_BR/)>.

<sup>22</sup> Disponível em <<https://tidal.com/>>.

<sup>23</sup> Disponível em <<https://soundcloud.com/>>.

<sup>24</sup> Disponível em <<https://www.mixcloud.com/>>.

<sup>25</sup> Disponível em <<https://www.sonos.com/>>.

<sup>26</sup> Disponível em <<https://hipem.com/>>.

<sup>27</sup> Disponível em <<https://8tracks.com/>>.

<sup>28</sup> Disponível em <<https://bandcamp.com/>>.

<sup>29</sup> Disponível em <<https://www.pandora.com/>>.

indexada pelo autor empregando um termo ou expressão precedidos do sinal #. As *tags* permitem que outros usuários encontrem os conteúdos das postagens utilizando as expressões como argumentos em mecanismos de busca internos ou externos. Além disso, no caso do Twitter, é possível visualizar, em tempo real, os principais assuntos de interesse dos usuários através da cartografia de utilização das *tags* (os chamados *trending topics* ou TT).

Desta forma, na rede Last.Fm, as faixas, álbuns e artistas são objetos indexados por *tags* atribuídas pelos usuários, permitindo a filtragem colaborativa dos conteúdos<sup>30</sup>. Nos sistemas que utilizam filtragem colaborativa:

[...] usuários que avaliam de forma semelhante os mesmos conteúdos são considerados usuários com preferências similares e, portanto, estima-se que um conteúdo avaliado positivamente por esse subconjunto de usuários do qual o usuário  $x$  faz parte deva também ser bem avaliado pelo usuário  $x$  (e.g. Paulo e Roberto gostam de Goethe. Paulo gosta de Molière, então Roberto também deverá gostar do escritor francês) (Figueira-Filho, Geus & Albuquerque, 2008, p. 2.).

Alternativamente, a definição de sistemas de recomendação pode ser descrita em termos matemáticos, conforme apresentado por Jannach e Bonnin (2017, p. 565). O principal algoritmo de filtragem colaborativa em sistemas de recomendação contém duas partes distintas. A primeira delas trata da similaridade entre os usuários e é fundamentada frequentemente a partir do coeficiente de correlação de Pearson, embora outros modelos também possam ser admitidos. A função para a verificação da similaridade entre dois usuários ( $u_1$  e  $u_2$ ), portanto, é

$$sim_{(u_1, u_2)} = \frac{\sum_{i \in \hat{I}} (r_{u_1, i} - \bar{r}_{u_1}) (r_{u_2, i} - \bar{r}_{u_2})}{\sqrt{\sum_{i \in \hat{I}} (r_{u_1, i} - \bar{r}_{u_1})^2} \sqrt{\sum_{i \in \hat{I}} (r_{u_2, i} - \bar{r}_{u_2})^2}} \quad (1)$$

em que  $\hat{I}$  é o conjunto de itens avaliados por ambos os usuários,  $\bar{r}_{u_1}$  é a média das avaliações de  $u_1$  e  $r_{u_1, i}$  é a avaliação do item  $i$  pelo usuário  $u_1$ . Usuários similares que integram um mesmo grupo, portanto, são chamados pares (“*peers*”) ou vizinhos (“*neighbors*”).

A segunda parte trata da predição propriamente dita das avaliações de itens desconhecidos. De acordo com Jannach e Bonnin (2017, p. 565), considerando um usuário  $u_1$  e um item desconhecido

<sup>30</sup> Por esse motivo, Santini e Souza (2010) relatam o eventual uso da expressão “filtragem colaborativa” como sinônimo para “sistema de recomendação”, ainda que os termos façam referência a conceitos distintos, uma vez que nem todo sistema de recomendação emprega necessariamente recursos de filtragem colaborativa. A este respeito, ver Jannach e Bonnin (2017).

$i$ , a predição pode ser obtida a partir da média de avaliações de  $u_1$  e da opinião de uma lista de  $N$  vizinhos similares, conforme a equação:

$$\hat{r}(u_i, i) = \bar{r}_{u_1} + \frac{\sum_{u_2 \in N} (\text{sim}(u_1, u_2)(r_{u_2, i} - \bar{r}_{u_2}))}{\sum_{u_2 \in N} \text{sim}(u_1, u_2)} \quad (2)$$

Em um exemplo cujo resultado é conhecido (Tabela 4), Jannach e Bonnin (2017) estimam a preferência da usuária Alice para a faixa 5, considerando o julgamento de outros usuários que avaliaram anteriormente o mesmo item:

**Tabela 4**

Exemplo de conjunto de dados sobre a avaliação de canções

Usuários	Faixa 1	Faixa 2	Faixa 3	Faixa 4	Faixa 5
Alice	5	3	4	4	?
User1	3	1	2	3	3
User2	4	3	4	3	5
User3	3	3	1	5	4
User4	1	5	5	2	1
Média	3.2	3	3.2	3.4	3.25

Fonte: adaptado de Jannach e Bonnin (2017, p. 565).

Aplicando a correlação de Pearson para encontrar a similaridade (1) descrita anteriormente, é possível identificar os usuários User2 e User3 como pares próximos de Alice (0.85 e 0.70, respectivamente). Quando considerada a função de predição (2), ambos sugerem uma avaliação da Faixa 5 acima da média (4.87), orientando a inclusão da faixa na lista de recomendação de Alice.

Sistemas de recomendação que empregam filtragem colaborativa têm apresentado uma série de desafios para a comunidade de pesquisadores da ciência da computação e recuperação de informações musicais. Dutra (2014) e Kuzelewska e Ducki (2013) descrevem questões relacionadas à esparsidade das informações e o chamado *cold start*. O problema da esparsidade diz respeito à popularidade de certos artistas e faixas: poucos artistas são conhecidos por muitas pessoas, ao passo que muitos artistas são conhecidos por poucas pessoas. Com efeito, os sistemas de recomendação parecem reforçar a popularidade de artistas conhecidos e prejudicar a descoberta de novos trabalhos (Bezerra, Guerra & Silva, 2017). Este aspecto é foco do Estudo II realizado no decorrer desta pesquisa, no qual se procurou simular a preferência musical empregando variáveis como a popularidade.

A questão do *cold start*, por sua vez, está relacionada com a inclusão de novos itens ou ingresso de novos usuários na rede, considerando que novos itens não possuem avaliações (*ratings*) suficientes para serem recomendados e novos usuários não realizaram interações suficientes que

permitam ao sistema agrupá-lo em um conjunto de pares similares. Em sistemas de recomendação voltados para o comércio eletrônico (comum em sites de livrarias como a Amazon<sup>31</sup> ou a Livraria Cultura<sup>32</sup>), o *cold start* pode gerar prejuízos para a empresa em virtude das limitações dos algoritmos de filtragem colaborativa, sendo necessário, portanto, a utilização de alternativas para a composição do sistema de recomendação.

Alguns analistas, por exemplo, responsabilizam a venda de espaços para editoras como um dos principais problemas enfrentados pela crise no comércio de livros no Brasil, especialmente no modelo das *megastores* físicas. Em geral, ao vender espaço nas vitrines, os comerciantes ignoram a preferência do consumidor em um modelo de negócios que é altamente sensível aos interesses dos compradores. A sensibilidade (que pode depender da oferta, da demanda ou do preço) é denominada *elasticidade*. Produtos elásticos são aqueles que, aumentando o preço, diminuem as receitas (elasticidade-preço). Produtos inelásticos, por outro lado, são aqueles que aumentando o preço, aumentam a receita. Em geral, bens de consumo de primeira necessidade são tidos como inelásticos, ao passo que artigos de luxo são definidos como elásticos. Há que se observar, entretanto, o fenômeno da elasticidade cruzada: aumentando o preço de determinado produto, pode-se aumentar a receita das vendas de um produto substituto, diminuindo a receita das vendas do produto primário (bens substitutos). Por outro lado, pode-se ainda aumentar ou diminuir a receita da venda de ambos (bens complementares). Por fim, a venda dos produtos pode não ter relação entre si (bens independentes) (cf. Krugman & Wells, 2017). No caso dos livros, estes parecem ser altamente sensíveis ao preço e à demanda (produtos elásticos), porém, a queda na comercialização de determinado título não apresenta variação em outros livros semelhantes (bens independentes), uma vez que muitas vezes os consumidores procuram livros específicos que não podem ser substituídos ou complementados (por exemplo, quando um consumidor entra na loja buscando um exemplar de “O Alienista”, de Machado de Assis, provavelmente não aceitará comprar um exemplar de “Criação”, de Gore Vidal, caso não encontre o livro que procura). Em se tratando de sistemas de recomendação aplicados ao comércio digital, qualquer falha pode representar grandes prejuízos para a empresa<sup>33</sup>.

#### 1.5.4 *MetaBrainz Foundation*

*MetaBrainz Foundation* é uma instituição criada para subsidiar a iniciativa *MusicBrainz*<sup>34</sup>, uma enciclopédia *open source* de informações musicais *online*. Criada em 2000 por Robert Kaye, a

---

<sup>31</sup> Disponível em <<https://www.amazon.com.br>>.

<sup>32</sup> Disponível em <<https://www.livrariacultura.com.br>>.

<sup>33</sup> A este respeito, ver a matéria publicada em 02 de março de 2017 por Haroldo Sereza na PublishNews, disponível em <<https://www.publishnews.com.br/materias/2017/03/02/crise-nas-livrarias-insistindo-no-erro-ate-encontrar-o-fracasso>>.

<sup>34</sup> Disponível em <<https://musicbrainz.org>>.

enciclopédia tem por objetivo armazenar a maior quantidade possível de metadados musicais editoriais, colaborando com usuários, desenvolvedores e projetos comerciais. Estes metadados estão organizados em torno de entidades como artistas, gravações, selos, editores, instrumentos e *tags*, dentre outras. Recentemente outras iniciativas foram apresentadas pela *MetaBrainz Foundation*, como *MusicBrainz Picard*, *Cover Art Archive*, *CritiqueBrainz*, *AcousticBrainz*, *BookBrainz*, *ListenBrainz* e *MessyBrainz*. A tabela a seguir apresenta um panorama dos projetos disponibilizados pela *MetaBrainz Foundation*, de acordo com as informações contidas em seu site.

**Tabela 5**  
Projetos disponibilizados pela *MetaBrainz Foundation*.

Projeto	Descrição
<i>MusicBrainz</i>	Enciclopédia <i>open source</i> que coleta e disponibiliza metadados musicais.
<i>MusicBrainz Picard</i>	Aplicação para identificar, indexar e organizar gravações de áudio digital.
<i>Cover Art Archive</i>	Banco de dados de artes de capas de discos com <i>releases</i> indexados no <i>MusicBrainz</i> . Constitui um projeto comum com a <i>Internet Archive</i> .
<i>CritiqueBrainz</i>	Plataforma de crítica musical licenciada sob a <i>Creative Commons</i> .
<i>AcousticBrainz</i>	Reúne informações sonoras sobre músicas produzidas em todo o mundo. Iniciativa em conjunto com o <i>Music Technology Group</i> , da <i>Universitat Pompeu Fabra</i> em Barcelona (Espanha).
<i>BookBrainz</i>	Enciclopédia <i>online</i> contendo informações sobre literatura publicada.
<i>ListenBrainz</i>	Plataforma <i>open source</i> que permite aos usuários importar seus hábitos musicais de modo similar à <i>Last.Fm</i> . Uma de suas metas é produzir sistemas de recomendação abertos.
<i>MessyBrainz</i>	Identifica dados danificados e vincula a identificadores estáveis do <i>MusicBrainz</i> .

Fonte: *MetaBrainz Foundation* (disponível em <<https://metabrainz.org/>>).

*AcousticBrainz* é uma plataforma *open source* que se destaca por extrair aspectos sonoros dos objetos musicais indexados pelo *MusicBrainz* e disponibilizá-los para análises de áudio. Elaborado por meio de um esforço conjunto da *MetaBrainz Foundation* e do *Music Technology Group da Universitat Pompeu Fabra* (Barcelona, Espanha), *AcousticBrainz* tem se mostrado uma iniciativa promissora para a composição de um banco de metadados musicais de natureza acústica (Bogdanov et al., 2016; Porter, Bogdanov & Serra, 2016). Após a instalação do programa, o usuário pode analisar suas músicas e enviar estes dados para a composição do *database* da plataforma *AcousticBrainz*, que, por sua vez, serão disponibilizados sob domínio público para outros usuários, desenvolvedores e pesquisadores. Estes metadados estão divididos em duas classes de descritores: *low level* e *high level*. Descritores *low level* incluem dados como dinâmica, intensidade, espectro, andamento (bpm), tonalidade e escalas. Descritores *high level*, por sua vez, incluem dados sobre *mood*, gênero musical

e tipo de voz, a partir de classificadores de aprendizado de máquina supervisionado tendo por base os descritores *low level* empregados na etapa de treinamento. Para extração dos aspectos sonoros, são utilizados recursos da biblioteca *Essentia* para *C++/Python* desenvolvida pelo *Music Technology Group*<sup>35</sup>.

O gerenciamento de metadados musicais na Web Semântica (*Semantic Web*) consiste em uma importante tarefa entre os pesquisadores da área de música e ciência de dados (Raimond & Sandler, 2008; Raimond et al., 2007). Trata-se de uma abordagem importante em recuperação de informações musicais (Downie, 2003) e mineração de dados musicais (Li, Ogihara & Tzanetakis, 2011). No âmbito da recuperação de informações musicais, o interesse por iniciativas de organização dos dados relacionados à música na Web Semântica foi sistematizado por Raimond e seus colaboradores (2007) em torno da chamada *Music Ontology*. De um modo geral, a *Music Ontology* está dividida em três partes: informação editorial (nome das faixas, dos artistas, dos selos), informação a respeito da produção musical (composições, arranjos, interpretações) e decomposição de eventos específicos (e.g. “o pianista está tocando em uma certa tonalidade”) (Raimond & Sandler, 2008). Estes dados estão interligados (*linked data*) em torno de uma rede (*web of data*). Para compor esta rede, Raimond e seus colaboradores (2007) propõem, por exemplo, a utilização de RDF (*Resource Description Framework*) com identificadores URI (*Unique Resource Identifier*) integrados a bancos de dados *open source*, como *MusicBrainz*, *Wikipedia*<sup>36</sup>, *Wikibooks*<sup>37</sup>, *Geonames*<sup>38</sup>, *Wordnet*<sup>39</sup>, *DBLP Bibliography*<sup>40</sup>, *Magnatune*<sup>41</sup> e *Jameno*<sup>42</sup>.

Hemerly (2011), citando o relatório de Jones (2008), descreve maneiras diferentes de entradas de usuários para indexar um mesmo objeto a partir da combinação de dados sobre a faixa e o artista, ilustrando o desafio de gerenciamento dos metadados editoriais. A tabela a seguir apresenta as 25 (vinte e cinco) primeiras posições de um ranking composto pelas 100 (cem) principais formas encontradas nos arquivos dos servidores da rede Last.Fm para definir um mesmo objeto.

---

<sup>35</sup> Disponível em <<http://essentia.upf.edu/documentation/index.html>>. A lista completa de descritores encontra-se disponível em <[http://essentia.upf.edu/documentation/streaming\\_extractor\\_music.html#music-descriptors](http://essentia.upf.edu/documentation/streaming_extractor_music.html#music-descriptors)>.

<sup>36</sup> Disponível em <<https://www.wikipedia.org/>>.

<sup>37</sup> Disponível em <<https://www.wikibooks.org/>>.

<sup>38</sup> Disponível em <<https://www.geonames.org/>>.

<sup>39</sup> Disponível em <<https://wordnet.princeton.edu/>>.

<sup>40</sup> Disponível em <<http://dblp.uni-trier.de/>>.

<sup>41</sup> Disponível em <<https://magnatune.com/>>.

<sup>42</sup> Disponível em <<https://www.jamendo.com/>>.

**Tabela 6**

Diferentes maneiras de indexar um mesmo objeto a partir da combinação de artista/faixa.

Artista	Faixa
Guns N' Roses	Knockin' On Heaven's Door
Guns N' Roses	Knocking On Heavens Door
Guns 'N' Roses	Knockin' On Heaven's Door
Guns N' Roses	Knockin On Heavens Door
Guns N' Roses	Knockin' On Heavens Door
Guns N' roses	knockin on heavens door
Guns N' Roses	Knocking on Heaven's Door
Guns N Roses	Knockin' On Heaven's Door
Guns N Roses	Knockin On Heavens Door
Guns And Roses	Knockin On Heavens Door
Guns NRoses	Knockin On Heavens Door
Guns'n' Roses	Knockin' On Heaven's Door
Guns N Roses	Knockin' On Heaven's Door
Guns 'n' Roses	Knockin' On Heaven's Door
Guns 'N Roses	Knockin' On Heaven's Door
Guns & Roses	Knockin' on Heaven's Door
Guns N'Roses	Knockin' On Heaven's Door
Guns and Roses	Knockin' On Heaven's Door
Guns'n Roses	Knockin On Heavens Door
Guns 'n' Roses	Knockin' On Heavens Door
Aerosmith	Knockin On Heaven's Door
Guns 'n Roses	Knockin On Heaven's Door
Guns 'n' Roses	Knockin On Heavens Door
Guns N Roses	Knockin On Heaven's Door
Guns N' Roses	Knockin On Heaven's Door

Fonte: Jones (2008 como citado em Hemerly, 2011).

Outro tipo de dificuldade encontrada com frequência no gerenciamento dos metadados musicais reside sobre a tarefa de desambiguação dos dados informados a respeito de uma entidade. Eventualmente, dois artistas ou faixas distintas podem ter o mesmo nome, sendo necessário o uso de estratégias para diferenciá-los. Na página oficial da enciclopédia *MusicBrainz*, por exemplo, são citados os casos do compositor americano John Towner Williams (1932-) e do violonista australiano John Christopher Williams (1941-), ambos comumente referenciados por John Williams. Para evitar equívocos desta natureza, o serviço *MusicBrainz* fornece um banco de dados (*MusicBrainz Database*) empregando um identificador para cada entidade (artistas, lançamentos, gravações, trabalhos, selos de gravadoras, geolocalização, lugares e URLs) contendo uma série de *aliases*. O identificador padrão do *MusicBrainz* é chamado *mbid* (MusicBrainz Identifier) e está estruturado em 36 caracteres UUID

(Universally Unique Identifier)<sup>43</sup>. Adicionalmente, o *MusicBrainz Database* faz uso de identificadores extraídos de outros bancos de dados, como o DiscID<sup>44</sup>, AcoustID<sup>45</sup>, Barcode<sup>46</sup>, ISRC<sup>47</sup>, ISWC<sup>48</sup>, IPI<sup>49</sup> e PUID<sup>50</sup>, permitindo a integração com diferentes recursos. O *MusicBrainz Picard* permite verificar dados de identificação em duplicidade ou corrompidos e vinculá-los a identificadores *mbid* estáveis.

A relevância comercial do serviço de padronização de metadados oferecido pela *MusicBrainz*, bem como as demais iniciativas da *MetaBrainz Foundation*, tem atraído a atenção de empresas privadas como *Universal Music Group*<sup>51</sup>, *7digital*<sup>52</sup>, *Spotify*<sup>53</sup>, *BBC*<sup>54</sup>, *Last.Fm*, *Google*<sup>55</sup> e *Amazon*. Os dados coletados pelo *Audioscrobbler* a partir de um serviço de streaming como o *Spotify*, por exemplo, são padronizados de acordo com os identificadores utilizados pelo *MusicBrainz*<sup>56</sup>, reforçando o potencial científico e econômico da iniciativa.

Para dar continuidade à discussão acerca da música e do mercado, na próxima seção serão apresentadas questões relacionadas à popularidade e aos mercados de nicho que sustentam esta tese.

## 1.6 Popularidade e mercados de nicho

Segundo Romanelli (2019), a internet está diretamente ligada ao formato digital da música, o que implica em mudanças inéditas, como a veiculação, pela primeira vez, no mesmo suporte, de texto, imagem e som. Isso implica em uma realidade diferenciada da atividade de escuta das primeiras décadas do século XX, quando som e imagem eram distanciados.

Compreender a popularidade de determinado artista ou obra, portanto, representa um desafio genuíno para a pesquisa em cognição musical e ciência de dados, especialmente em tempos de *streaming* (Araújo, Cristo & Giusti, 2019; Anderson, 2017; Pachet, 2011). Pachet (2011) denomina a área como *Hit Song Science*, ou seja, a ciência por trás das canções que estão no topo das principais “paradas” de sucesso. De modo semelhante ao que se trata aqui, o autor emprega a Nova Estética

---

43 UUID é um padrão constituído por um conjunto de caracteres alfanuméricos empregados para identificar informações em sistemas computacionais.

44 Disponível em <[https://musicbrainz.org/doc/Disc\\_ID](https://musicbrainz.org/doc/Disc_ID)>.

45 Disponível em <<https://acoustid.org/>>.

46 Disponível em <<https://musicbrainz.org/doc/Barcode>>.

47 Disponível em <<https://www.abramus.org.br/musica/720/isrc/>>.

48 Disponível em <<https://www.abramus.org.br/musica/musica-faq/12395/o-que-e-iswc/>>.

49 Disponível em <<https://wiki.musicbrainz.org/IPI>>.

50 Disponível em <<https://wiki.musicbrainz.org/Fingerprinting#PUID>>.

51 Disponível em <<https://www.universalmusic.com/>>.

52 Disponível em <<http://about.7digital.com/>>.

53 Disponível em <<https://www.spotify.com/>>.

54 Disponível em <<https://www.bbc.com/>>.

55 Disponível em <<https://www.google.com/>>.

56 Vale destacar que o *Spotify* emprega também seus próprios identificadores, que podem ser acessados através de sua API disponível em <<https://developer.spotify.com/>>.

Experimental de Berlyne (1971; 1973) para abordar a questão dos efeitos da exposição sobre a familiaridade/novidade.

Ainda no mesmo sentido, Araújo, Cristo e Giusti (2019) investigaram o fenômeno das canções “virais”, procurando elaborar um modelo preditivo baseado em técnicas de aprendizado de máquina para a descoberta de novos *hits* utilizando dados do serviço Spotify. O estudo desses autores se encontra vinculado a uma série de colaborações com artistas regionais e permite identificar fatores que possam ser aplicados para o incremento da popularidade destes grupos.

Anderson (2017), por outro lado, oferece uma leitura diferente do problema em questão. Para o autor, pesquisas nesta área não devem estar focadas nos *hits*, mas nos nichos, uma vez que, assim como outras indústrias que seguem o mesmo padrão na era da *big data*, a indústria musical tem procurado oferecer grandes volumes de produtos para garantir o maior número de usuários. No entanto, apenas poucos produtos terão vendas acentuadas de *hits*, o que demarca a extensão da distribuição, alongando a porção inferior onde consta a maior parte dos produtos (a chamada “cauda longa”). Segundo os dados analisados por Anderson (2017), é esta cauda longa que constitui os nichos e que dá sustentação para o mercado da indústria musical, constituindo uma fatia aproximada de 95 a 98% do mercado. Para Anderson (2017), a economia do *hit* fez sentido enquanto os CDs eram comercializados fisicamente e precisavam de espaço em prateleiras; a partir do momento em que as pessoas puderam ter acesso praticamente ilimitado ao conteúdo digital disponibilizado pelos serviços de *streaming*, parece plausível acreditar que estes mesmos indivíduos passaram a contratar serviços para poder ouvir aquilo que desejarem (e quando desejarem).

Para Anderson (2017, p. 54), portanto:

A teoria da Cauda Longa pode ser resumida da seguinte forma: a nossa cultura e economia estão a abandonar cada vez mais a focalização num número relativamente pequeno de *hits* (produtos e mercados da corrente dominante) no topo da procura, para passarem a centrar-se num elevado número de nichos na cauda. Numa era livre dos condicionalismos associados aos espaços físicos das prateleiras e a outro tipo de estrangulamentos na distribuição, os bens e serviços que são alvo de uma procura mais limitada conseguem ser tão economicamente atrativos como aqueles que se destinam a um público mais vasto.

São características dos mercados baseados em nichos (Anderson, 2017, p. 55): a existência de muito mais produtos de nicho do que *hits*, os custos de acesso cada vez mais decrescentes, a utilização de sistemas de recomendação eficientes, a premissa de que quanto mais eficiente o sistema de recomendação para o nicho, maior a planificação da curva de demanda e, portanto, menor a popularidade dos *hits*, o fato de que todos os nichos juntos contribuem para a formação do mercado e, finalmente, a ideia de que quando tudo está funcionando, a curva de demanda (ou seja, a curva que representa a procura por novos itens) tende a ser normalizada.

Embora estas perspectivas possam parecer conflitantes, ressalta-se que a análise de mercados de nichos proposta por Anderson (2017) deve ser levada em conta na medida em que permite verificar a sustentação econômica da indústria musical. Isso ocorre porque essa sustentação comporta contribuições significativas para a compreensão dos processos relacionados à preferência musical, em que pese as escolhas individuais mediadas por variáveis colativas e psicofisiológicas derivadas da Nova Estética Experimental de Daniel Berlyne (1973; 1971). Além disso, tanto Araújo, Cristo e Giusti (2019), quanto Pachet (2011), concentram suas análises nos *hits* – no topo das “paradas”. Anderson (2017) parece observar o comportamento geral do sistema. Em outras palavras, o mercado se sustenta pela grande oferta de itens (músicas e artistas) e as escolhas do público são mediadas por variáveis como popularidade das faixas e potencial de *arousal*.

Neste sentido, deve-se lembrar que Berlyne (1971) pressupôs que variáveis colativas, a exemplo da familiaridade/novidade, poderiam ser consideravelmente significativas para a preferência da obra de arte. Assim, quanto maiores as métricas de popularidade de uma faixa musical para um determinado grupo de pessoas, presumivelmente maiores serão os níveis de familiaridade atribuídos a esta faixa, uma vez que tanto maiores serão os níveis de exposição ao estímulo em questão.

Esta pesquisa se baseou na hipótese, portanto, que as variáveis descritas nas teorias em questão poderiam influenciar a preferência musical dos ouvintes no contexto da música difundida pelos serviços de *streaming*, na medida em que afetariam diretamente a popularidade das faixas musicais. Isso significa que faixas com maior preferência – aquelas que são escolhidas mais vezes pelos ouvintes – possam ser influenciadas em maior ou menor grau por alguns mecanismos psicológicos relacionados à Teoria Unificada das Emoções Musicais e à Nova Estética Experimental. Esses mecanismos psicológicos (reflexo do tronco cerebral, pareamento rítmico e contágio emocional) foram escolhidos porque estão relacionados aos elementos estruturais da música (Juslin, 2013b) e, por conseguinte, são teoricamente compatíveis com a Nova Estética Experimental, em especial as variáveis psicofisiológicas e colativas.

No capítulo seguinte, serão apresentados os estudos empíricos realizados durante esta pesquisa, com o intuito de sustentar e verificar a hipótese acima mencionada, a saber: (a) desenvolvimento de uma aplicação para mineração de dados; (b) simulação computacional da preferência musical de usuários da rede social Last.Fm; (c) testagem da acurácia da simulação implementada nas primeiras etapas; (d) simulação da popularidade das faixas em cenários evolutivos.

## **2. ESTUDOS EMPÍRICOS**

## 2.1 Estudo I: Goliath Toolbox – uma ferramenta para mineração de dados musicais no Matlab

### 2.1.1 Introdução

A recuperação de informações musicais (*music information retrieval*) constitui uma profícua área de pesquisas na atualidade, com interfaces na computação musical, na cognição e na indústria musical (Jannach & Bonnin, 2017; Song, Dixon & Pearce, 2012a; Song, Dixon & Pearce, 2012b; Yang & Chen, 2012; Li, Ogihara & Tzanetakis, 2011; Eerola, Lartillot & Toivianen, 2009; Downie, 2003).

Uma definição possível para a área envolve a extração de informações e a inferência de características significativas a partir de uma determinada música (incluindo sinais de áudio, representações simbólicas ou de uma fonte externa como uma página da *web*), a indexação do conteúdo utilizando estes recursos e o desenvolvimento de esquemas de pesquisa e acesso (por exemplo, pesquisa baseada em conteúdo, sistemas de recomendação ou interfaces de usuários para navegar em grandes conjuntos de dados) (Schedl, Gómez & Urbano, 2014; Downie, 2003).

Durante o 2<sup>nd</sup> *International Symposium on Music Information Retrieval*, J. Stephen Downie, um dos mais importantes representantes da área, assim se referiu ao campo em um de seus trabalhos apresentados durante o evento:

Como a recuperação de informações musicais (MIR) é um problema de pesquisa tão complexo e multidimensional, muitos grupos de acadêmicos, pesquisadores e interessados começaram a explorar as questões da MIR dentro das estruturas de suas disciplinas específicas. Esses grupos incluem biblioteconomistas, cientistas da computação, engenheiros de áudio, editores e produtores, musicólogos, especialistas em recuperação de informações, advogados de propriedade intelectual, músicos, psicólogos da música, educadores, provedores de conteúdo para Internet, locutores e gerentes de negócios. Os alunos, representando todas as disciplinas acima mencionadas, em níveis que vão da graduação ao pós-doutorado, também estão vendo as questões da MIR como áreas de estudo proveitosas e interessantes (Downie, 2005, p. 5).

No âmbito da MIR, vários estudos têm se dedicado a investigar aspectos emocionais (e. g. Yang & Chen, 2012) e/ou relacionados à preferência (e. g. Liu, Hu & Schedl, 2018; Pachet, 2011; Lima, 2009), empregando técnicas como aprendizado de máquina e mineração de dados musicais.

Neste estudo, portanto, foi desenvolvida uma aplicação utilizando o Matlab R2017b para recuperação de informações musicais em grandes conjuntos de dados pautada em *music data mining*, cujas definições operacionais foram apresentadas na seção 1.5.2 do Capítulo I. Tal implementação

foi baseada no trabalho desenvolvido por Lima (2009), que propôs um *web crawler* para dados de artistas na *Last.Fm API*. Neste cenário, propõe-se ampliar esta possibilidade para a integração com o *MusicBrainz Database*.

Desta forma, *Goliath Toolbox* foi utilizado no decorrer desta tese com o objetivo de recuperar dados da *Last.Fm API* e da *AcousticBrainz*, possibilitando a elaboração de uma simulação capaz de prever a preferência musical utilizando redes neurais. Informações sobre esta etapa serão apresentadas posteriormente, no Estudo II.

### 2.1.2 Características técnicas do *Goliath Toolbox*<sup>57</sup>

No contexto desta pesquisa, os dados foram recuperados em *web services* empregando requisições de protocolo HTTP (*Hipertext Transfer Protocol*) baseadas em REST (*Representational State Transfer*)<sup>58</sup>, que estabelece uma comunicação entre cliente (*client*) e servidor (*server*) e permite ações como inclusão, exclusão, alteração ou recuperação de dados armazenados pelo servidor de acordo com o método empregado pelo cliente (*GET*, *PUT*, *DELETE*, entre outros) (Fielding, 2000). Estas requisições são realizadas por meio de uma API (*application programming interface*), cujo papel é viabilizar uma interface de comunicação entre os desenvolvedores e a aplicação<sup>59</sup>. Exemplos de *web services* que disponibilizam APIs são as redes sociais digitais, como Facebook<sup>60</sup> ou Twitter<sup>61</sup>. Qualquer usuário devidamente cadastrado nestas redes pode interagir com os serviços disponibilizados de acordo com suas políticas institucionais. Para executar e gerenciar as requisições, podem ser utilizados softwares como *Postman*<sup>62</sup> e *Advanced REST Client (ARC)*<sup>63</sup>, dentre outros.

Empregando o método *GET*, por exemplo, é possível recuperar dados que se encontram armazenados pelos servidores de *web services*. Em geral, os resultados para estas requisições são apresentados em formato JSON (*JavaScript Object Notation*) ou XML (*eXtensible Markup Language*). Embora distintos (com destaque para o fato de que JSON é uma forma de notação e XML consiste em um tipo específico de linguagem computacional), ambos os formatos permitem que os dados sejam compreendidos igualmente pelos usuários e pelos dispositivos, através de interações com linguagens de programação.

---

<sup>57</sup> O nome *Goliath* faz referência à aranha-gólias (*Theraphosa blondi*), uma espécie de tarântula endêmica da região amazônica considerada a maior aracnídeo do mundo.

<sup>58</sup> Outra opção para recuperação de dados, por exemplo, é a técnica conhecida como *web scraping*, que consiste em extrair dados diretamente da página desejada através de acesso ao seu código-fonte.

<sup>59</sup> O site <<https://www.99apis.com/>> permite consultar outras opções de acesso a APIs abertas para desenvolvedores e usuários.

<sup>60</sup> Disponível em <<https://pt-br.facebook.com/>>.

<sup>61</sup> Disponível em <<https://twitter.com/>>.

<sup>62</sup> Disponível em <<https://www.getpostman.com/>>.

<sup>63</sup> Disponível em <<https://install.advancedrestclient.com/#/install/>>.

Para exemplificar a saída de dados nos formatos JSON e XML, pode-se considerar o formulário de cadastro *online* de uma biblioteca fictícia contendo dois livros no catálogo: Odisseia, de Homero, publicado em 2014, e Ulysses, de James Joyce, publicado em 1929. O cadastro é formado pelos campos: id (e. g. 01 e 02), título (e. g. Odisseia e Ulysses), autor (e. g. Homero e James Joyce) e ano (e. g. 2014 e 1929). Conforme pode ser observado na Figura 3, os dados recuperados em formato JSON têm a seguinte aparência:

```
1 {
2   "biblioteca":{
3     "catalogo":[
4       {"id":"01",
5        "titulo":"Odisseia",
6        "ano":"2014",
7        "autor":"Homero"
8       },
9       {"id":"02",
10      "titulo":"Ulysses",
11      "ano":"1929",
12      "autor":"James Joyce"}]
13   }
14 }
```

**Figura 3.** Exemplo de respostas no formato JSON.  
Fonte: Autor (2021).

No formato JSON, os dados são apresentados na forma de pares de parâmetros (e. g. título) e valores (e. g. Ulysses). No formato XML, por sua vez, os dados são inseridos entre etiquetas (*tags*) com abertura (e. g. <id>) e fechamento (e. g. </id>). Os dados da biblioteca quando transformados em XML assumem a forma apresentada na Figura 4.

```
1 <?xml version="1.0" encoding="UTF-8" ?>
2 <cadastro nome="biblioteca">
3   <catalogo>
4     <id>01</id>
5     <titulo>Odisseia</titulo>
6     <autor>Homero</autor>
7     <ano>2014</ano>
8   </catalogo>
9   <catalogo>
10    <id>02</id>
11    <titulo>Ulysses</titulo>
12    <autor>James Joyce</autor>
13    <ano>1929</ano>
14  </catalogo>
15 </cadastro>
```

**Figura 4.** Exemplo de respostas no formato XML.  
Fonte: Autor (2021).

Nesta pesquisa, os dados foram recuperados a partir da rede social *Last.Fm*<sup>64</sup> e das iniciativas subsidiadas pela *MetaBrainz Foundation* no formato JSON, cuja estrutura computacional é

<sup>64</sup> Disponível em <<https://www.last.fm/>>.

consideravelmente mais econômica em termos de recursos de memória (bastando conferir o número de linhas e caracteres para os dois catálogos de exemplo disponíveis nas Figuras 3 e 4).

### 2.1.3 Cenário de implementação do Goliath Toolbox

A Figura 5 abaixo representa um diagrama do cenário de pesquisa empregado no decorrer desta etapa. Ao utilizar um serviço de *streaming* (por exemplo, *Spotify*, *Deezer* ou *Google Play Music*) em seu dispositivo (isto é, computador, *notebook*, celular ou *tablet*), o usuário envia dados à rede *Last.Fm* através do *Audioscrobbler*, que emprega recursos da enciclopédia *MusicBrainz* para cartografar as audições e recomendar novas faixas e artistas. A plataforma *MusicBrainz*, por sua vez, permite a identificação de aspectos sonoros (*audio features*) das faixas, por meio da vinculação do identificador *mbid* ao banco de dados *AcousticBrainz* (Lima, 2009):

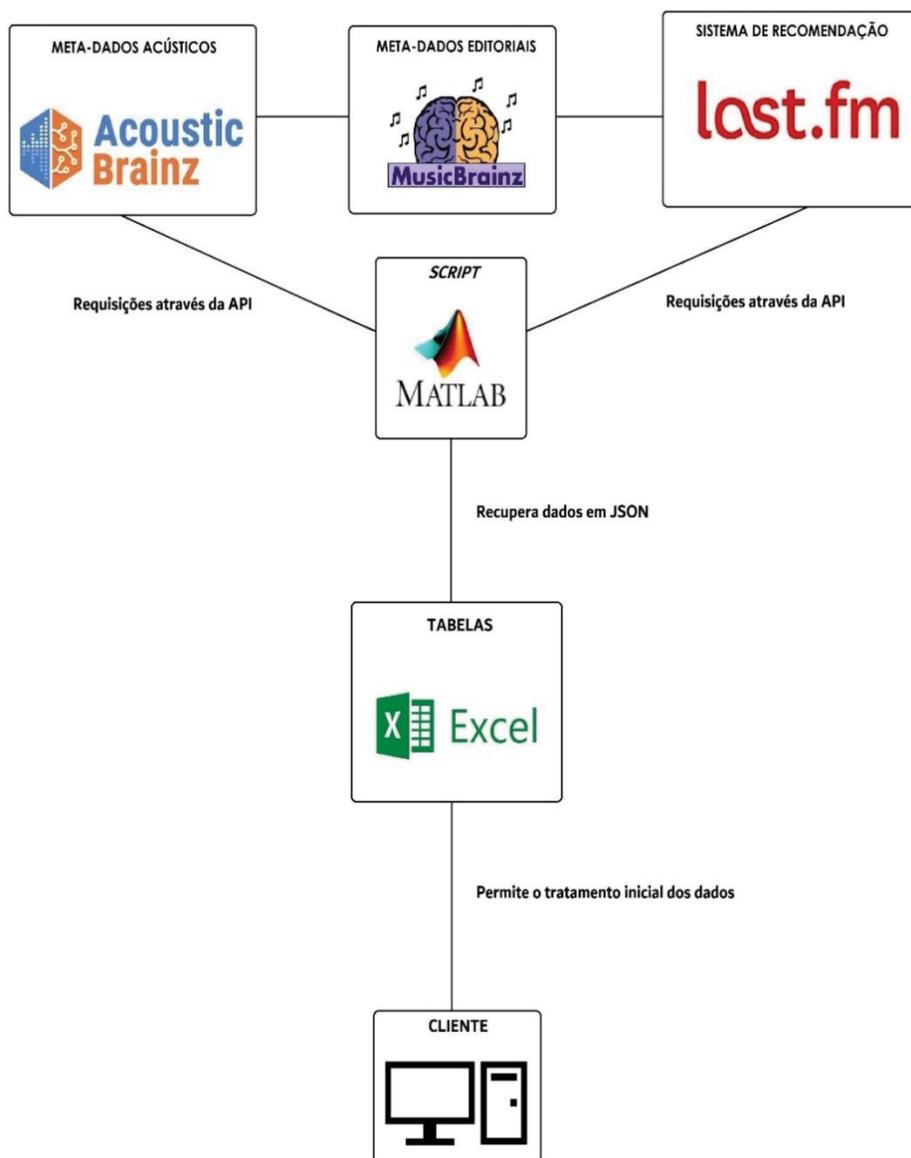


**Figura 5.** Cenário de pesquisa.

Nota: Quando o usuário acessa os serviços de *streaming* e utiliza a rede social/*scrobler*, a Last.Fm contabiliza estes dados e fornece os identificadores mbid para que seja possível encontrar as informações no MusicBrainz Database.

Fonte: Autor (2021).

*Goliath Toolbox*, portanto, constitui um conjunto de funções escritas em Matlab e testadas na versão R2017b para serem aplicadas com o intuito de acessar a *Last.Fm API* e os bancos de dados da *MetaBrainz Foundation* para mineração de dados musicais. Desta forma, é possível recuperar um grande volume de informações sobre a preferência musical de usuários da rede social ou de um determinado país, bem como dados sobre a popularidade de artistas ou faixas, e comparar tais informações com aquelas que se encontram disponíveis na *MusicBrainz Database*. A Figura 6 a seguir, portanto, demonstra uma inserção típica de um *script* empregando o *Goliath Toolbox*.



**Figura 6.** Procedimentos para recuperação de dados.

Nota: O *script* em Matlab representa a inserção do *Goliath Toolbox* para mineração dos dados via API.

Fonte: Autor (2021).

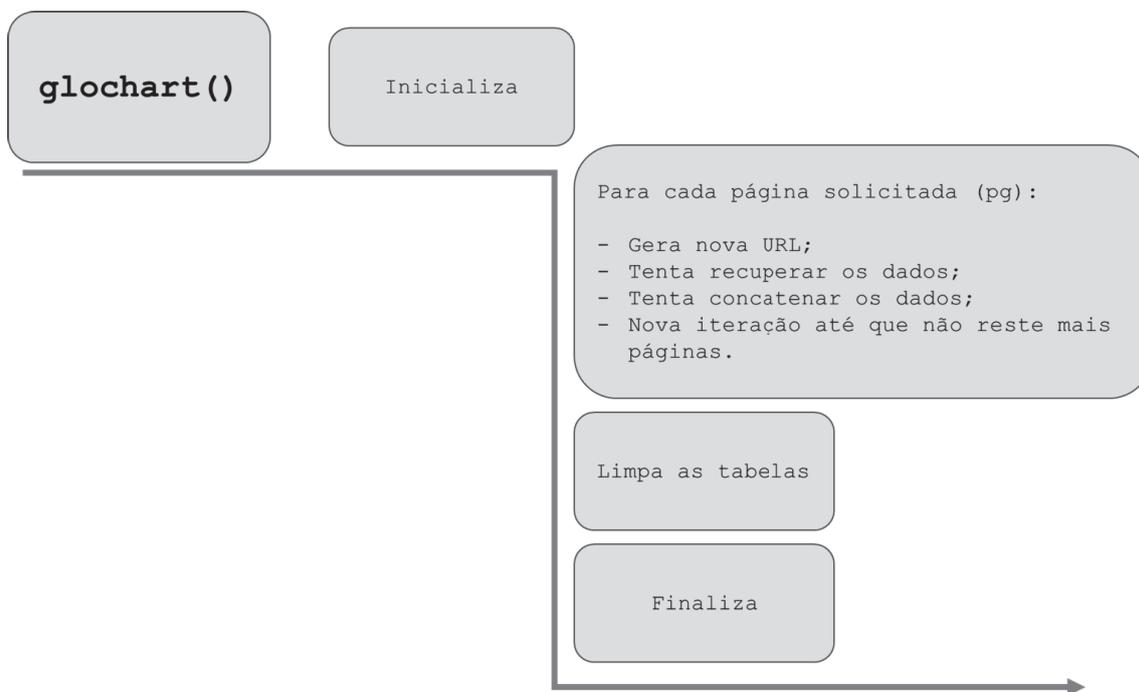
Para efeito operacional, a métrica de popularidade foi mensurada pelo número de ouvintes (*listeners*) cujos perfis de usuário estiveram associados pelo menos uma vez à faixa, isto é, que ouviram pelo menos uma vez a obra em questão. Por outro lado, a preferência foi mensurada pelo número de vezes que a faixa foi executada (*playcount*). Tais métricas permitem, com alguma fidedignidade, obter informações sobre quantos usuários conhecem a faixa (popularidade) e quantas vezes a faixa foi executada (preferência).

Até o presente momento, a aplicação contém as seguintes funções, podendo ser acrescida de outras futuramente:

**Tabela 7**  
Funções incluídas no *Goliath Toolbox*.

Função	Descrição
ArtInfo(art_mbid, art_name)	Recupera informações disponíveis no <i>MusicBrainz Database</i> sobre um artista específico. “art_mbid” equivale ao “mbid” do artista e “art_name” equivale ao nome do artista.
TrInfoAB(tr_mbid, tr_name)	Recupera informações disponíveis no <i>MusicBrainz Database</i> sobre uma faixa específica. “tr_mbid” equivale ao “mbid” da faixa e “tr_name” equivale ao nome da faixa.
TrInfoLFM(AK, tr_name, art_name)	Recupera informações disponíveis na <i>Last.Fm API</i> sobre uma faixa específica. “AK” equivale à API Key do usuário (necessário para utilização da <i>Last.Fm API</i> ), “tr_name” equivale ao nome da faixa e “art_name” equivale ao nome do artista.
geochart(AK, pg, n, country)	Recupera informações disponíveis na <i>Last.Fm</i> sobre a preferência musical dos usuários de um país. “AK” equivale à API Key do usuário (necessário para utilização da <i>Last.Fm API</i> ), “pg” equivale ao número de páginas solicitadas, “n” equivale ao número de resultados por página e “country” equivale ao país que deseja consultar.
glochart(AK, pg, n)	Recupera informações disponíveis na <i>Last.Fm</i> sobre a preferência musical global, incluindo todos os usuários da rede social. “AK” equivale à API Key do usuário (necessário para utilização da <i>Last.Fm API</i> ), “pg” equivale ao número de páginas solicitadas e “n” equivale ao número de resultados por página.
lowS(tr_mbid, tr_name)	Recupera informações disponíveis na plataforma <i>AcousticBrainz</i> sobre os aspectos sonoros de baixo nível ( <i>low-level</i> ) de uma faixa específica. “tr_mbid” equivale ao “mbid” da faixa e “tr_name” equivale ao nome da faixa.
lowM(filename, n)	Recupera informações disponíveis na plataforma <i>AcousticBrainz</i> sobre os aspectos sonoros de baixo nível ( <i>low-level</i> ) de múltiplas faixas. “filename” equivale ao arquivo onde constam os nomes das faixas e os respectivos “mbid” (resultado da função geochart e glochart) e “n” equivale ao número de faixas que deseja consultar.
highS(tr_mbid, tr_name)	Recupera informações disponíveis na plataforma <i>AcousticBrainz</i> sobre os aspectos sonoros de alto nível ( <i>high-level</i> ) de uma faixa específica. “tr_mbid” equivale ao “mbid” da faixa e “tr_name” equivale ao nome da faixa.
highM(filename, n)	Recupera informações disponíveis na plataforma <i>AcousticBrainz</i> sobre os aspectos sonoros de alto nível ( <i>high-level</i> ) de múltiplas faixas. “filename” equivale ao arquivo onde constam os nomes das faixas e os respectivos “mbid” (resultado da função geochart e glochart) e “n” equivale ao número de faixas que deseja consultar.
tablow(filename)	Tabulação dos aspectos sonoros de baixo nível ( <i>low-level</i> ). “filename” equivale ao arquivo onde constam os nomes das faixas que devem ser tabuladas.
tabhigh(filename)	Tabulação dos aspectos sonoros de baixo nível ( <i>low-level</i> ). “filename” equivale ao arquivo onde constam os nomes das faixas que devem ser tabuladas.

A Figura 7 contém o esquema de um pseudocódigo para a função *glochart()*, considerada uma das principais funções disponíveis no *toolbox*. Quando o usuário fornece a *API Key* (cadastrada na *Last.Fm API*), o número de páginas e o número de resultados por página, a função retorna três arquivos contendo dados sobre as faixas mais populares e o número de pessoas que escolheram ouvir as faixas recuperadas.



**Figura 7.** Pseudocódigo para a função *glochart()*.  
Fonte: Autor (2021).

No decorrer desta tese, *Goliath Toolbox* foi utilizado para recuperar informações junto à *Last.Fm API* e à *AcousticBrainz*, com o intuito de coletar dados para providenciar as simulações da preferência (Estudos II e III) e popularidade (Estudo IV), tendo representado um aspecto central para a realização da pesquisa. *Goliath Toolbox* encontra-se disponível no Apêndice A, bem como seu tutorial para instalação e uso (Apêndice B).

A seguir, apresenta-se uma discussão relacionada às principais características encontradas na implementação do *Goliath Toolbox*, incluindo os aspectos técnicos e jurídicos.

#### 2.1.4 Discussão

O desenvolvimento de *web crawlers* e o interesse pela interseção entre *music information retrieval* e cognição musical não é recente. Há cerca de 20 anos, Huron (2000) se questionava: qual é a melhor taxonomia para classificar *moods*, estilos e outras características musicais? Como é possível criar sistemas que caracterizarão de forma automatizada e confiável gravações ou partituras?

Desde então, iniciativas têm sido conduzidas com o intuito de aperfeiçoar a recuperação de informações musicais e o acesso aos dados pelos pesquisadores e desenvolvedores, como, por exemplo, o esforço da *MetaBrainz Foundation*. Tais iniciativas têm permitido o avanço da área e o desenvolvimento de novas aplicações, em diversos centros de pesquisas espalhados pelo mundo. Algumas destas iniciativas, como o software *Essentia*, do *Music Techonology Group* da Universidade Pompeu Fabra, têm sido utilizados também com finalidade comercial, demonstrando potencial econômico para a área de recuperação de informações musicais.

#### 2.1.4.1 Aspectos éticos e jurídicos

A implementação de técnicas de mineração de dados para pesquisas em cognição musical, quando aplicadas dentro do que preceitua as normas éticas e jurídicas (em especial a Lei nº 13.709/2018, conhecida como Lei Geral de Proteção de Dados Pessoais), parece oferecer contribuições significativas para o avanço do conhecimento sobre a mente musical e a recuperação de informações musicais. Entretanto, ressalta-se que devem ser observadas normas específicas dos *web services*, para evitar transtornos como aqueles relacionados recentemente ao Facebook e à *Cambridge Analytica*, que utilizaram dados privados dos usuários para fins comerciais. A má conduta no uso de dados é um dos casos mais recentes em relação ao uso dessa ferramenta<sup>65</sup>. Em 2014, a empresa já havia sido obrigada a se retratar após a publicação de um experimento social no *Proceedings of the National Academy of Sciences of the United States of America* (PNAS), que abordava o contágio emocional massivo em redes sociais sem mencionar a afiliação de um dos autores ao departamento científico do *Facebook* (Kramer et al., 2014). Estes eventos sugerem que o *Facebook* tenha conduzido experimentos em sua rede sem a notificação do público.

Neste sentido, segundo a Lei nº 13.709/2018:

Art. 5º Para os fins desta Lei, considera-se:

I – dado pessoal: informação relacionada a pessoa natural identificada ou identificável;

[...]

III – dado anonimizado: dado relativo a titular que não possa ser identificado, considerando a utilização de meios técnicos razoáveis e disponíveis na ocasião de seu tratamento; (Brasil, 2018).

Além disso:

---

<sup>65</sup>A reportagem do canal de notícias G1 traz pormenores da discussão e pode ser acessada em <<https://g1.globo.com/economia/tecnologia/noticia/2018/12/19/procurador-em-washington-processa-facebook-por-caso-cambridge-analytica-diz-jornal.ghtml>>

Art. 7º O tratamento de dados pessoais somente poderá ser realizado nas seguintes hipóteses:

[...]

IV – para a realização de estudos por órgão de pesquisa, garantida, sempre que possível, a anonimização dos dados pessoais; (Brasil, 2018)

Em relação a este aspecto, os termos de serviço da *Last.Fm API* concedem autorização para o usuário devidamente cadastrado e proprietário de uma *API Key* a efetuar o *download* dos dados e manuseá-los de forma não-comercial, desde que citando os créditos da empresa e de forma a não prejudicar sua imagem comercial. Estes dados garantem a privacidade e anonimato dos usuários e não podem ser vinculados individualmente a pessoas específicas. Com efeito, *Goliath Toolbox* recupera dados relacionados às músicas e não às pessoas.

#### 2.1.4.2 Aspectos técnicos

O tempo de requisição (latência) dos dados é uma questão importante. Os termos de serviço orientam aos usuários não efetuarem mais de cinco requisições de dados por segundo, o que evita a sobrecarga do servidor. Portanto, coletas relacionadas a grandes volumes de dados podem levar horas ou dias para serem executadas. Além disso, como observou Lima (2009), a periodicidade de requisições de dados também deve ser considerada. Na implementação realizada nesta pesquisa, requisições quinzenais se mostraram inviáveis, devido ao grande volume de dados. No entanto, no presente caso, a plataforma não se manteve atualizada com frequência, inviabilizando requisições com periodicidade inferior a um mês.

Os termos de uso dos serviços da *MetaBrainz Foundation*, por outro lado, atribuem uma licença *Creative Commons* de domínio público (CC0 1.0 Universal) à maior parte dos dados, o que indica que nenhum indivíduo pode requerer autoria dos dados. Uma parte minoritária dos dados mantidos pela instituição são protegidos sob a licença *Creative Commons* de atribuição não-comercial compartilha-igual (CC BY-NC-SA 3.0), o que significa dizer que todo produto derivado destes dados deve citar a fonte original e ser utilizado necessariamente de forma não-comercial, de forma a garantir o uso compartilhado, como a matriz original<sup>66</sup>. A vantagem de se utilizar dados oriundos da *MetaBrainz Foundation* é que não é preciso trabalhar com as obras musicais originais. A instituição mantém um banco de dados de informações editoriais e sonoras, permitindo o acesso aos pesquisadores apenas aos dados musicais de relevância científica (como, por exemplo, informações sobre andamento e tonalidade, dentre outros). Com efeito, apresenta-se como uma alternativa viável para evitar

---

<sup>66</sup>Mais informações sobre as licenças *Creative Commons* podem ser encontradas na página oficial da instituição, disponível em <<https://creativecommons.org/>>.

o acesso ilegal a obras musicais protegidas por direitos autorais, evitando qualquer tipo de infração (Panda & Paiva, 2012; Bertin-Mahieux et al., 2011; Swartz, 2002).

Neste caso específico, portanto, *Goliath Toolbox* se apresenta como uma ferramenta viável para pesquisadores e desenvolvedores, porque ele permite o acesso a grandes conjuntos de dados da rede social *Last.Fm* e da *MusicBrainz Foundation*. Tais dados permitem uma grande diversidade de análises, incluindo procedimentos de categorização, comparação, séries temporais, dentre outros. Dentre as inúmeras vantagens deste tipo de abordagem, pode-se citar a possibilidade de acesso a dados musicais coletados em contexto real e de forma espontânea no cotidiano (Juslin & Sloboda, 2010).

No Estudo II, que será apresentado na sequência, os dados foram recuperados com o auxílio do *Goliath Toolbox* para simular a preferência musical em um ambiente computacional, demonstrando uma parcela de seu potencial. No Estudo III, os dados foram coletados utilizando uma função de geolocalização entre usuários brasileiros, ampliando a possibilidade de utilização da ferramenta. Finalmente, no Estudo IV, os dados foram coletados reiteradamente a cada ano, sempre à mesma época, para se comparar a simulação e a evolução da popularidade musical ao longo do tempo.

## 2.2 Estudo II: simulação da preferência musical por meio do uso de redes neurais artificiais

### 2.2.1 Introdução

Este estudo teve por objetivo procurar entender o papel da Nova Estética Experimental e da Teoria Unificada das Emoções Musicais para a preferência musical de usuários da rede social *Last.Fm*. Desta forma, foram realizadas rotinas<sup>67</sup> de recuperação de dados musicais utilizando o *Goliath Toolbox* para Matlab R2017b no mês de abril de 2018. Buscou-se responder às seguintes questões: quais processos psicológicos possivelmente estão relacionados à escolha das músicas destes usuários? Como as variáveis descritas na Nova Estética Experimental e na Teoria Unificada das Emoções Musicais atuam sobre estes processos? A hipótese que guia esse estudo é a de que as variáveis descritas em ambas as teorias possam influenciar a preferência musical, na medida em que afetam diretamente a popularidade das faixas.

Conforme apresentado na Fundamentação Teórica, isso significa que faixas com maior preferência – aquelas que são escolhidas mais vezes pelos ouvintes – sejam influenciadas em maior ou menor grau por alguns mecanismos psicológicos relacionados à Teoria Unificada das Emoções Musicais e à Nova Estética Experimental. Esses mecanismos psicológicos (reflexo do tronco cerebral, pareamento rítmico e contágio emocional) foram escolhidos porque estão relacionados aos elementos estruturais da música (Juslin, 2013b) e, por conseguinte, são teoricamente compatíveis com a Nova Estética Experimental, em especial as variáveis psicofisiológicas e colativas.

Vale destacar que, embora as análises da preferência sejam oriundas de simulações computacionais, os dados referentes às escolhas musicais dos usuários não o são. Assim, o *Goliath Toolbox* permite acessar informações obtidas a partir de atividades de escuta de usuários reais que utilizem os serviços de *streaming*. Em sua maioria, esses serviços distribuem música popular, cujas características principais são a organização em torno de uma indústria, a circulação em massa e o registro tecnológico (Tagg, 2003). De certa forma, ainda que isso represente alguma dificuldade em termos de controle experimental (já que na presente pesquisa não foi possível controlar as condições em que os ouvintes escolheram as músicas), há certas vantagens do uso dessa ferramenta no que diz respeito à origem da informação, que foi coletada em um ambiente real. Dessa forma, esta é uma das poucas maneiras para acessar os hábitos de escuta de muitos ouvintes de um país ou mesmo do mundo todo. Para minimizar as dificuldades no controle experimental desse estudo, posteriormente, no Estudo III,

---

<sup>67</sup> Agendamento de tarefas a serem realizadas pelo computador.

será realizado um estudo com a participação de agentes humanos, colocando sob testagem a simulação elaborada na presente etapa.

### 2.2.2 Metodologia

*Equipamentos:* um computador Dell OptiPlex 7050, processador Intel Core i5-7500, 3.40GHz, 8GB RAM, Windows 10; softwares IDE Python 3, Matlab R2017b, Goliath Toolbox, Microsoft Excel 2016 e Orange Data Mining 3.26.

*Dataset:* a função *glochart()* foi utilizada para realizar requisições de 10.230 músicas referentes às primeiras posições do *ranking* mundial de preferência musical dos usuários da rede *Last.Fm*. Foram excluídas da amostra as faixas que não possuíam identificadores *mbid*. Isso reduziu o conjunto de dados para 5.099 músicas. A segunda fase deste estudo consistiu em recuperar informações de descritores *low level* e *high level* obtidos através plataforma *AcousticBrainz*, o que reduziu a amostragem para 2.827 músicas, considerando apenas aquelas que possuíam informações disponíveis integralmente na plataforma. Para tanto, foram utilizados os identificadores *mbid* das faixas incluídas no conjunto de dados, empregando o protocolo HTTP/REST com método *GET* durante a requisição junto à API. Como na fase anterior, foram utilizadas as funções *hiM()* e *loM()* do *web crawler Goliath Toolbox*, retornando resultados em formato JSON transformados em tabelas no formato *.m* e *.xlsx*, compatíveis com os *softwares* Matlab R2017b, Microsoft Excel 2016, Orange Data Mining 3.26 (Demšar et al., 2013).

*Procedimentos:* as principais etapas operacionais relacionadas à mineração de dados compreendem o gerenciamento dos dados (*data management*), o pré-processamento (*data preprocessing*) e, por fim, a mineração de dados propriamente dita, em que são aplicadas técnicas de aprendizado de máquina para a extração de informações válidas visando a análise estatística e a apresentação gráfica para a compreensão do usuário (Li, Ogihara & Tzanetakis, 2011). Conforme descrito, o gerenciamento inicial dos dados nesta pesquisa foi realizado com suporte do *Goliath Toolbox* e do Microsoft Excel 2016. Posteriormente, as etapas de pré-processamento (transformação das variáveis, exclusão de casos atípicos, seleção de subconjuntos para treinamento, testagem e validação computacional, etc.) e mineração (aplicação dos algoritmos, análises estatísticas e visualização dos resultados) foram realizadas em *Python 3.6.6* e *Orange Data Mining 3.26* (Demšar et al., 2013).

Para que se possa compreender melhor a maneira pela qual os dados desse estudo foram analisados, torna-se necessário a definição de alguns conceitos oriundos da psicologia experimental, pertinentes à essa análise, especialmente conceitos relacionados aos tipos de variáveis experimentais que foram consideradas, bem como os “casos atípicos”. Nesse sentido, variáveis discretas são aquelas que podem assumir apenas valores inteiros no âmbito de determinado intervalo (mesmo que este intervalo seja desconhecido, como no caso da altura de uma pessoa). Variáveis contínuas, por sua vez, são aquelas que podem variar infinitamente no contexto de um intervalo conhecido, como 0-1. As variáveis categóricas, finalmente, são aquelas que definem uma categoria, como “sim” e “não” ou “alto” e “baixo”, para qual o pesquisador pode computar o número de ocorrências em cada grupo (Dancey & Reidy, 2013; Levin, Fox & Forde, 2012; Callegari-Jacques, 2003). No caso em questão, as variáveis discretas (“*listeners*”, “*danceability*” e “*bpm*”) foram transformadas de acordo com o intervalo 0-1, ou seja, foram transformadas em variáveis contínuas considerando os valores máximos e mínimos dos registros de ouvintes, execuções das faixas e andamento constantes no conjunto de dados original, seguindo os padrões de apresentação das demais variáveis contínuas. Esta medida faz parte do pré-processamento e é necessária para estabelecer uma forma de padronização entre as variáveis.

Valores atípicos ou *outliers*, por sua vez, são “[...] aqueles escores na [...] amostra que estão a uma distância considerável mais alta ou mais baixa do que a maioria dos outros escores da [...] amostra” (Dancey & Reidy, 2013, p. 83). Nesse estudo foram excluídos 613 casos atípicos, restando, portanto, um conjunto de dados formado por 2214 músicas. Este conjunto de dados, por sua vez, foi dividido em três subconjuntos para treinamento, testagem e validação computacional dos algoritmos, na proporção aproximada de 3:2:1. O subconjunto de treinamento foi constituído por 1462 músicas, enquanto os subconjuntos de testagem e validação computacional foram constituídos por 497 e 255 músicas, respectivamente. A divisão foi realizada aleatoriamente, procurando manter as características originais da amostra.

*Análise dos dados:* os dados foram primeiramente tabulados. Em seguida, a primeira etapa da simulação consistiu na análise descritiva do conjunto de dados de treinamento, considerando-se um total de 1462 músicas. Para cada variável, foram identificados os valores mínimos, máximos, de dispersão e mediana. Estes valores indicam, respectivamente, o menor valor obtido, o maior valor obtido, o valor médio da diferença entre as observações e a média e o valor central das observações. Foi

aplicada uma análise dos parâmetros da distribuição da amostra da preferência musical. A compatibilidade com o padrão de distribuição gaussiana foi verificada com o auxílio do teste Kolmogorov-Smirnov ( $D$ ), considerando-a quando  $p > 0.05$ <sup>68</sup>.

A segunda fase do estudo consistiu na elaboração da simulação propriamente dita. Para tanto, foi implementado um algoritmo baseado em redes neurais artificiais (RNA), utilizando a interface gráfica do software *Orange Data Mining 3.26* (Demšar et al., 2013).

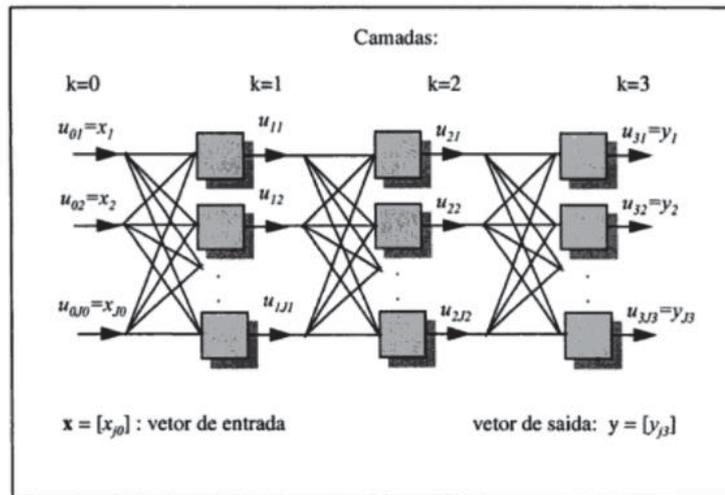
Redes neurais artificiais (RNA) representam certas vantagens para a otimização do problema em questão, na medida que permitem o ajuste dos pesos (*weights*) de cada variável de entrada (*input*) incluída na simulação. Por definição, uma RNA:

[...] consiste em um conjunto de unidades de processamento, os chamados nós que simulam neurônios, que estão ligados de forma análoga às conexões sinápticas no sistema nervoso. Os nós representam componentes de cálculo muito simples baseados na observação de que um neurônio se comporta como um interruptor: se neurotransmissores suficientes foram acumulados no corpo celular, um potencial de ação é gerado. Esse potencial é modelado matematicamente como uma soma ponderada de todos os sinais que chegam ao nó e é comparado a um determinado limite. Somente se esse limite for excedido, o nó “dispara”. Estruturalmente, uma RNA é obviamente comparável a uma rede neural natural (biológica) como, por exemplo, o cérebro humano (Weihs & Glasmachers, 2017, p. 321).

A Figura 8 ilustra uma rede neural artificial multicamadas (*perceptron*) em que podem ser observados diferentes nós de processamento, representados pelos quadrados. Cada camada é representada pela letra  $k$ .

---

<sup>68</sup>Testes de aderência utilizados para verificar a relação entre uma amostra e uma determinada distribuição são elaborados com base na verificação de hipóteses. O enunciado da hipótese-nula ( $H_0$ ) estabelece que a amostragem compartilha características com a distribuição analisada. A hipótese alternativa ( $H_1$ ), por sua vez, estabelece que a amostragem *não* compartilha características com a distribuição analisada. Desta forma, supondo que o pesquisador deseje testar a relação entre a amostra e a distribuição normal (ou gaussiana), espera-se que o valor de  $p$  seja inferior a 0.05 para a rejeição de  $H_0$ . Do contrário (quando  $p > 0.05$ ), então deve-se aceitar  $H_0$  e a distribuição em questão.



**Figura 8.** Rede artificial multicamada (*perceptron*).  
 Fonte: Kovács (2006).

Segundo Kovács (2006, p. 39),

Os neurônios que recebem diretamente as *entradas* da rede constituem o que se chama de *camada de entrada*. Os neurônios que recebem como entradas as saídas daqueles da camada de entrada constituem a segunda camada e assim sucessivamente até a camada final que é a *camada de saída*. As camadas internas que não são nem a de entrada e nem a de saída são geralmente referidas como *camadas ocultas*.

Desta forma, em uma RNA, espera-se que os pesos sejam ajustados até o valor ideal esperado para cada componente da simulação (neste caso, as variáveis preditoras incluídas na análise), minimizando os erros de entrada e otimizando os resultados das saídas (*outputs*).

A utilização de RNA é útil em problemas de aprendizado supervisionado, isto é, quando os resultados são conhecidos e os pesquisadores desejam treinar o algoritmo para a resolução destes problemas. No caso em questão, os resultados da preferência são conhecidos, restando ajustar o “peso” interno do algoritmo.

Para realização da simulação, portanto, foram selecionadas 16 variáveis preditoras derivadas da Nova Estética Experimental (Berlyne, 1973; 1971) e da Teoria Unificada das Emoções Musicais (Juslin, Harmat & Eerola, 2014; Juslin, 2013a; Juslin & Västfjäll, 2008). A Tabela 8 apresenta as variáveis preditoras selecionadas distribuídas em função das teorias em questão:

**Tabela 8**

Variáveis independentes selecionadas para a composição da simulação de RNA

Teoria	Componente	Variável
Nova Estética Experimental (Berlyne, 1973; 1971)	Familiaridade/Novidade Simplicidade/Complexidade	Popularidade Dissonância, tonal/atonal, saliência do <i>pitch</i> , taxa de mudança de acordes
Teoria Unificada das Emoções Musicais (Juslin, Harmat & Eerola, 2014; Juslin, 2013a; Juslin, 2013b; Juslin & Västfjäl, 2008)	Clareza/Obscuridade Reflexo do tronco cerebral Pareamento rítmico Contágio emocional	Timbre claro/escuro Intensidade, andamento, timbre claro/escuro, dissonância <i>Danceability</i> Vocal/instrumental, voz masculina/feminina, <i>mood</i> agressivo, <i>mood</i> alegre, <i>mood</i> tranquilo e <i>mood</i> triste

Nota: A variável *popularidade* foi mensurada a partir do número de usuários que ouviram pelo menos uma vez a faixa. A variável *andamento*, por sua vez, foi mensurada em batidas por minuto (bpm). Ambas são mensuradas como variáveis discretas e foram transformadas em variáveis contínuas considerando a frequência do intervalo entre os maiores e menores valores obtidos.

Fonte: Autor (2021).

Para avaliação da RNA, foram considerados o coeficiente múltiplo de determinação ( $R^2$ ) e suas medidas de erro – *mean squared error* (MSE), *root mean square error* (RMSE) e *mean absolute error* (MAE). O coeficiente  $R^2$  indica a precisão da simulação, ou seja, a porcentagem da variável dependente que pode ser explicada pela variação das variáveis independentes. Quanto mais próximo de 1 ou -1, mais precisa é a simulação (indicando uma relação direta quando positivo ou inversa quando negativo). Já as medidas de erro indicam a acurácia da simulação, isto é, o quanto se aproxima dos valores esperados.

A testagem da simulação computacional será descrita no Estudo III. Ela consiste em uma abordagem experimental com a participação agentes humanos, no intuito de identificar ocorrências que corroborem ou refutem as estimativas previstas no estudo ora apresentado.

### 2.2.3 Resultados

A Tabela 9 apresenta a estatística descritiva da amostra ( $n=2214$ ), incluindo a mediana, os valores máximos (max) e mínimos (min) e a dispersão (coeficiente de variação) para cada variável, sendo útil para fornecer um panorama contendo o menor valor obtido, o maior valor obtido, o tamanho da dispersão (variação) e o ponto central das observações das variáveis analisadas. Estes valores foram obtidos pelo processo de mineração de dados junto à Last.Fm API (dados sobre a popularidade) e AcousticBrainz (demais dados). Alguns dados foram obtidos como variáveis discretas e transformados em variáveis contínuas, a exemplo do número de ouvintes.

**Tabela 9**Descrição das variáveis empregadas na simulação ( $n=2214$ ).

	<b>Min</b>	<b>Mediana</b>	<b>Max</b>	<b>Dispersão</b>
Andamento	0,36	0,66	1,00	0,19
<i>Danceability</i>	0,00	0,48	0,95	0,44
Dissonância	0,29	0,45	0,49	0,04
Intensidade	0,00	0,81	0,98	0,22
<i>Mood</i> Agressivo	0,00	0,21	0,99	1,43
<i>Mood</i> Alegre	0,00	0,38	0,99	0,70
<i>Mood</i> Tranquilo	0,00	0,56	0,99	0,58
<i>Mood</i> Triste	0,00	0,30	0,95	0,67
Pitch	0,18	0,52	0,66	0,09
Popularidade	0,00	0,15	0,58	1,02
Mudança de acordes	0,00	0,06	0,17	0,36
Timbre brilhante	0,00	0,44	0,99	0,87
Tonalidade	0,00	0,38	0,99	0,96
Voz	0,00	0,50	0,99	0,78
Voz Masculina	0,00	0,47	0,99	0,64
<b>Preferência (*)</b>	<b>0,00</b>	<b>0,13</b>	<b>0,56</b>	<b>1,05</b>

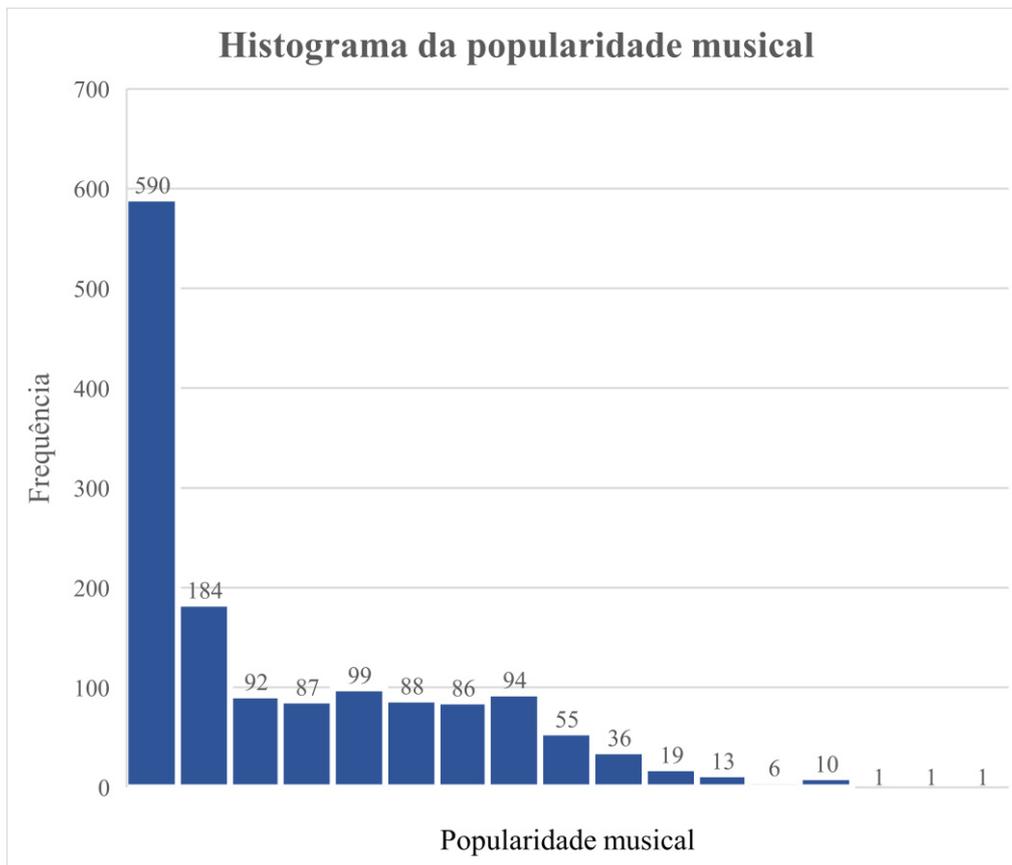
(\*) Preferência representa a variável dependente (*target*) empregada para treinamento do algoritmo RNA.

Fonte: Autor (2021).

De acordo com a Tabela 9, observa-se que as variáveis *Danceability*, Intensidade, *Mood* Agressivo, *Mood* Alegre, *Mood* Tranquilo, *Mood* Triste, Popularidade, Mudança de acordes, Timbre brilhante, Tonalidade, Voz, Voz masculina e Preferência indicam valores mínimos igual a 0,00, indicando presença de valores baixos na amostra. Já a variável Andamento apresenta valor máximo 1,00, indicando presença de andamento rápido na amostra.

O teste Kolmogorov-Smirnov foi aplicado para verificar a distribuição gaussiana<sup>69</sup> e refutou a compatibilidade entre o subconjunto de treinamento e tal distribuição ( $D = 0.99$ ,  $p < 0.000$ ) para a popularidade (número de usuários que ouviram pelo menos uma vez a faixa). Por outro lado, observa-se no histograma constante na Figura 9 uma distribuição semelhante à de Pareto. Segundo Souza e seus colaboradores (2012), Vilfredo Pareto, economista francês que viveu entre 1848 e 1923, constatou que apenas um número reduzido de pessoas detinha grande parte da riqueza existente. Para os autores, a distribuição de Pareto é uma distribuição de probabilidade de lei de potência, utilizada para a modelagem de dados sociais, geofísicos, atuariais e muitos tipos de fenômenos observáveis.

<sup>69</sup> A distribuição gaussiana, também chamada distribuição normal, indica que a probabilidade de um evento ocorrer é frequentemente maior na porção mediana da amostra, diminuindo perto dos extremos.



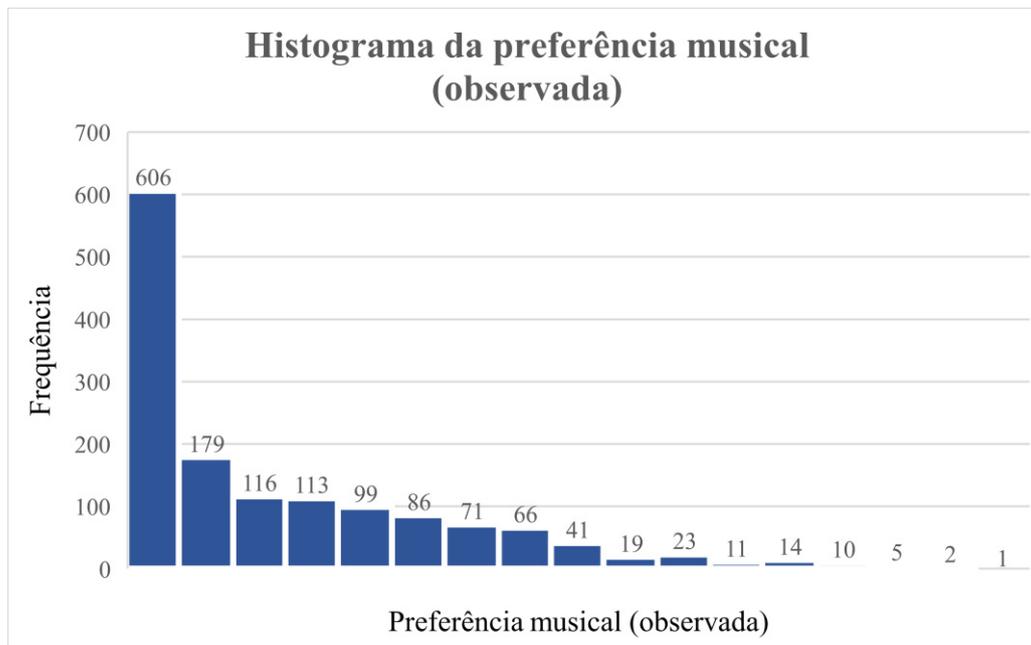
**Figura 9.** Histograma da popularidade ( $n=1462$ ) observada na amostra obtida da rede social *Last.Fm*.

Nota: A distribuição encontra-se na família exponencial, com estimativa de  $\alpha=1.7874$  para a distribuição de Pareto. A frequência indica a quantidade de faixas que apresentaram a mesma contagem de popularidade.

Fonte: Autor (2021).

A Figura 9 apresenta o histograma da popularidade, em que cada coluna demonstra o agrupamento das faixas de acordo com a quantidade de ouvintes. Observa-se um grande número de faixas (590) na porção inferior do eixo  $x$  que registra a quantidade de ouvintes e um pequeno número de faixas (1) na porção superior do mesmo eixo. Aplicando o princípio de Pareto, observa-se uma distribuição com um parâmetro  $\alpha=1.7874$ . Este parâmetro é denominado “parâmetro de forma” e modela a “curvatura” da distribuição (a “forma”).

De maneira parecida, o histograma constante na Figura 10 apresenta a distribuição de Pareto para a preferência musical (observada) dos usuários da rede social *Last.Fm*, com estimativa de  $\alpha=1.60177$ . Estes dados são importantes para a compreensão da relação entre a preferência musical observada na amostra e a popularidade das faixas musicais.



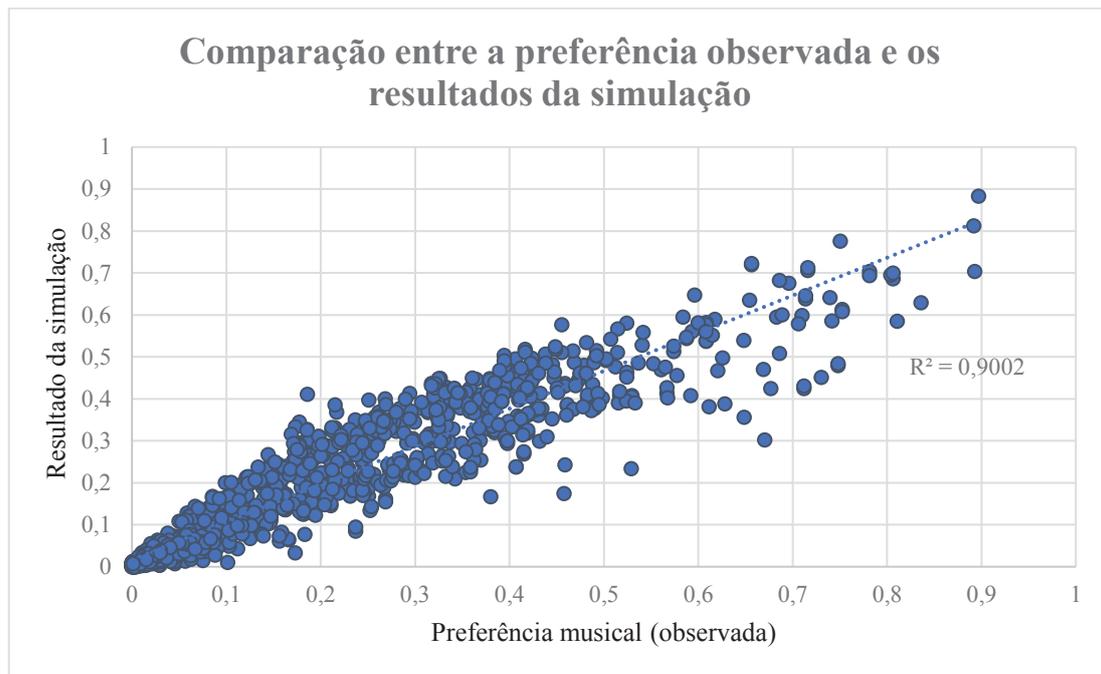
**Figura 10.** Histograma da preferência musical ( $n=1462$ ) observada na amostra obtida da rede social Last.Fm.

Nota: A distribuição encontra-se na família exponencial, com estimativa de  $\alpha=1.60177$  para a distribuição de Pareto. A frequência indica a quantidade de faixas que apresentaram a mesma contagem de preferência musical (observada).

Fonte: Autor (2021).

Na Figura 10, observa-se o histograma da preferência, com muitas faixas situadas na porção inferior do eixo  $x$  onde está situada a contagem do número de vezes que a faixa foi ouvida pelos usuários (606) e poucas faixas na porção superior do mesmo eixo (1). De acordo com o princípio de Pareto, poucos artistas detêm muita preferência e muitos artistas detêm pouca preferência.

A Figura 11 apresenta o resultado da predição da preferência musical utilizando o algoritmo de redes neurais artificiais (RNA). Os pontos marcados no gráfico correspondem às faixas musicais, de modo que estão dispostas em função da preferência musical observada entre os usuários. Desta forma, é possível verificar a correspondência entre os dados esperados (preferência musical observada) e os dados preditos pelo algoritmo.



**Figura 11.** Resultados obtidos durante a etapa de predição da preferência musical ( $n=1462$ ,  $R^2=0,9002$ ). Nota: Cada ponto no gráfico representa uma faixa, em que são comparados os resultados da simulação empregando o algoritmo de redes neurais artificiais (eixo  $y$ ) e a preferência observada (eixo  $x$ ). Fonte: Autor (2021).

O coeficiente múltiplo de determinação indicou forte relação positiva ( $R^2=0.900$ ), indicando que as variáveis selecionadas para a presente simulação são capazes de prever com precisão a preferência musical em simulações computacionais utilizando redes neurais artificiais. O gráfico indica correspondência entre os valores observados para a preferência musical (resultados esperados) e a predição, representado pela inclinação da reta.

A seguir, são apresentados os resultados da avaliação da implementação da simulação. A Tabela 10 apresenta os resultados obtidos durante a avaliação da RNA utilizada (*multi-layer perceptron*). Como parâmetros da RNA, foram adotados 2000 neurônios em camadas escondidas (*hidden layers*) e 5000 iterações ( $i=5000$ ), padrão de ativação logística e um algoritmo L-BFGS-B. Isto significa que foram adotadas 2000 camadas de processamento da informação e o cálculo foi repetido 5000 vezes. A ativação logística é necessária para entradas de dados com intervalos contínuos (0 a 1). Além disso, o algoritmo L-BFGS-B é útil para otimizar as tarefas em cálculos desta natureza. A simulação foi extraída para o formato .pckls e pode ser incorporada futuramente a outras aplicações em Python 3.x:

**Tabela 10**

Resultado da avaliação da implementação da simulação computacional da preferência musical ( $i=5000$ ).

<b>Treinamento (<math>n = 1462</math>)</b>			
<b>MSE</b>	<b>RMSE</b>	<b>MAE</b>	<b><math>R^2</math></b>
0.003	0.058	0.036	0.900*
<b>Testagem (<math>n = 497</math>)</b>			
<b>MSE</b>	<b>RMSE</b>	<b>MAE</b>	<b><math>R^2</math></b>
0.004	0.060	0.037	0.902*
<b>Validação (<math>n = 255</math>)</b>			
<b>MSE</b>	<b>RMSE</b>	<b>MAE</b>	<b><math>R^2</math></b>
0.003	0.054	0.036	0.917*

Nota 1: MSE – *mean squared error*; RMSE – *root mean square error*; MAE – *mean absolute error*;  $R^2$  – coeficiente múltiplo de determinação.

Nota 2: Os erros (MSE, RMSE e MAE) indicam a acurácia da simulação, isto é, o quanto se aproxima dos valores esperados. Quanto menores os erros, mais acurada é a simulação. O coeficiente múltiplo de determinação ( $R^2$ ) indica a precisão da simulação, ou seja, a porcentagem da variável dependente que pode ser explicada pela variação das variáveis independentes. Quanto mais próximo de 1 ou -1, mais precisa é a simulação (indicando uma relação direta quando positivo ou inversa quando negativo).

Fonte: Autor (2021).

Em geral, observa-se que durante a etapa de validação computacional da simulação ocorreu a diminuição dos erros em relação ao resultado previsto e o aumento do coeficiente múltiplo de determinação levando em conta as variáveis independentes derivadas da Nova Estética Experimental e da Teoria Unificada das Emoções Musicais, indicando, respectivamente, ligeiro aumento da acurácia e da precisão das respostas, ambas consideradas satisfatórias em relação à preferência musical observada. Os dados sugerem, portanto, que as variáveis derivadas da Nova Estética Experimental (Berlyne, 1973; 1971) e da Teoria Unificada das Emoções Musicais (Juslin, Harmat & Eerola, 2014; Juslin, 2013a; Juslin, 2013b; Juslin & Västfjäll, 2008) podem ser empregadas, neste contexto, para explicar a escolha dos usuários da rede social *Last.Fm*.

Finalmente, a Tabela 11 apresenta alguns exemplos de faixas e seus respectivos artistas cujas preferências foram simuladas no decorrer deste estudo. Destaca-se que as respostas se encontram na forma de variável contínua, ou seja, no intervalo de 0 a 1. A coluna Posição representa o ranking dentre a amostra de faixas selecionadas no exemplo, considerando os valores observados no contexto real (Preferência). Entre parênteses, encontra-se a nova alteração após aplicação da simulação, considerando os valores preditos (Predição):

Estes resultados fornecem informações suficientes para produzir novas simulações de rankings de preferência ou popularidade musicais pelos pesquisadores em cognição musical e *music*

*information retrieval*. Como pode ser observado, os resultados preditos permitem organizar as faixas, com alguma precisão ( $R^2=0.907$ ), em função de sua estimativa de preferência. De acordo com os resultados da simulação descritos na Tabela 11, houve alteração apenas nos dois últimos casos, ocupando “*Purple Rain*” e “*Female Robbery*” a nona e a décima posições, respectivamente, no *ranking* de preferência observada, e a 10<sup>a</sup> e a 9<sup>a</sup> posições, respectivamente, no *ranking* de predições.

**Tabela 11**  
Exemplos de faixas incluídas na simulação<sup>70</sup>.

Posição	Faixa	Artista	Preferência	Predição
1(1)	<i>Let It Go</i>	<i>The Neighbourhood</i>	0,514	0,510
2(2)	<i>Inhaler</i>	<i>Foals</i>	0,319	0,412
3(3)	<i>The Bad Touch</i>	<i>Bloodhound Gang</i>	0,244	0,248
4(4)	<i>Last Dance</i>	<i>The Cure</i>	0,134	0,200
5(5)	<i>So Easy</i>	<i>Röyksopp</i>	0,129	0,109
6(6)	<i>Englishman in New York</i>	<i>Sting</i>	0,089	0,102
7(7)	<i>Here Comes the Rain Again</i>	<i>Eurythmics</i>	0,086	0,095
8(8)	<i>Space Oddity</i>	<i>David Bowie</i>	0,071	0,070
9(10)*	<i>Purple Rain</i>	<i>Prince</i>	0,006	0,009
10(9)*	<i>Female Robbery</i>	<i>The Neighbourhood</i>	0,005	0,014

Fonte: Autor (2021).

Em suma, os resultados indicam que a uma grande concentração de faixas com preferência e popularidade próximas de marcações mínimas, alinhando-se ao princípio de Pareto. Além disso, este estudo demonstrou que a utilização das variáveis derivadas da Nova Estética Experimental e da Teoria Unificada das Emoções Musicais podem ser úteis para a simulação computacional da preferência musical na amostra empregada.

Para facilitar a compreensão destes resultados, eles serão discutidos em maiores detalhes na próxima seção.

#### 2.2.4 Discussão

O objetivo deste estudo foi entender o papel da Nova Estética Experimental e da Teoria Unificada das Emoções Musicais para a preferência musical de usuários da rede social *Last.Fm*. Os dados foram obtidos por meio de uma técnica de mineração de dados na *Last.Fm API* e na *AcousticBrainz* e, posteriormente, inseridos em uma simulação computacional utilizando um algoritmo de redes neurais artificiais (RNA). Como pode ser observado, a preferência musical dos usuários desta rede parece ser influenciada pelas variáveis descritas no contexto da Nova Estética Experimental (Berlyne, 1973; 1971) e da Teoria Unificada das Emoções Musicais (Juslin, Harmat & Eerola, 2014; Juslin, 2013a; Juslin, 2013b; Juslin & Västfjäll, 2008), uma vez que a RNA foi capaz de simular a preferência musical com precisão e acurácia. Tais variáveis envolvem características sonoras de baixo e alto níveis

<sup>70</sup> As faixas do exemplo podem ser acessadas na *playlist* disponível em <https://open.spotify.com/playlist/5JNv1MHu2e3TpXMArfqjGs?si=8lSdqPY9RC-QVqkqOJ7w>.

(andamento, saliência do *pitch*, intensidade, dissonância, timbre brilhante, tonalidade/atonalidade, voz/instrumental, voz masculina/voz feminina, taxa de mudança de acordes, *danceability* e *mood*), bem como características da recepção da obra (popularidade).

Por outro lado, a forma como as variáveis da Nova Estética Experimental e da Teoria Unificada das Emoções Musicais interagem entre si parece não estar totalmente esclarecida pela literatura. Por exemplo: ambas adotam, em algum grau, a noção de *arousal* e reconhecem o papel da familiaridade para a formação da preferência musical (Liljstöm, Juslin & Västfjäll, 2012; Berlyne, 1973). Entretanto, a relação entre os mecanismos subjacentes que compõem a teoria de Juslin e a preferência em música pela abordagem berlyniana parece ter sido pouco explorada em estudos empíricos no campo da cognição musical. A utilização do tipo de simulação computacional empregada neste estudo pode oferecer uma alternativa para a solução de problemas relacionados a esta lacuna.

Em um recente artigo de opinião, Holm (2019) defendeu a utilização de algoritmos de *machine learning* para a resolução de problemas complexos em casos em que os pesquisadores tenham dificuldades de compreender todas as perspectivas de funcionamento das variáveis, incluindo ciências, engenharia e saúde. Para a autora, em determinados contextos, algoritmos do tipo *black box* são úteis quando os pesquisadores não possuem condições suficientes para esclarecer o funcionamento de sistemas complexos, quando o funcionamento do todo não pode ser resumido às partes. Esta afirmação corrobora a visão de Menezes-Filho (2003), para quem o uso de computadores é frequentemente necessário para a compreensão desses sistemas. Além disso, estes algoritmos constituem iniciativas em direção ao esclarecimento destes mesmos problemas de pesquisa, evidenciando certas questões e novas possibilidades metodológicas para sua investigação.

Yang e Chen (2012) revisaram estudos sobre o reconhecimento automatizado de emoções desencadeadas pela música, empregando algoritmos de *machine learning*. A área tem sido denominada *music emotion recognition* (MER) e tem recebido particular atenção nos últimos anos, em especial com o recente desenvolvimento de novos aplicativos e interfaces para uso comercial. Os autores destacam duas abordagens distintas para a questão dos estudos nessa área. De um lado, uma abordagem categórica, na qual a Teoria Unificada das Emoções Musicais pode ser incluída; de outro lado, uma abordagem dimensional, na qual as emoções assumem a disposição de um plano ortogonal (Russell, 1980).

Presumivelmente, a escolha dos usuários deve levar em conta, em algum grau, as variáveis analisadas neste trabalho além de outras variáveis que não puderam ser analisadas, como os níveis de segurança do estímulo previstos na Nova Estética Experimental (Berlyne, 1971). Em um cenário decisivo, pode-se supor que a escolha dos agentes, portanto, ocorra sob a influência do julgamento do contexto geral da tomada de decisão (avaliação da obra, da situação em que as escolhas ocorrem e da decisão dos outros agentes), de forma semelhante ao que preceitua o modelo do *feedback* recíproco,

em que estão atuando as características da obra, do indivíduo e do contexto, influenciando-se mutuamente (Hargreaves, North & Tarrant, 2016).

Segundo Lerner e colaboradores (2015) e Sanfey (2007), pesquisas neste domínio do conhecimento devem enfatizar, também, a avaliação dos aspectos emocionais do indivíduo no momento da escolha, bem como a predição da ação dos outros usuários, importante para o convívio e fortalecimento de seus vínculos sociais em situações de decisão. Isso poderia influenciar, em última instância, a formação da popularidade das faixas musicais entre os usuários da rede. Neste aspecto, tanto a familiaridade quanto os componentes emocionais veiculados pela obra, como aqueles relacionados ao mecanismo psicológico de pareamento rítmico, poderiam estar atuando no sujeito (Abe, 2019).

Quando usuários escolhem suas músicas de preferência, o fazem sob certas condições – em determinados contextos específicos e sob influência de determinadas emoções/processos cognitivos – ainda que não totalmente conscientes, conforme pontuam Lerner e colaboradores (2015). Embora os algoritmos de recomendação por filtragem colaborativa pareçam exercer notável influência sobre as decisões dos usuários, salienta-se que a exposição à música e à formação do gosto não ocorre apenas no contexto das redes sociais digitais (Bezerra, Guerra & Silva, 2017; Schäfer, 2008; Hargreaves, North & Tarrant, 2016). Os usuários são expostos a uma ampla variedade de manifestações culturais no cotidiano, seja por intermédio da mídia, seja pelas trocas culturais com seus pares. Por conseguinte, mesmo que sejam plausíveis as evidências de contágio emocional massivo por meio do uso de algoritmos, parece necessário considerar também as evidências de que as métricas de popularidade das obras e preferência musical dos usuários em redes sociais representem um paradigma particularmente interessante para o desenvolvimento de estudos em cognição musical (Nave et al., 2018; Kramer et al., 2014). De certa forma, os indivíduos têm acesso à música pela mídia. Porém, é possível que a mídia também reproduza aquilo que os indivíduos pareçam consumir com maior frequência fora do ambiente virtual.

Morgan, McDonald e Pitts (2014) investigaram as experiências musicais entre mães e seus filhos adolescentes. Segundo os autores, embora os adolescentes sejam vistos como autônomos em suas escolhas, estão mais sujeitos à influência das tendências de sua época. Além disso, parece haver um processo de construção social da identidade mediada pela negociação musical: filhas estavam mais propensas a receber as recomendações de suas mães, ao passo que os filhos pareceram estar menos dispostos a compartilhar dos gostos maternos. Ao realizar a escolha, portanto, é possível que as decisões dos agentes estejam afetando mutuamente o comportamento geral do sistema, influenciando não apenas seus próprios estados cognitivos/emocionais (Hargreaves, North & Tarrant, 2016; Konečni, 2010), bem como a popularidade das faixas de sua preferência e, indiretamente, as escolhas de outros usuários, que receberão novas recomendações a partir do incremento da popularidade. Estas transformações parecem ocasionar estados de popularidade e preferência musical irreversíveis, na

medida em que os indicadores de uma faixa não podem ser revertidos a seus estados de preferência ou popularidade anteriores. Em outras palavras, uma vez que um usuário conhece uma faixa, ele não poderá mais ignorar sua existência, já que a faixa, neste contexto, apenas poderá ser menos conhecida do que sua concorrente. Quanto à preferência, uma vez que a escolha tenha sido efetuada, esta escolha poderá ser revisada apenas em um novo cenário de decisão, tendo a escolha anterior ficado no passado.

Esta descrição parece ser uma característica peculiar de sistemas dinâmicos, corroborando a perspectiva de Oliveira (2014, p. 24):

Sistemas dinâmicos são aqueles que apresentam mudanças em seus estados internos, em termos de organização e/ou estrutura, e essas mudanças obedecem a padrões de transformações que conseguem se manter coerentes em estados do sistema que estão distantes do equilíbrio. Uma ampla gama de fenômenos pode ser descrita através da teoria dos sistemas dinâmicos, desde o comportamento de moléculas inorgânicas até o tintilar de dedos ao se ouvir um ritmo contagiante, passando pelo próprio fenômeno da vida e chegando às organizações sociais. Segundo Kelso (1995), todo sistema dinâmico possui parâmetros de ordem e parâmetros de controle. Resumidamente, um parâmetro de ordem é uma configuração que surge em um sistema dinâmico e que, uma vez instituído, passa a dirigir o comportamento do sistema, é uma propriedade emergente da interação dos elementos de um sistema. Um parâmetro de controle é uma condição na qual, ou um estado no qual, uma variável coletiva emerge, sendo que ela não é dependente de outra condição ou estado e pode ser causado por agentes externos ao sistema. Os comportamentos e propriedades de um sistema dinâmico podem mudar em função de situações particulares (parâmetros de controle) que acarretem configurações ou comportamentos emergentes (parâmetros de ordem) que passam a dirigir ou restringir o próprio sistema, em suas configurações e/ou comportamentos.

Neste sentido, o cenário decisório em que as escolhas dos usuários são realizadas atua como um parâmetro de controle – empregando aqui a definição apresentada por Oliveira (2014) – gerando impulsionamento para um novo *status* no qual popularidade e preferência das obras pelos usuários podem ser momentaneamente computadas (parâmetro de ordem).

No presente estudo, o uso de mineração de dados musicais e redes neurais artificiais para simulação da preferência musical por meio de dados de escuta de usuários da rede social *Last.Fm* revelou semelhanças com os aspectos destacados por Anderson (2017) a respeito dos mercados de nicho, em que pese o maior acúmulo de produtos (faixas) na porção inferior do histograma da preferência (Figura 10). Isto revela a possibilidade de que a sustentação econômica destes mercados esteja na base de sua oferta diversificada, uma vez a maior parte das audições se concentra na região das faixas pouco conhecidas.

Além disso, a simulação mostrou que talvez seja possível encontrar resultados semelhantes à preferência musical dos usuários da rede empregando variáveis obtidas junto à Nova Estética Experimental e à Teoria Unificada das Emoções Musicais. Juntas, estas teorias cobrem variáveis relacionadas à obra e à recepção da música pelos sujeitos, com dados sobre a popularidade.

No estudo seguinte, são apresentados os resultados de um estudo realizado com a participação de agentes humanos em que se buscou verificar a precisão da simulação desenvolvida na presente etapa.

## **2.3 Estudo III: Testagem da simulação da preferência musical entre ouvintes brasileiros**

### *2.3.1 Introdução*

A utilização de inteligência artificial (IA) nas ciências cognitivas constitui um campo vasto de pesquisas na atualidade, com diferentes propósitos, como a análise de expressões faciais e o desenvolvimento da computação afetiva. Nas ciências cognitivas, a simulação computacional envolve a programação de computadores para simular aspectos do funcionamento cognitivo humano, com base na contribuição de áreas como a matemática e a estatística. Simulações computacionais eficientes revelam como uma teoria opera e como é possível prever comportamentos em novas situações – por exemplo, o risco de novos acidentes de carro a partir de preditores baseados nas infrações de tráfego (Eysenck & Keane, 2010).

Alguns autores consideram diferenças significativas entre o campo da simulação computacional e o da inteligência artificial. Para autores como Eysenck e Keane (2010), a inteligência artificial considera certo grau de autonomia em relação às demais áreas para o desempenho das tarefas, diferentemente da simulação computacional. Entretanto, não raramente a simulação computacional emprega recursos de aprendizagem de máquina e mineração de dados (Farrell & Lewandowsky, 2018), ambos derivados originalmente dos estudos em inteligência artificial (Russell & Norvig, 2013), tornando tais fronteiras permeáveis.

Sistemas cognitivos complexos (Jordan, Srinivasan & van Leeuwen, 2015; Oliveira, 2014; Carvalho, Varenne & Braga, 2014; Lamb et al., 2007) envolvem, dentre outras coisas, comportamento dinâmico e a emergência de propriedades funcionais a partir da operação de seus componentes fundamentais. Desta forma, a simulação computacional, aliada à inteligência artificial, parece oferecer uma contribuição significativa para a compreensão dos processos cognitivos que se busca investigar (Nicoletis, 2011; Menezes-Filho, 2003; Lamb et al., 2007).

Russel e Norvig (2013) recomendam, quando possível, a realização de estudos com a participação de agentes humanos, com o intuito de se corroborar ou se refutar as hipóteses sob análise. Neste sentido, o presente estudo tem por objetivo investigar a eficiência da simulação desenvolvida na etapa precedente, por meio da predição da preferência musical de usuários brasileiros da rede *Last.Fm*. Como esta rede se restringe a fornecer dados de popularidade das faixas musicais para um determinado país (número de ouvintes), parte-se dos questionamentos: é possível utilizar a simulação elaborada no estudo anterior para prever a preferência de ouvintes brasileiros (número de vezes que uma faixa é escolhida)? Qual é o comportamento geral deste grupo de ouvintes? Para tanto, neste

estudo, será conduzido um experimento de adequação da preferência musical predita pela rede neural artificial desenvolvida no Estudo II, submetida à opinião de indivíduos brasileiros. As hipóteses a serem testadas neste estudo é a de que a simulação pode ser devidamente utilizada para prever a preferência musical e que os ouvintes brasileiros têm uma tendência a preferir faixas musicais em uma estrutura de nichos, conforme preceitua Anderson (2017).

### 2.3.2 Metodologia

*Participantes:* foram recrutados 89 ouvintes brasileiros com idade entre 19 e 66 anos (média: 32 anos; desvio-padrão: 9,15 anos), nascidos e habitando em todas as regiões do país (40,90% no Norte, 27,28% no Sudeste, 26,13% no Sul, 3,40% no Nordeste e 2,28% no Centro-oeste), sendo 55,68% do sexo masculino e 44,32% do sexo feminino. 47% dos participantes possuíam curso superior ou profissionalizante completo, enquanto 28% deles possuíam pós-graduação. 74% não possuíam qualquer tipo de formação acadêmica musical.

*Equipamentos:* um computador Dell OptiPlex 7050, processador Intel Core i5-7500, 3.40GHz, 8GB RAM, Windows 10; *softwares* IDE Python 3, Matlab R2017b, *Goliath Toolbox*, Microsoft Excel 2016, Orange Data Mining 3.26 e Jotform.

*Dataset:* foram utilizadas 2896 músicas selecionadas a partir da mineração de dados na *Last.Fm API* e do banco de dados da *AcousticBrainz* durante o mês de abril de 2019, utilizando o *Goliath Toolbox* para Matlab R2017b. Foram recuperadas informações sobre as faixas mais populares entre os usuários brasileiros utilizando parâmetros de geolocalização, empregando a função *geo-chart()*. Após seleção do material e pré-processamento (transformação das variáveis discretas em variáveis contínuas, exclusão de casos repetidos e exclusão de *outliers*), o conjunto de dados ( $n=2224$ ) foi submetido à simulação da preferência musical utilizando os algoritmos de RNA descritos no Estudo II da presente tese. A etapa de pré-processamento e simulação foi realizada por meio do uso do software *Orange Data Mining 3.26* (Demšar et al., 2013).

*Procedimento:* o experimento foi conduzido online na plataforma *Jotform*. Foram selecionadas aleatoriamente 40 faixas musicais a partir do *dataset* descrito anteriormente e uma pesquisa de preferência (tarefa de escolha forçada) foi aplicada aos participantes ouvintes. Os participantes receberam a seguinte recomendação:

“Você está sendo convidado(a) a participar de uma pesquisa de opinião sobre suas preferências musicais em cenários de decisão. Os dados desta pesquisa serão utilizados para um estudo de doutorado realizado no Programa de Pós-Graduação em Música da Universidade Federal do Paraná (PPGMúsica/UFPR). Caso você aceite participar, gostaríamos que você nos desse sua opinião após ouvir alguns trechos musicais. Pedimos a gentileza de que, se possível, você utilize fones de ouvido com volume confortável para garantir a qualidade da audição. Esclarecemos que sua participação é voluntária e anônima. Neste sentido, nenhum dado será coletado ou utilizado para sua identificação. Além disso, esclarecemos que este estudo atende aos requisitos da Resolução CNS nº 510/2016. Caso você tenha alguma dúvida ou queira mais informações, por favor, entre em contato com a equipe do Grupo de Pesquisa Música e Expertise (GRUME/UFPR)”.

Assim, na primeira parte do estudo, eles foram convidados escolher uma faixa dentre quatro opções disponíveis. As faixas foram apresentadas utilizando um *web player* do *Spotify*, contendo 30 segundos de duração. Os participantes poderiam ouvir as faixas inteiras ou pular para as próximas faixas caso já as conhecessem. Posteriormente, eles preencheram a Escala de Preferência Musical – STOMP (Gouveia et al., 2008), constituída por 18 itens avaliados em uma escala do tipo *likert* de 11 pontos (0 a 10). A tabela a seguir apresenta a STOMP e seus itens de avaliação. Os exemplos entre parênteses foram extraídos aleatoriamente da rede *Last.Fm* usando as etiquetas (*tags*) empregadas para indexar as faixas e têm o objetivo meramente ilustrativo para orientar os participantes sobre a terminologia adotada para definir cada repertório.

**Tabela 12**

Escala de Preferência Musical – STOMP.

Considere os gêneros musicais listados abaixo. Entre parênteses, encontram-se alguns exemplos de artistas para ilustrar o gênero em questão. Gostaríamos que você indicasse o seu nível de preferência para estes gêneros musicais. Faça isso indicando um número ao lado de cada gênero, em que 0 indica "detesto" e 10 indica "gosto muito".

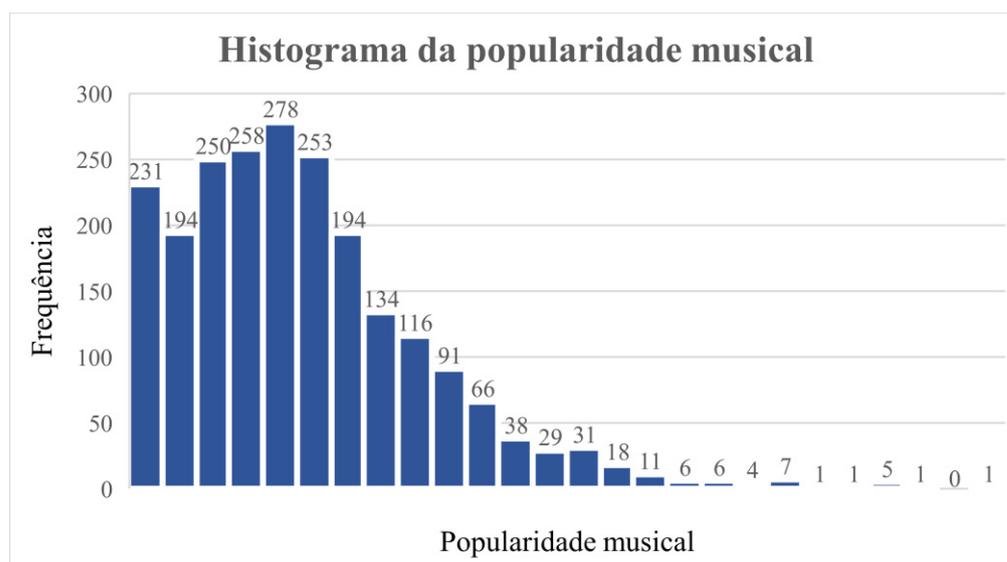
MPB (Chico Buarque, Toquinho...)	1	2	3	4	5	6	7	8	9	10
RAP (50Cent, Childish Gambino...)	1	2	3	4	5	6	7	8	9	10
Sertaneja (Zezé di Camargo & Luciano, Chitãozinho e Xororó...)	1	2	3	4	5	6	7	8	9	10
Funk (Funkadelic, Tim Maia...)	1	2	3	4	5	6	7	8	9	10
Música clássica (Mozart, Beethoven...)	1	2	3	4	5	6	7	8	9	10
Reggae (Bob Marley, Mano Chao...)	1	2	3	4	5	6	7	8	9	10
Música religiosa (Aline Barros, Padre Marcelo Rossi...)	1	2	3	4	5	6	7	8	9	10
Samba (Clara Nunes, Adoniran Barbosa...)	1	2	3	4	5	6	7	8	9	10
Blues (Muddy Waters, Nina Simone...)	1	2	3	4	5	6	7	8	9	10
Heavy metal (Black Sabbath, Judas Priest...)	1	2	3	4	5	6	7	8	9	10
Pop (Lady Gaga, Cher...)	1	2	3	4	5	6	7	8	9	10
Pagode (Molejo, Revelação...)	1	2	3	4	5	6	7	8	9	10
Rock (Pink Floyd, Fall Out Boy...)	1	2	3	4	5	6	7	8	9	10
Música romântica (Laura Pausini, Roberto Carlos...)	1	2	3	4	5	6	7	8	9	10
Forró (Luiz Gonzaga, Falamansa...)	1	2	3	4	5	6	7	8	9	10
Punk (The Clash, Ramones...)	1	2	3	4	5	6	7	8	9	10
Dance/Música eletrônica (Daft Punk, Avicii...)	1	2	3	4	5	6	7	8	9	10
Jazz (Miles Davis, Ella Fitzgerald...)	1	2	3	4	5	6	7	8	9	10

Fonte: adaptado de Gouveia et al. (2008).

*Análise de dados:* Os dados foram tabulados e uma estatística descritiva foi providenciada. Na primeira etapa da análise, um teste Kolmogorov-Smirnov foi utilizado para verificar a compatibilidade entre os resultados preditos pela rede neural artificial e a distribuição gaussiana. Posteriormente, o teste Kolmogorov-Smirnov foi novamente utilizado para verificar a compatibilidade entre os dados obtidos experimentalmente através da participação dos ouvintes e a distribuição gaussiana, bem como a distribuição referente à predição obtida pela rede neural artificial.

### 2.3.3 Resultados

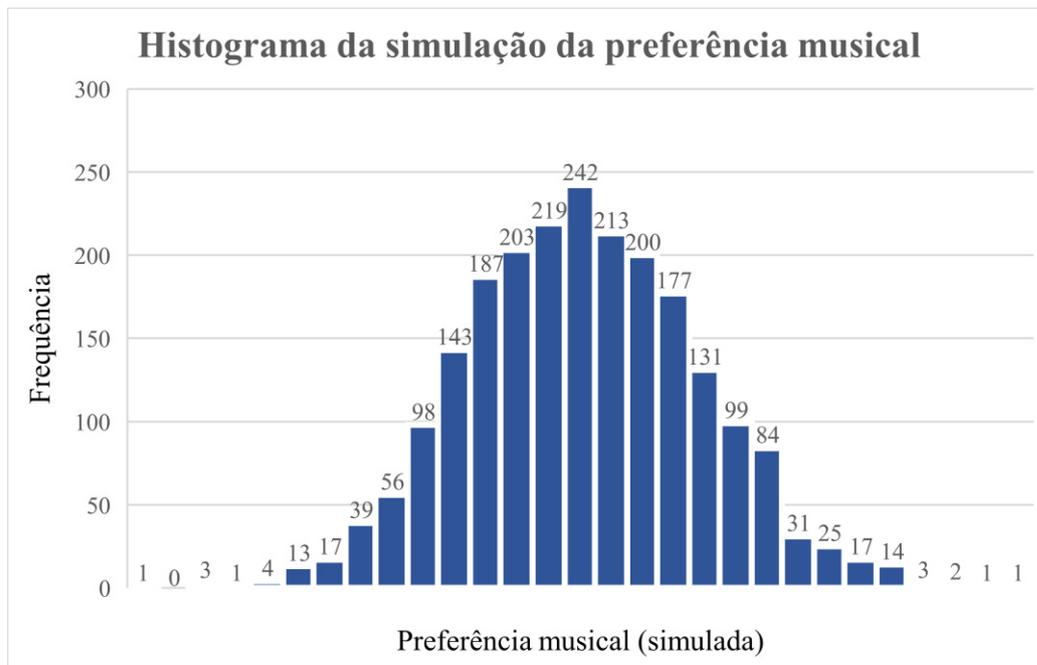
A Figura 12 apresenta o histograma contendo a distribuição da popularidade atribuída ao conjunto de faixas musicais que constituiu a amostra original do estudo. Os dados foram obtidos junto à Last.Fm API e representam a frequência em que determinada observação foi computada (isto é, a frequência com que um número relacionado à popularidade foi mencionado).



**Figura 12.** Histograma da popularidade ( $n=2224$ ), observando-se assimetria à direita.  
Nota: A frequência indica a quantidade de faixas que apresentaram a mesma contagem de popularidade.  
Fonte: Autor (2021).

Trata-se de uma descrição em que pode ser observada a presença de assimetria à direita, com concentração de faixas com pouca popularidade na região inferior do eixo  $x$ , que indica a contagem de popularidade. Isso indica que a distribuição da amostra se concentra nos limites inferiores, com poucas faixas musicais detendo grande popularidade.

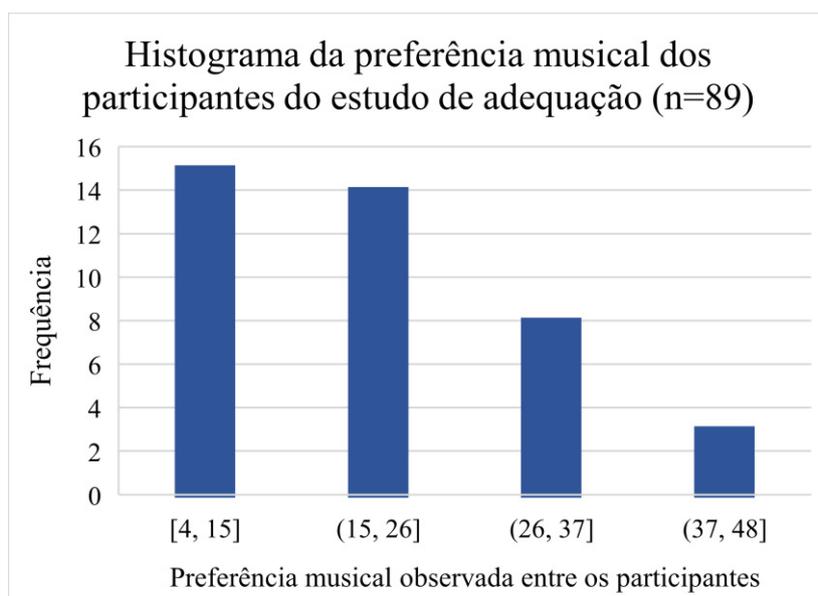
A Figura 13, por sua vez, apresenta o resultado da simulação da preferência musical entre usuários brasileiros, após a aplicação do algoritmo de RNA:



**Figura 13.** Histograma dos resultados da simulação (preferência musical predita), sugerindo uma distribuição gaussiana (média = 0,20, desvio-padrão < 0,01).  
 Nota: A frequência indica a quantidade de faixas que apresentaram a mesma contagem de preferência musical (simulada).  
 Fonte: Autor (2021).

Conforme pode ser observado, os resultados obtidos (*outputs*) tendem a uma distribuição gaussiana (média = 0,20; desvio-padrão < 0,01). O teste Kolmogorov-Smirnov foi utilizado para verificar a ocorrência desta distribuição e confirmou tal possibilidade ( $D = 0,56$ ;  $p = 0,00$ ). Esta relação demonstra que a RNA foi capaz de ajustar a simulação da preferência musical entre usuários brasileiros, como poucas músicas preferidas nos extremos inferior e superior.

A Figura 14 apresenta o histograma contendo os resultados das preferências musicais dos participantes do experimento de adequação. Como pode ser observado, a maior parte dos resultados encontra-se no limite inferior da preferência, tendo sido escolhidas entre quatro a 26 vezes.



**Figura 14.** Histograma da preferência musical referente aos participantes do estudo de adequação (n=89).

Nota: A frequência indica a quantidade de faixas que apresentaram a mesma contagem de preferência musical entre os participantes do estudo. Fonte: Autor (2021).

Os dados constantes na Figura 14 mostram a prevalência de músicas pouco preferidas pelos participantes e, por outro lado, poucas músicas cuja preferência foi exarcebada. O teste Kolmogorov-Smirnov refutou a distribuição normal ( $D = 0,99, p < 0,01$ ). Além disso, o teste Kolmogorov-Smirnov ( $D$ ) não confirmou a compatibilidade entre a amostra observada e os resultados da simulação ( $D=0,8, p < 0,01$ ).

A Tabela 13 apresenta alguns exemplos de faixas incluídas na simulação, com sua respectiva posição no *ranking*. O número entre parênteses indica a posição após a opinião dos participantes do estudo ( $n=89$ ):

**Tabela 13**

Exemplos de faixas incluídas na simulação (amostra de usuários brasileiros)<sup>71</sup>.

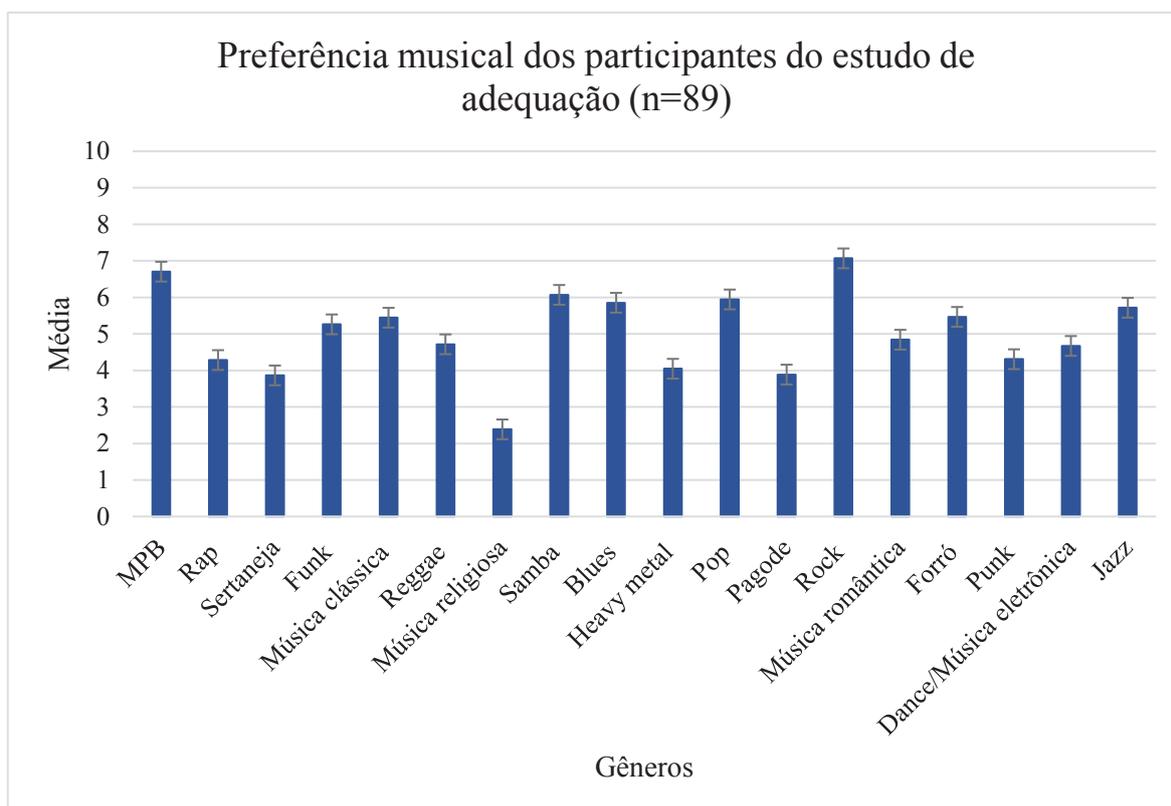
Posição	Título	Artista	Predição
1(29)	<i>Graceless</i>	<i>The National</i>	0,2143
2(2)*	<i>Ho Hey</i>	<i>The Lumineers</i>	0,2138
3(16)	<i>Already Gone</i>	<i>Kelly Clarkson</i>	0,2134
4(1)	<i>Porch</i>	<i>Pearl Jam</i>	0,2120
5(27)	<i>Everything Will Be Alright</i>	<i>The Killers</i>	0,2116
6(21)	<i>Hey Jude</i>	<i>The Beatles</i>	0,2115
7(9)	<i>Metade</i>	<i>Adriana Calcanhotto</i>	0,2115
8(11)	<i>The Unforgiven III</i>	<i>Metallica</i>	0,2110
9(6)	<i>Don't You (Forget About Me)</i>	<i>Simple Minds</i>	0,2109
10(38)	<i>Erre</i>	<i>Boogarins</i>	0,2089

Fonte: Autor (2021).

<sup>71</sup> As faixas do exemplo podem ser acessadas na *playlist* disponível em <https://open.spotify.com/playlist/7fDfFaAst1Q9ctZvdczKLS?si=HHH0H0VDTHy8FysN8YxnkQ>.

De acordo com os exemplos contidos na Tabela 13, apenas um caso (*Ho Hey*) manteve-se inalterado em relação ao *ranking* da preferência musical predita e observada experimentalmente. Os demais casos tiveram suas posições modificadas após a opinião dos participantes.

Por fim, a Figura 15 apresenta o gráfico da preferência musical dos participantes do experimento de adequação (n=89), obtido por meio da aplicação da Escala de Preferência Musical – STOMP.



**Figura 15.** Gráfico da preferência musical dos participantes do estudo de adequação (n=89).  
Fonte: Autor (2021).

Como pode ser observado, tem-se a prevalência de um padrão de preferência musical dos participantes voltado para o rock e a MPB, seguidos pelo samba, pop, blues e jazz.

Em suma, pode-se verificar que os dados obtidos experimentalmente no estudo de preferência musical distoam dos dados preditos pela rede neural artificial. Dentre as quarenta opções de faixas musicais, apenas uma música (2,5%) manteve-se inalterada no *ranking* de preferência, sugerindo que este algoritmo não seja suficiente para predizer a preferência de um grupo de usuários brasileiros.

Para compreender os detalhes destas observações, a próxima seção contém a discussão deste estudo.

### 2.3.4 Discussão

Os dados coletados no ambiente da rede *Last.Fm* entre usuários brasileiros sugere uma particularidade especial, em virtude do que parece ser uma divergência entre a simulação e a preferência observada, caracterizando um nicho específico de escuta. É possível que, ao menos entre estes participantes, a preferência musical siga um padrão de distribuição semelhante ao observado na popularidade das faixas musicais, priorizando determinadas características da obra em detrimento de outras, o que explicaria a assimetria observada (muitas músicas com baixa popularidade, poucas músicas efetivamente populares). De certa forma, a caracterização destes nichos contribui para a formação do sistema global de compartilhamento e distribuição em escala industrial de *streaming* musical, já que a composição de vários nichos forma a distribuição global da cauda longa, em que muitos artistas são pouco conhecidos.

Para Anderson (2017), existem três características principais associadas a este padrão, denominados pelo autor como *forças*: (a) a democratização das ferramentas de produção, que gera mais produtos e alonga a cauda longa da distribuição global do sistema; (b) a democratização das ferramentas de distribuição, ampliando o acesso aos nichos e “engordando” a cauda longa (da qual, portanto, o caso brasileiro seria apenas um exemplo de nicho para composição do sistema global); e (c) a ligação entre oferta e demanda, que desloca o negócio dos *hits* para o modelo de nichos, conforme pode ser observado na Figura 13. Segundo o autor:

Outra coisa que acontece quando os consumidores trocam ideias entre si é descobrirem, coletivamente, que os seus gostos são muito mais diversificados do que aquilo que é sugerido pelos planos de *marketing* com que são bombardeados. Os seus interesses encaixam-se em comunidades de afinidade cada vez mais estreitas, indo cada vez mais fundo na investigação dos assuntos de sua predileção, tal como sempre acontece quando se reúnem mentalidades semelhantes. Encorajados pelo fato de terem companhia, seja de forma virtual ou não, exploram em conjunto o desconhecido, aventurando-se por caminhos para lá dos que já foram desbravados (Anderson, 2017, p. 59).

Para Lena (2012), são os gêneros musicais que permitem a relação entre os usuários. Isto seria responsável por mantê-los coesos em torno daquilo que denomina “comunidade de gênero”:

Eu defino gêneros musicais como sistemas de orientações, expectativas e convenções que unem a indústria, artistas, críticos e fãs em fazer o que eles identificam como um tipo distinto de música. Em outras palavras, um gênero existe quando há algum consenso de que um estilo distinto de música está sendo executado. [...]

Comunidades de gênero reúnem um constituinte diversificado de gravadoras e outras organizações complexas; fãs, ouvintes e público; músicos; e “legados históricos que chegam até nós em formações sociais mais amplas”. Comunidades de gênero são mundos da arte: redes de produção, distribuição e consumo cultural. Os mundos da

arte incluem tecnologias ou materiais artísticos (por exemplo, câmeras, pincéis); sistemas regulatórios (por exemplo, lei de direitos autorais); sistemas de distribuição e locais de exibição (por exemplo, CDs, galerias); sistemas de recompensa (por exemplo, gráficos de vendas, prêmios); organizações (por exemplo, gravadoras); sistemas de apreciação e crítica (por exemplo, currículos universitários que transmitem ressonância histórica da arte); guardiões (por exemplo, caçadores de talentos, críticos de jornais) e públicos (Lena, 2012, p. 6-7).

Os resultados deste estudo também corroboram outros encontrados por Berns e colaboradores (2010), que identificaram áreas cerebrais específicas relacionadas ao sistema de recompensa para prática de avaliação (*rating*) de música baseada em popularidade. Segundo os autores, há a possibilidade de uma complexa rede neural envolvida na avaliação baseada na popularidade, em parte porque a própria música ativa uma série de mecanismos de base (como o córtex auditivo, o processamento semântico e outros). Algumas áreas do cérebro que podem estar relacionadas a essa avaliação são o sistema estriado e o córtex orbito-frontal. Isso poderia indicar uma rede neural específica destinada à avaliação de músicas consideradas mais populares, sendo tal rede associada ao sistema de recompensas.

Tomando por base os preceitos estabelecidos pela Nova Estética Experimental (Berlyne, 1973; 1971) e pela Teoria Unificada das Emoções Musicais (Juslin, Harmat & Eerola, 2014; Juslin, 2013a; Juslin, 2013b; Juslin & Västfjäll, 2008), é possível supor que os usuários deste estudo preferiram as músicas mais populares porque elas provavelmente eram mais familiares em determinado contexto. Além disso, há um papel relevante na organização interna do *ranking* encontrado neste estudo que diz respeito possivelmente às variáveis afetivas, como aquelas relacionadas ao mecanismo de contágio emocional, do reflexo do tronco cerebral e do pareamento rítmico. Isso ocorre porque, de um ponto de vista epistemológico, a primeira teoria trata das escolhas; a segunda trata de mecanismos dos quais podem ser extraídas variáveis que podem interferir nestas escolhas, como discutido no segundo estudo dessa tese.

Em um estudo sobre a preferência musical utilizando *world music* (música africana, asiática e latino-americana), Fung (1996) identificou que músicos ( $n=180$ ) e não-músicos ( $n=269$ ) são influenciados positivamente pela familiaridade em qualquer repertório. Isso corrobora a perspectiva de Zajonc (1968 como citado em Hargreaves & North, 2010), por sua vez, para quem a “mera exposição” é uma condição suficiente para aumentar seu comportamento de preferência. Neste sentido, quanto mais as pessoas são expostas a um estímulo (e, portanto, mais se tornam familiares), mais teriam condições de serem positivamente influenciados no que diz respeito à preferência. Os resultados encontrados no presente estudo também corroboram os achados de Fung (1996), na medida em que a preferência dos ouvintes parece se sustentar pela familiaridade.

Embora essa hipótese fuja do escopo desta pesquisa, parece importante considerar seus efeitos entre participantes brasileiros, levando em conta a divergência entre o repertório nacional e internacional. Os dados são incipientes para afirmar que músicos e não-músicos são susceptíveis à nacionalidade da obra durante o ato de escolha, sendo necessário mais estudos a este respeito.

Phillip Russell (1987 como citado em North & Hargreaves, 2008) investigou os efeitos da repetição na familiaridade e na preferência em *rankings* de sucesso relacionados à música popular. Seus achados mostram que as faixas que entram nos *rankings* estão associadas à maior familiaridade, porém isso não altera os padrões de preferência dos ouvintes. Para Russell (1987), deve haver algum mecanismo de autorregulação pela qual os ouvintes limitam sua familiaridade quando ela adquire níveis altos, sugerindo a existência processos que fogem ao escopo da teoria de Berlyne.

Em *The Clockwork Muse*, Martindale (1990) estabeleceu a chamada “Lei da Novidade”, que pressupõe que o desejo pela novidade nas artes (arquitetura, música, literatura e artes visuais) gera pressões adaptativas para os artistas. Sob esta perspectiva, seriam as decisões dos usuários – e não necessariamente a oferta dos serviços de *streaming* – as principais responsáveis pela composição dos nichos, na medida que operam como mecanismos de pressão adaptativa para o meio – pressão no sentido metafórico, como destaca Mayr (2009). Na medida em que os usuários passam a efetuar suas escolhas, ouvindo determinada faixa e deixando de ouvir outras, são geradas pressões adaptativas que interferem na criatividade musical dos artistas. Este aspecto será retomado no Estudo IV, onde serão investigados os processos pelos quais a popularidade evolui com o tempo.

Finalmente, deve-se destacar que a pouca precisão encontrada na implementação da simulação com dados brasileiros pode ser explicada também pelo fato de que o algoritmo não foi originalmente elaborado para essa população, carecendo de refinamento. O Estudo II, onde o algoritmo foi desenvolvido, considerou dados globais da preferência, contemplando usuários do mundo todo. Ao aplicar este algoritmo no Estudo III, foi evidenciada uma característica local, que merece mais atenção. Estudos futuros podem se dedicar a esse aspecto, bem como ampliar a amostra de agentes humanos para testagem. Para tanto, é possível coletar informações com usuários brasileiros e, posteriormente, treinar o algoritmo a partir da popularidade.

Por conseguinte, no próximo estudo que compõe essa tese será implementada uma nova simulação da popularidade em cenários de competição. Seu intuito é verificar a evolução da popularidade das faixas musicais no ambiente de *streaming*, com o objetivo de compreender os efeitos a longo prazo das escolhas dos indivíduos sobre os hábitos musicais em mercados de nicho.

## **2.4 Estudo IV: Simulação da popularidade musical em cenários de competição pela preferência na música popular compartilhada por *streaming***

### *2.4.1 Introdução*

Os estudos precedentes atribuíram um papel relevante à popularidade das obras musicais e a forma como as decisões dos sujeitos influenciam a formação deste componente. O objetivo deste estudo, portanto, foi simular a evolução da popularidade musical em cenários de competição pela preferência na música popular compartilhada por *streaming*. Buscou-se responder às seguintes questões: como a popularidade das obras se comportam durante seu “ciclo de vida”? É possível prever este fenômeno? A hipótese aqui testada pressupõe que a evolução da popularidade ocorra em um cenário de competição entre as obras, na medida em que as preferências dos usuários pelas faixas musicais representam mecanismos de seleção.

Lee e Lee (2015), em sua investigação sobre a predição da popularidade na música popular no contexto de mercado, destacam que ela é significativa, por exemplo, para saber o valor de mercado da obra e do artista, visando se estabelecer quais músicas serão empregadas em quais peças publicitárias na indústria cultural. Para Anderson (2017), por sua vez, a popularidade está intimamente ligada ao tempo, uma vez que este representa um efeito condicionante para acesso dos usuários nos mercados de nicho. Neste sentido, é possível supor que uma simulação adequada da popularidade musical deva levar em conta o tempo em que ela se desenvolve, considerando os efeitos da exposição temporal sobre a familiaridade dos ouvintes (e, no caso sob análise, também sobre os sistemas de recomendação).

Assim, nesta pesquisa, a popularidade foi mensurada por meio do cálculo do número de vezes que ouvintes selecionavam pelo menos uma vez determinada faixa musical para a escuta. Este dado reflete um indicador de familiaridade/novidade, de acordo com a Nova Estética Experimental de Berlyne (1973; 1971). Em outras palavras, quanto mais indivíduos ouvirem determinadas faixas, presumivelmente mais familiares aquelas faixas são para aquele grupo, uma vez que foram mais expostos.

### *2.4.2 Metodologia*

*Equipamentos:* um computador Dell OptiPlex 7050, processador Intel Core i5-7500, 3.40GHz, 8GB RAM, Windows 10; softwares IDE Python 3, Matlab R2017b, Goliath Toolbox, Microsoft Excel 2016 e Orange Data Mining 3.26.

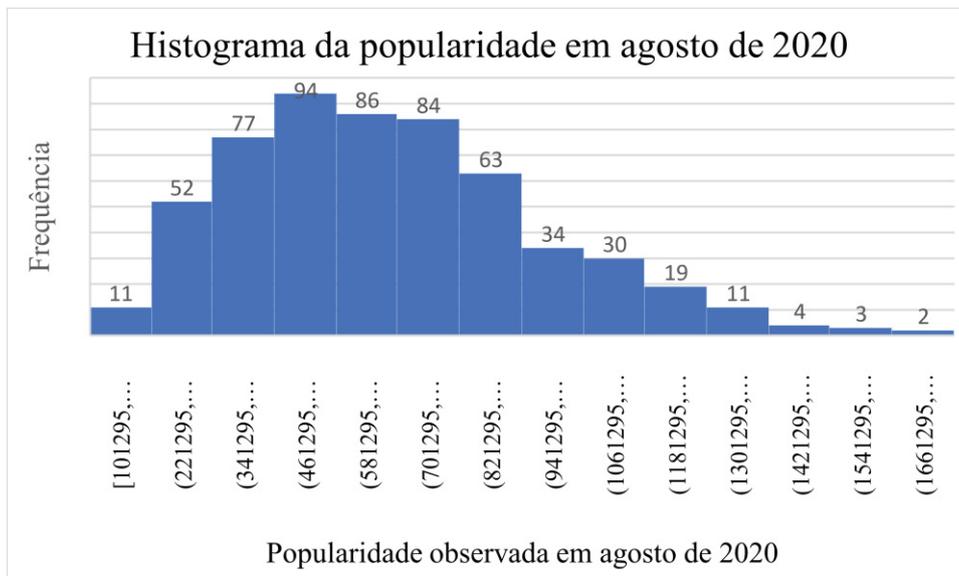
*Dataset:* a função *glochart()*, disponível no *Goliath Toolbox*, foi utilizada para realizar requisições referentes às primeiras posições dos *rankings* mundiais de popularidade musical das faixas disponíveis na Last.Fm. O *dataset*, portanto, é composto por dados recuperados nos meses de agosto de 2018, agosto de 2019 e agosto de 2020, contendo informações sobre a popularidade (número de ouvintes) das faixas constantes na *Last.FM API*, bem como seus respectivos *mbid*. Foram identificadas 571 faixas recorrentes ao longo do período de três anos ( $n=571$ ). Os resultados no formato em JSON foram transformados em tabelas nos formatos *.m* e *.xlsx*, compatíveis com os *softwares* Matlab R2017b, Microsoft Excel 2016 e Orange Data Mining 3.26 (Demšar et al., 2013).

*Procedimentos:* o *dataset* foi compilado, pré-processado (exclusão de casos atípicos) e devidamente armazenado. Posteriormente, foi realizada uma consulta no editor Power Query para Microsoft Excel 2016, mesclando as tabelas relativas aos anos de 2018, 2019 e 2020. O resultado da consulta foi levado em consideração para a simulação, contendo os casos repetidos nos três anos subsequentes. A simulação, por sua vez, foi realizada no ambiente gráfico do software Orange Data Mining 3.26, baseado em Python 3.x. Os resultados da simulação foram extraídos para novas tabelas no formato *.xlsx*, onde foram produzidos os gráficos utilizados nesta tese.

*Análise de dados:* foi implementada uma análise baseada em estatística descritiva. Além disso, a compatibilidade com o padrão de distribuição gaussiana foi verificada com o auxílio do teste Kolmogorov-Smirnov ( $D$ ), considerando-a quando  $p > 0.05$ . Para avaliação do algoritmo de regressão linear, foram considerados o coeficiente múltiplo de determinação ( $R^2$ ) e suas medidas de erro – *root mean square error* (RMSE) e *mean absolute error* (MAE). O coeficiente  $R^2$  indica a precisão da simulação, ou seja, a porcentagem da variável dependente que pode ser explicada pela variação das variáveis independentes. Quanto mais próximo de 1 ou -1, mais precisa é a simulação (indicando uma relação direta quando positivo ou inversa quando negativo). Já as medidas de erro indicam a acurácia da simulação, isto é, o quanto se aproxima dos valores esperados.

### 4.3 Resultados

Os dados apresentados no histograma da Figura 16 representam a popularidade das faixas musicais observada no mês de agosto de 2020, último período em que foi realizada a coleta de dados.



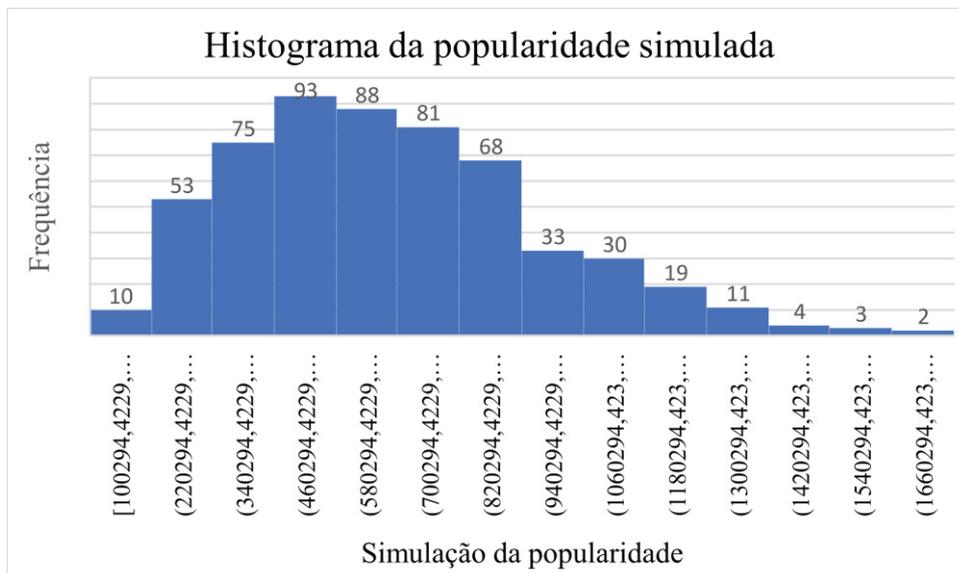
**Figura 16.** Histograma da distribuição da popularidade em agosto de 2020.

Nota: A frequência indica a quantidade de faixas que apresentaram a mesma contagem de popularidade em agosto de 2020.

Fonte: Autor (2021).

Como pode ser observado, há presença de assimetria à direita, com concentração das frequências na porção inferior do eixo referente à popularidade. O teste Kolmogorov-Smirnov não confirmou a distribuição gaussiana para essa amostra.

A Figura 17, por sua vez, apresenta o histograma contendo a distribuição da popularidade das faixas musicais simulada por um algoritmo de regressão linear.



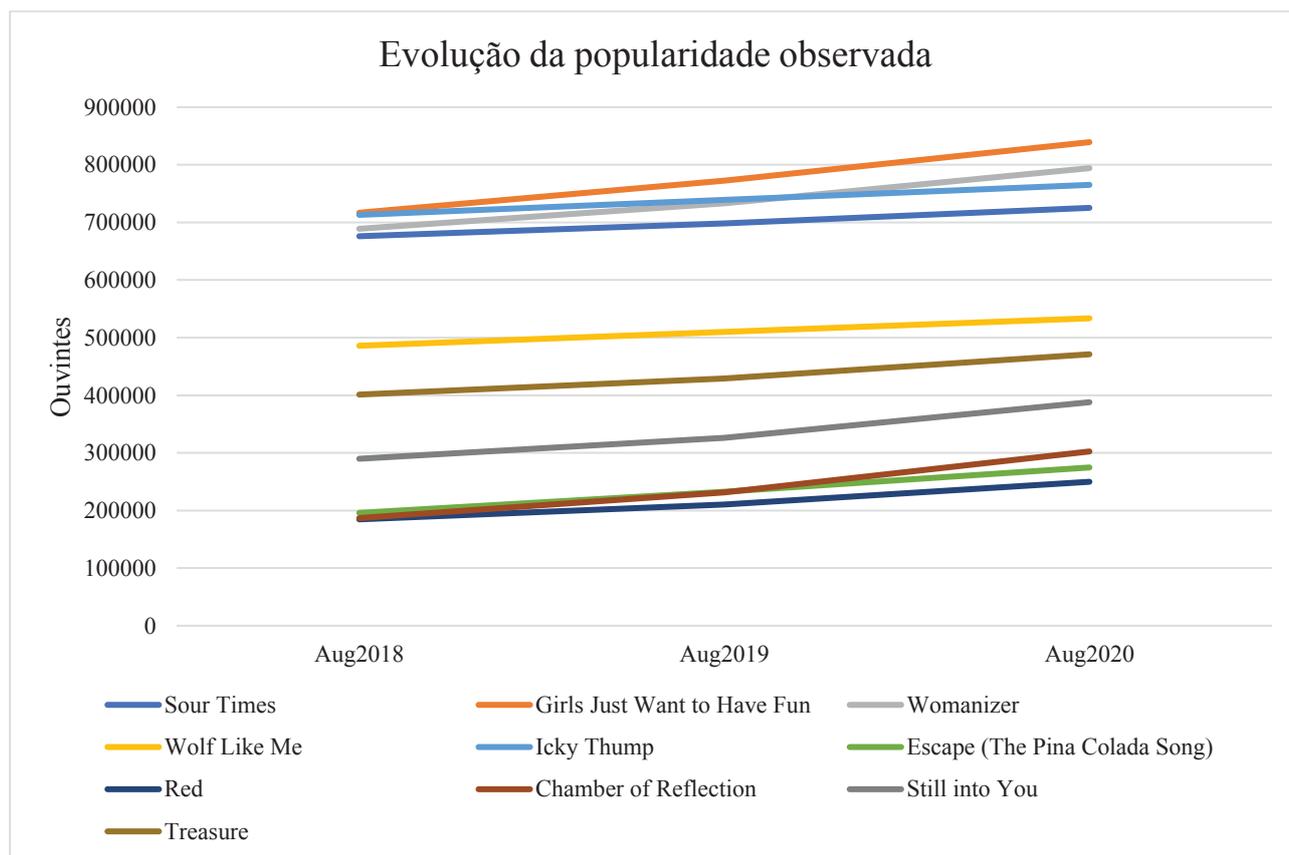
**Figura 17.** Histograma da distribuição dos resultados da simulação.

Nota: A frequência indica a quantidade de faixas que apresentaram o mesmo limiar de popularidade durante a simulação.

Fonte: Autor (2021).

Na figura acima, há presença de assimetria à direita, com concentração das frequências na porção inferior do eixo referente à popularidade das faixas musicais. O teste Kolmogorov-Smirnov não confirmou a distribuição gaussiana, mas sugere compartilhar características em comum com a distribuição apresentada pelo histograma da popularidade observada em agosto de 2020 ( $D=0.105$ ,  $p=0,99$ ).

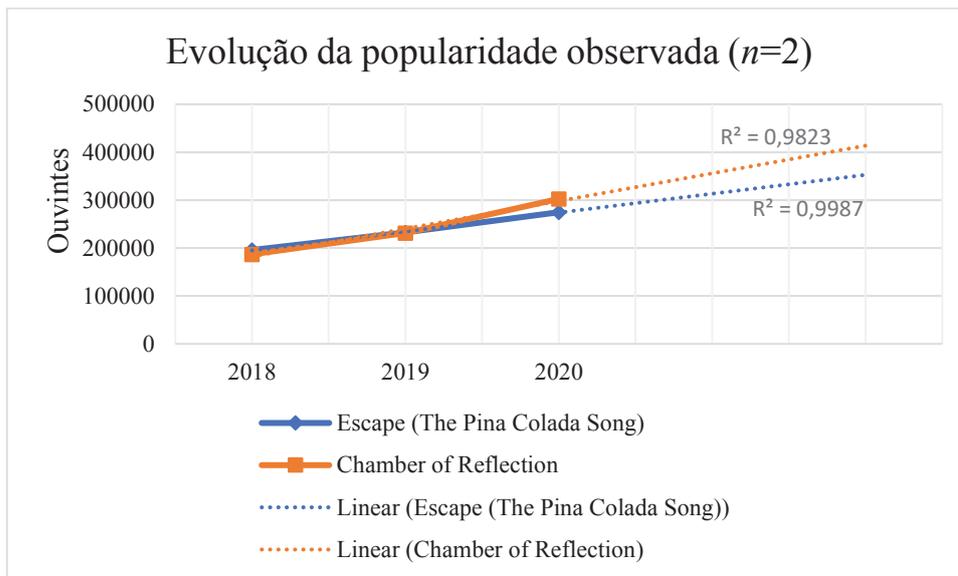
A Figura 18 apresenta o gráfico contendo alguns exemplos de faixas analisadas durante o período de 3 (três) anos ( $n=10$ ).



**Figura 18.** Popularidade observada entre agosto de 2018 e agosto de 2020.  
Fonte: Autor (2021).

Nota-se que algumas faixas possuem inicialmente uma popularidade semelhante, porém começam a se distanciar a partir de agosto de 2019. Há exemplos de faixas que perdem posições no *ranking* de popularidade (como *Escape*) e são substituídas por suas concorrentes (*Chamber of Reflection*).

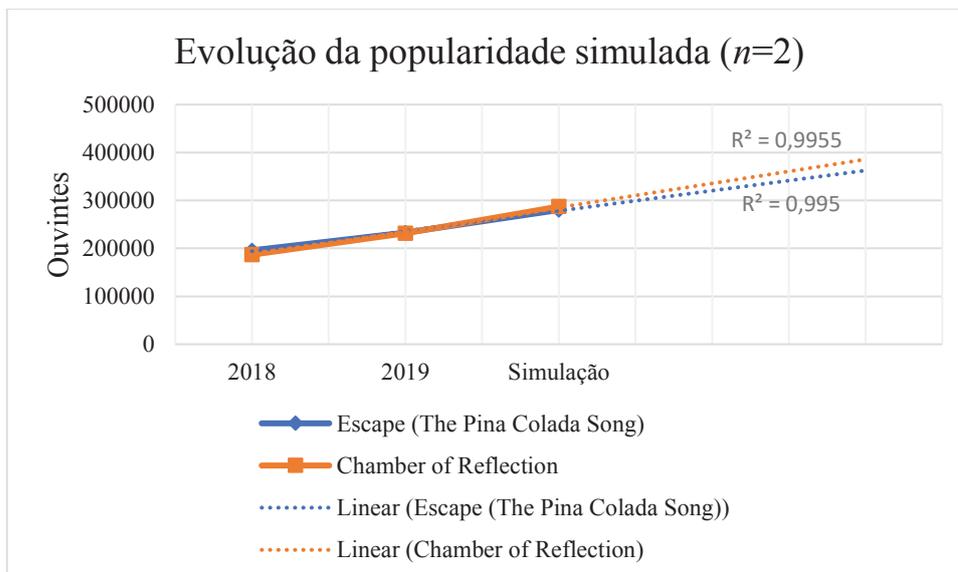
A Figura 19 apresenta um recorte do cenário em que *Escape (The Piña Colada Song)* e *Chamber of Reflection* encontram-se disputando a popularidade entre os ouvintes. As linhas pontilhadas indicam as projeções futuras.



**Figura 19.** Evolução da popularidade observada, considerando o caso de *Escape (The Piña Colada Song)* versus *Chamber of Reflection*.  
Fonte: Autor (2021).

Pode ser observado que, a partir de 2019, ambas as faixas musicais se encontram com popularidade semelhante. Porém, a partir de 2020, *Chamber of Reflection* ( $R^2=0.9823$ ) ultrapassa a marca de popularidade atribuída a sua concorrente ( $R^2=0.9987$ ).

Na Figura 20, apresenta-se um recorte do cenário simulado pelo algoritmo de regressão linear em que *Escape (The Piña Colada Song)* e *Chamber of Reflection* disputam a popularidade dos ouvintes. As linhas pontilhadas indicam as projeções futuras.



**Figura 20.** Evolução da popularidade simulada, considerando o caso de *Escape (The Piña Colada Song)* versus *Chamber of Reflection*.  
Fonte: Autor (2021).

Como no caso anterior, observa-se que a partir de 2019 ambas as faixas se encontram com popularidade semelhante, sendo que *Chamber of Reflection* ( $R^2=0,99$ ) ultrapassa a marca de popularidade de *Escape (The Piña Colada Song)* ( $R^2=0,99$ ) a partir de agosto de 2020.

A Tabela 14, por sua vez, apresenta os resultados da aplicação do algoritmo de regressão linear. *Root mean square error* (RMSE) e *mean absolute error* são as medidas de erro e indicam a acurácia do resultado da avaliação, sendo que quanto maiores os valores, menos acurados são os resultados.  $R^2$  é o coeficiente múltiplo de determinação e indica a precisão da simulação, sendo que quanto mais próximo de 1 ou -1, mais precisa é a simulação (indicando uma relação direta quando positiva ou inversa quando negativa).

**Tabela 14**

Resultado da avaliação da implementação da simulação computacional da popularidade ( $n=570$ ).

<b>Treinamento (<math>n = 376</math>)</b>		
<b>RMSE</b>	<b>MAE</b>	<b><math>R^2</math></b>
7526,97	5412,33	0,99*
<b>Testagem (<math>n = 129</math>)</b>		
<b>RMSE</b>	<b>MAE</b>	<b><math>R^2</math></b>
9510,22	6535,74	0,99*
<b>Validação (<math>n = 65</math>)</b>		
<b>RMSE</b>	<b>MAE</b>	<b><math>R^2</math></b>
5935,57	4937,99	1*

Nota 1: RMSE – *root mean square error*; MAE – *mean absolute error*;  $R^2$  – coeficiente múltiplo de determinação.

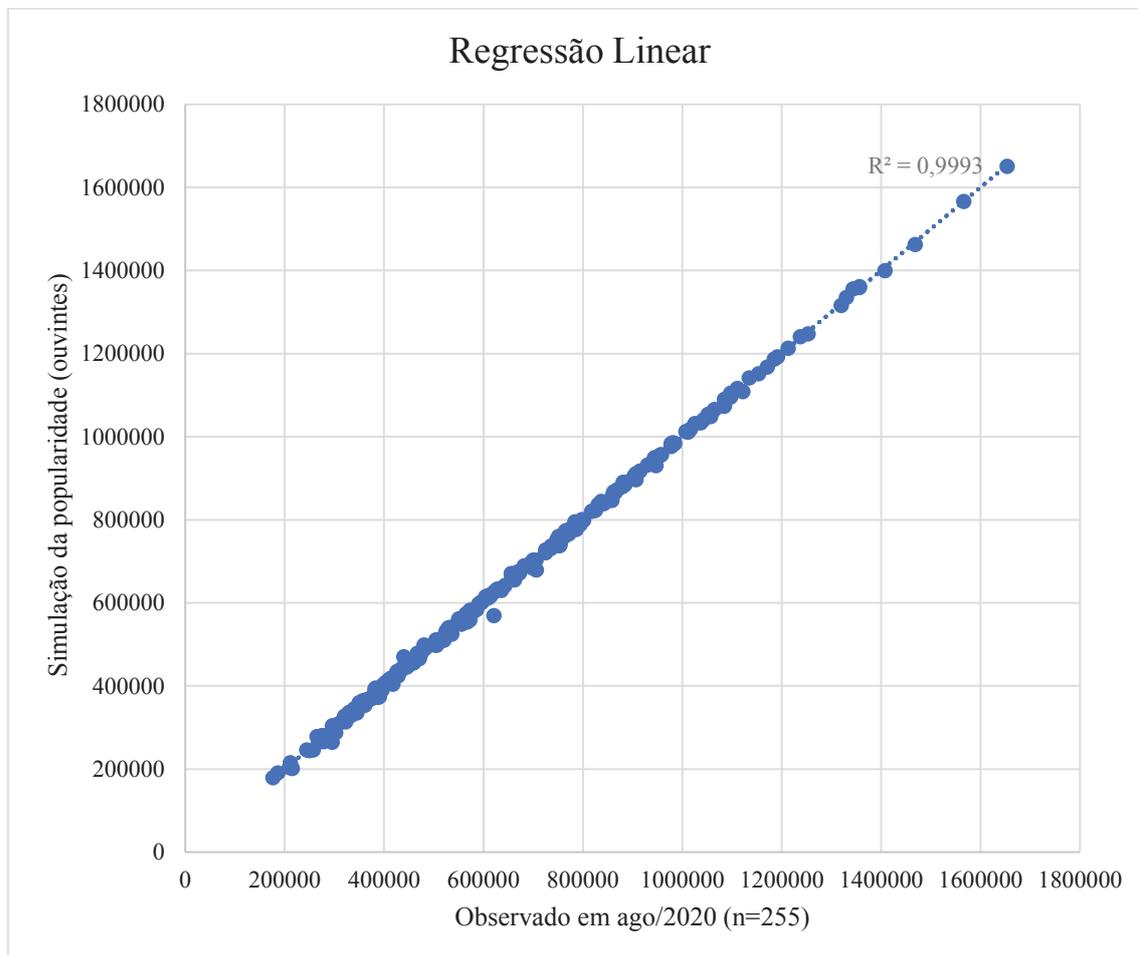
Nota 2: Os erros (RMSE e MAE) indicam a acurácia da simulação, isto é, o quanto se aproxima dos valores esperados. Quanto menores os erros, mais acurada é a simulação. O coeficiente múltiplo de determinação ( $R^2$ ) indica a precisão da simulação, ou seja, a porcentagem da variável dependente que pode ser explicada pela variação das variáveis independentes. Quanto mais próximo de 1 ou -1, mais precisa é a simulação (indicando uma relação direta quando positivo ou inversa quando negativo).

Fonte: Autor (2021).

Como pode ser observado, o algoritmo apresentou alta precisão ( $R^2=0.999$  na etapa de treinamento), mas suas medidas de erro apresentaram valores altos, em função dos altos valores dos dados de entrada. Em outras palavras, a simulação foi sensível a pequenas variações na entrada de dados (indicada pela alta precisão no resultado de  $R^2$ ), com resultados variando de acordo com as

medidas de erro entre o esperado pela simulação e o observado em agosto de 2020, considerando os altos valores atribuídos à simulação.

A Figura 21 apresenta os resultados da simulação da popularidade das faixas musicais, comparando a simulação com os dados observados em agosto de 2020.



**Figura 21.** Resultados da simulação (regressão linear,  $n=255$ ).  
Fonte: Autor (2021).

A figura revela grande compatibilidade entre os dados obtidos pela simulação por meio do algoritmo de regressão linear e as observações realizadas em agosto de 2020 ( $R^2=0.9993$ ).

Por fim, a Tabela 15 apresenta alguns exemplos de faixas incluídas na simulação, bem como os resultados da regressão linear.

**Tabela 15**Exemplos de faixas incluídas na simulação da popularidade<sup>72</sup>.

<b>Faixa</b>	<b>Artista</b>	<b>Popularidade</b>	<b>Simulação</b>
<i>Sour Times</i>	<i>Portishead</i>	725253	727358,7
<i>Girls Just Want to Have Fun</i>	<i>Cyndi Lauper</i>	839257	840961,3
<i>Womanizer</i>	<i>Britney Spears</i>	794185	787962,8
<i>Wolf Like Me</i>	<i>TV on the Radio</i>	533558	540920
<i>Icky Thump</i>	<i>The Withe Stripes</i>	765153	773169
<i>Escape (The Piña Colada Song)</i>	<i>Rupert Holmes</i>	274674	280046,3
<i>Red</i>	<i>Taylor Swift</i>	249841	244122,8
<i>Chamber of Reflection</i>	<i>Mac DeMarco</i>	302483	287301,2
<i>Still into You</i>	<i>Paramore</i>	387913	372792,4
<i>Treasure</i>	<i>Bruno Mars</i>	471113	465439,1
<i>Sleepyhead</i>	<i>Passion Pit</i>	879344	879614,9
<i>Soul Meets Body</i>	<i>Death Cab for Cutie</i>	955944	956599,5
<i>Undisclosed Desires</i>	<i>Muse</i>	760407	764126
<i>Man Down</i>	<i>Rihanna</i>	434962	438162,8
<i>Fix You</i>	<i>Coldplay</i>	1566442	1565916
<i>Am I Wrong</i>	<i>Nico &amp; Vinz</i>	383709	383222,4
<i>West Coast</i>	<i>Lana Del Rey</i>	428402	424403
<i>Cherry-Coloured Funk</i>	<i>Cocteau Twins</i>	278611	265892
<i>Common People</i>	<i>Pulp</i>	396589	401289,7

Fonte: Autor (2021).

A tabela acima ilustra os valores esperados (coluna “Popularidade”) e os valores obtidos pela simulação por meio do algoritmo de regressão linear (coluna “Simulação”). É possível verificar que, nos exemplos em questão, o algoritmo de regressão linear simula valores na direção esperada, porém apresenta certos equívocos em relação à resposta esperada.

Em suma, os resultados mostraram que o algoritmo de regressão linear foi capaz de simular a popularidade musical a partir de dados referentes aos anos precedentes, com alguma medida de erro. Além disso, os resultados sugerem que a popularidade das faixas se encontra em um cenário de competição com as demais, marcado pela coevolução das faixas candidatas.

Para compreensão destes resultados em seus pormenores, a próxima seção traz uma discussão aprofundada dos principais achados deste estudo.

#### 2.4.4 Discussão

O objetivo deste estudo foi simular a evolução da popularidade musical em cenários de competição pela preferência na música popular compartilhada por *streaming*. Os resultados mostraram que o algoritmo de regressão linear foi capaz de simular a popularidade musical utilizando dados de anos anteriores. Além disso, também se verificou que a popularidade das faixas musicais se encontra em um cenário de competição, em que as faixas podem assumir o lugar de suas concorrentes.

<sup>72</sup> As faixas do exemplo podem ser acessadas na *playlist* disponível em <<https://open.spotify.com/playlist/70EPMpd0FEfdmi0Oo1UbeB>>.

Para Van Valen (1973), no contexto da biologia evolutiva, as interações negativas (i. e., as competições por alimento, entre outras) são mais importantes no mesmo nível de interação do que o mutualismo<sup>73</sup>. Desta forma, o autor emprega a expressão derivada da narrativa “Alice através do espelho”, de Lewis Carroll (“é preciso correr sempre para permanecer no mesmo lugar”), para construir a hipótese de que a evolução depende de uma “probabilidade de adaptação”. Esta, por sua vez, leva em conta uma disputa que se torna cada vez mais complexa, na medida em que os indivíduos (e os sistemas) se encontram coevoluindo de forma mútua. Segundo o autor:

Nós podemos pensar na hipótese da rainha vermelha nos termos de uma teoria dos jogos pouco ortodoxa. Para uma boa aproximação, cada espécie é parte de um jogo de soma-zero contra outras espécies. Qual adversário é mais importante para uma espécie pode variar de tempos em tempos e, para algumas ou mesmo para a maioria das espécies, nenhum adversário pode ser de suma importância. Além disso, nenhuma espécie pode vencer, e novos adversários substituem sorridentes os perdedores. Essa é uma direção de generalização da teoria dos jogos que acho que não foi explorada (Van Valen, 1973, p. 21).

No cenário da pesquisa sobre a preferência musical, em particular, a analogia com a hipótese da rainha vermelha parece fazer sentido, uma vez que as faixas musicais representam opções cujas escolhas dos indivíduos podem interferir no comportamento geral do sistema. Isso influencia mutuamente a popularidade das demais faixas e, por conseguinte, a decisão dos demais usuários, conforme se demonstrou na simulação de preferência elaborada no segundo estudo dessa tese. Quando um participante prefere ouvir determinada peça, ele amplia o efeito de sua popularidade, favorecendo a consolidação dos nichos de preferência musical. Com efeito, semelhante a um jogo de soma-zero pautado no equilíbrio de Nash (ainda que as regras não estejam necessariamente explícitas para os usuários) – isto é, quando nenhum usuário pode individualmente aumentar seus ganhos mudando suas estratégias de forma unilateral (Lee, 2008) –, as escolhas de um usuário *X* pela faixa *A* poderiam acarretar indiretamente a rejeição da faixa *B* pelo usuário *Y*, na medida que aumentariam a exposição da primeira pelos sistemas de recomendação. Para que se tenha uma ideia da representatividade deste efeito, tome-se por base o *ranking* da *Billboard*: segundo informações dos próprios editores do *ranking*, apenas 3% dos primeiros lugares lideraram por dez semanas ou mais<sup>74</sup>.

Por conseguinte, a simulação aqui apresentada explorou parcialmente a hipótese de coevolução, demonstrando que a popularidade das faixas está crescendo continuamente no contexto da *Last.Fm*, devido, sobretudo, às escolhas dos usuários pautadas em um cenário decisório, conforme observado na Figura 18. Em outras palavras, no contexto da *Last.Fm*, a popularidade das faixas está

---

<sup>73</sup> Mutualismo é definido como uma relação ecológica entre interespecífica em que ambos os indivíduos são beneficiados.

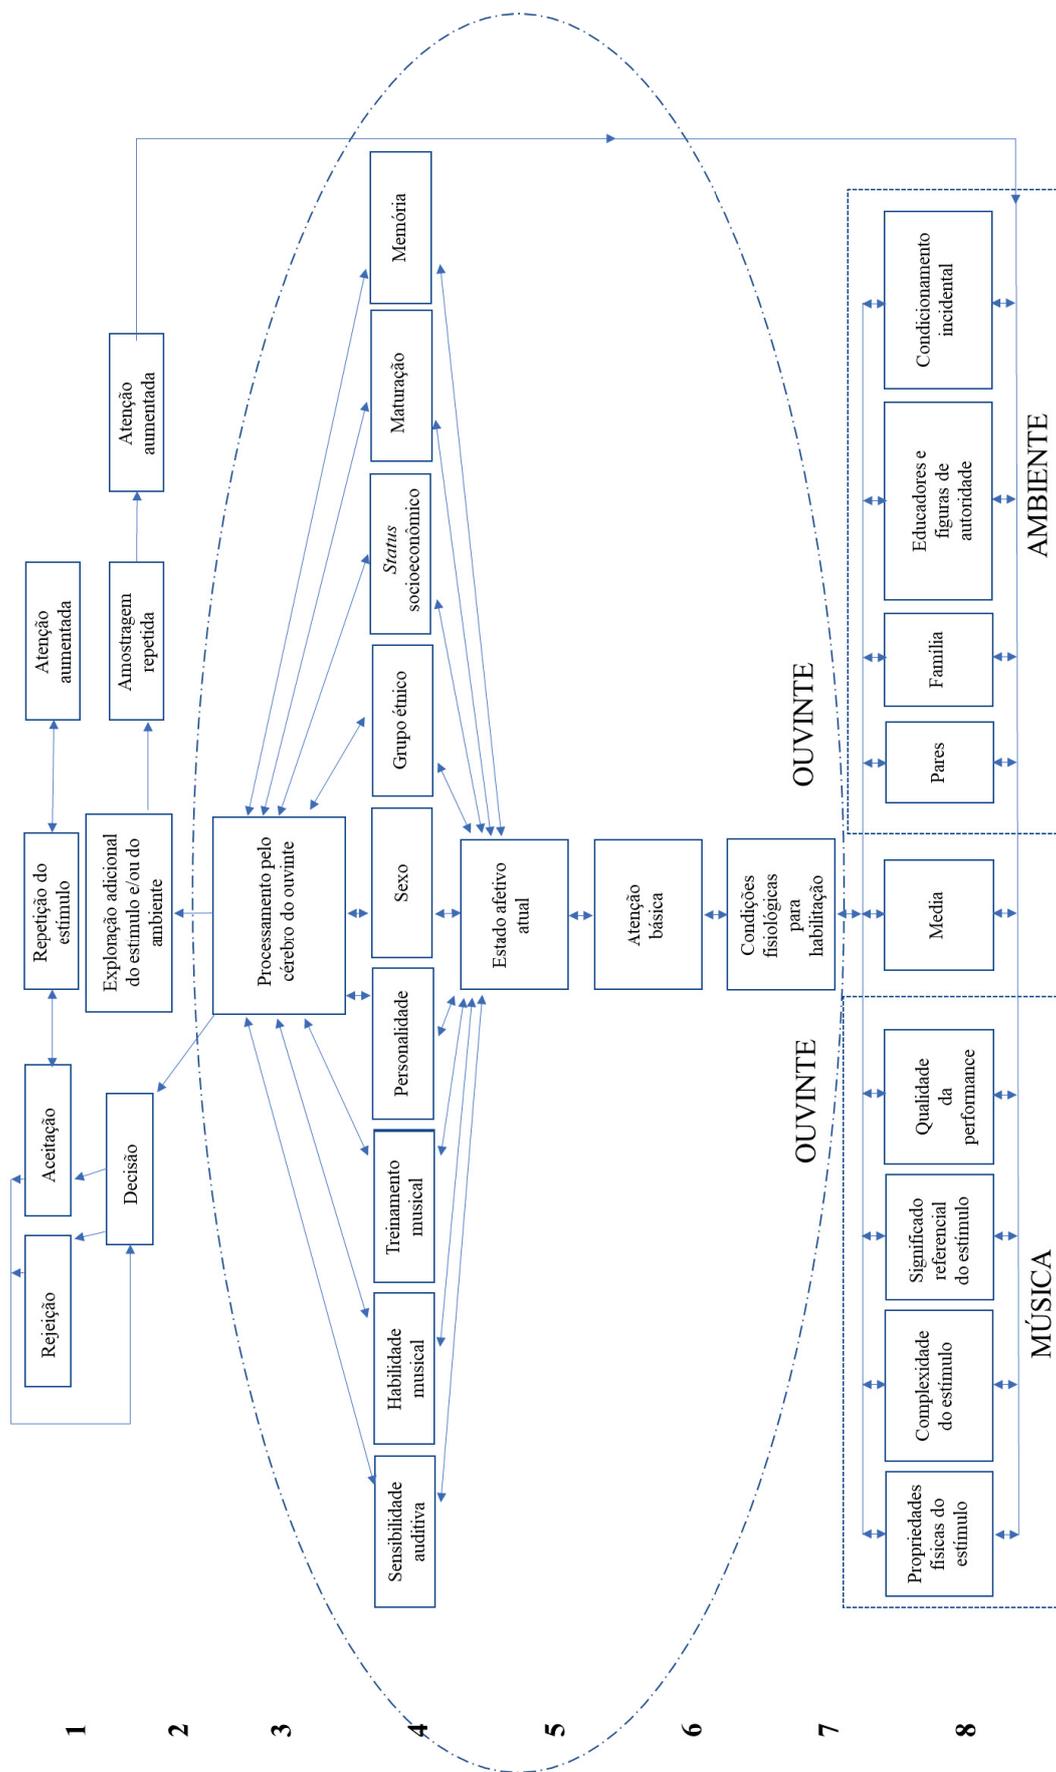
<sup>74</sup> A este respeito, ver <<https://www.billboard.com/articles/business/chart-beat/6077132/hot-100-songs-longest-leading-no-1s>>.

sempre aumentando, porque sempre haverá a contagem de novos indivíduos que ouvirem pelo menos uma vez determinada faixa. No entanto, algumas faixas podem ter sua popularidade acrescida mais rapidamente do que outras, porque arregimentarão mais ouvintes do que suas concorrentes. Como demais cenários evolutivos, isso não significa que as faixas candidatas escolhidas sejam melhores do que as outras, tampouco que esteja isento de processos estocásticos (Mayr, 2009). Por outro lado, isso poderia indicar que, por algum motivo (como por exemplo a exposição ou uma característica intrinsecamente musical), estas candidatas estejam mais adaptadas à preferência popular.

Isso se mostra evidente ao se analisar os resultados desse estudo: em um primeiro momento, observa-se a trajetória linear ascendente da popularidade das faixas, significando que, no geral, o sistema encontra-se em crescimento. Desta maneira, todas as faixas parecem estar aumentando sua popularidade em relação aos anos anteriores, acumulando mais ouvintes a cada ano. Por outro lado, algumas faixas acumulam mais ouvintes que outras. Uma explicação possível para este efeito é que algumas faixas substituem as demais neste cenário na medida em que são preferidas pelos usuários e, portanto, têm sua exposição aumentada pelos algoritmos de recomendação.

Cenários semelhantes foram estudados em teoria dos jogos pela economia. Para Schelling (1958; 1960 como citado em Padilha, 2015), ganhador do Prêmio Nobel em 2005 juntamente com Robert Aumann, as chamadas estratégias de pontos focais são importantes para chamar atenção dos “jogadores” (no contexto dessa pesquisa, dos usuários) para decisões em que são possíveis múltiplos equilíbrios em cenários de colaboração. Tais estratégias são baseadas frequentemente em percepções culturais ou tradições históricas e podem exercer um efeito decisivo nas escolhas dos jogadores. No caso dessa pesquisa, os artistas e os produtores parecem fazer uso de uma série de estratégias para chamar atenção dos usuários para suas obras, mantendo-as expostas ao público: exposição em trilhas sonoras, curadoria digital, dentre outros. Uma faixa maximiza sua popularidade não apenas pelas suas características musicais, mas também devido ao efeito da exposição – incluindo os sistemas de recomendação.

No campo da música e desenvolvimento na educação musical, LeBlanc (1987), apresenta uma complexa teoria interativa para descrever a preferência musical. Para o autor, as decisões dos ouvintes baseiam-se na interação das informações de entrada e nas características dos próprios indivíduos, com informações que dependem das características do estímulo musical e o ambiente cultural em que estes indivíduos estão inseridos. A Figura 22 apresenta um modelo hierárquico em que cada nível é indicado por um número, sendo o nível 8 relacionado à entrada das informações musicais e o nível 1 relacionado à resposta do ouvinte (decisão).



**Figura 22.** Fontes de variação na preferência musical.  
 Fonte: adaptado de Leblanc (1987).

Para LeBlanc (1987), a mídia tem um papel central na formação das preferências musicais, incluindo a mídia impressa. Por extensão às observações de LeBlanc (1987), deve-se considerar também os novos modos de escuta e compartilhamento de informação pela internet, com o advento das redes sociais e a comunicação em massa. Em geral, como a mídia molda a exposição da música, gerando pontos focais para as faixas candidatas que estão competindo entre si. Os usuários, por sua vez, buscam a estabilidade de um grupo social, como Koelsch (2013) observa.

Em 1914, Ernest Shackleton atravessava o Polo Sul quando perdeu seu navio, o *Endurance*. Dentre as coisas que fez questão de salvar, encontrava-se um banjo. Koelsch (2013) inicia seu artigo com essa narrativa para dar conta de que a música existe por algum motivo, estando ela relacionada a determinadas funções sociais. Koelsch (2013) descreve sete pontos a serem observados (7Cs) em relação a estas funções: contato, co-patia (*co-pathy*), cognição social, comunicação, coordenação, cooperação e coesão grupal. Para a autor:

[...] a música leva a uma maior coesão social de um grupo. Muitos estudos mostraram que os humanos têm uma "necessidade de pertencer" e uma forte motivação para formar e manter vínculos interpessoais duradouros. Atender a essa necessidade aumenta a saúde e a expectativa de vida. A coesão social também reforça a confiança no cuidado recíproco [...] e a confiança de que no futuro surgirão oportunidades de envolvimento com outras pessoas nas funções sociais mencionadas. (Koelsch, 2013, p. 207).

Importante observar que, na teoria interativa de LeBlanc (1987), assume-se que o indivíduo busca repetir qualquer estímulo musical quando há aceitação ou exploração adicional que pode advir, por exemplo, da recomendação de professores de música. Segundo essa perspectiva, a aceitação leva à busca por uma repetição, o que explicaria a composição de um núcleo de preferências do qual poderia emergir o gosto musical, a nível individual, e a popularidade, a nível grupal. Segundo o autor, estas escolhas não ocorrem na ausência de influência externa, tampouco deixam de influenciar os demais agentes que compõem o sistema. Comportamento semelhante foi notado por Anderson (2017) e na descrição dos resultados do terceiro estudo dessa tese, durante a formação dos nichos entre os ouvintes brasileiros. É possível que os usuários compartilhem entre si as mesmas preferências, aprofundando o efeito da “câmara de eco” (Porcaro & Gómez, 2019), em que ressoam as mesmas opções.

Kim, Suh e Lee (2014) realizaram um estudo tendo por base dados obtidos no *Twitter*, cujo objetivo era prever os hits e os artistas do ranking da Billboard a partir de postagens da rede social. Os autores elaboraram um modelo baseado em algoritmos de *support vector machine* (SVM), empregando as *hashtags* #nowplaying, #np e #itunes. Os resultados foram mais precisos para a predição dos *hits* do que para os artistas. Segundo os autores, estes resultados mostram que o número de *tweets* diários sobre uma música e um artista específicos podem ser usados de forma eficaz para

prever classificações e sucessos na Billboard. Esta pesquisa sugere que os hábitos de escuta musical dos usuários no Twitter estão altamente correlacionados com as tendências musicais em geral e podem desempenhar um papel importante na compreensão dos padrões de consumo de música dos consumidores. Além disso, sugerem que a análise dos hábitos de escuta musical dos usuários do Twitter pode ser aplicada no campo da *music information retrieval*.

Zangerle e colaboradores (2016) empregaram uma estratégia parecida à de Kim, Suh e Lee (2014), buscando prever a popularidade de faixas do *ranking* da Billboard a partir de *hashtags* #nowplaying do *Twitter*. Os autores analisaram três aspectos diferentes em relação à série temporal dos *tweets* #nowplaying e os gráficos da Billboard: (i) a correlação do Twitter e os gráficos; (ii) a relação temporal entre os dois; e (iii) o desempenho da previsão em relação aos gráficos das posições das faixas. Eles observaram que, embora haja uma correlação moderada entre os tweets e os gráficos, há um intervalo entre essas duas séries temporais para 90% de todas as faixas. Para o poder preditivo do Twitter, perceberam que incorporar informações em um modelo multivariado resulta em um aumento da acurácia.

No presente estudo, o interesse de pesquisa não recai sobre os *hits*, mas sobre o comportamento geral do sistema em que as faixas estão dispostas. Com efeito, a preocupação original residiu sobre a tentativa de se verificar a evolução da popularidade das faixas musicais em um cenário complexo, sem a pretensão de identificar quais músicas seriam escolhidas pelos usuários. Responder a esta questão é importante para que se possa compreender como uma faixa candidata se relaciona com as demais faixas em um cenário de competição.

Novos ajustes no algoritmo utilizado para a predição da popularidade são necessários para compreender a fundo os processos relacionados à formação da popularidade musical e à tomada de decisão e podem ser adotados em estudos futuros que tenham como objetivo, por exemplo, investigar possibilidades de existência de uma árvore de regressão para simular a escolha das faixas candidatas ou mesmo de uma nova camada de preferência baseada em redes neurais, como no segundo estudo dessa tese. Além disso, no cenário em investigação atual deste estudo, as faixas parecem incrementar sua popularidade indistintamente, mas não há a previsão da entrada de novas faixas candidatas para despertar a atenção dos usuários. Com efeito, mesmo que a popularidade destas faixas continue aumentando, outras faixas que não foram incluídas na simulação do presente estudo poderão ter sua popularidade aumentando ainda mais se obtiverem mais sucesso na disputa pelas colocações com as demais.

Em suma, os resultados deste estudo corroboram a hipótese de que a evolução da popularidade ocorra em um cenário de competição entre as obras, na medida em que as preferências dos usuários pelas faixas musicais representam mecanismos de seleção. Alinhados aos estudos anteriores, que se centraram na preferência e analisaram a atuação das variáveis relacionadas à Nova Estética

Experimental e à Teoria Unificada das Emoções Musicais (Estudo II), bem como o papel da popularidade para a preferência musical entre usuários brasileiros (Estudo III), estes resultados permitem supor que os processos relacionados à preferência musical e à popularidade da obra estejam interrelacionados, dependendo de variáveis como aquelas incluídas nesta pesquisa, em maior ou menor grau.

Para aprofundar essas questões, a próxima seção contém uma discussão geral da tese, redigida com o intuito de incorporar elementos dos quatro estudos produzidos ao longo desta pesquisa. Isso será feito para debater os resultados dos estudos dentro de uma macro-perspectiva analítica, fazendo emergir a relação entre o objetivo da pesquisa, sua hipótese e os possíveis avanços que essa tese traz para o campo da cognição musical.

### **3. DISCUSSÃO GERAL**

O objetivo deste trabalho foi investigar a preferência musical de usuários de uma rede social voltada para o compartilhamento de suas escolhas musicais, no intuito de compreender alguns dos processos relacionados aos seus hábitos de escuta. A hipótese central da pesquisa era a de que as variáveis descritas poderiam influenciar a preferência musical dos ouvintes no contexto da música difundida pelos serviços de *streaming* na medida em que afetariam diretamente a popularidade das faixas musicais.

Para isso, foram realizados quatro estudos: (i) a implementação de uma ferramenta para mineração de dados musicais no Matlab – o *Goliath Toolbox*; (ii) a simulação da preferência musical utilizando redes neurais artificiais; (iii) a testagem da simulação da preferência musical entre brasileiros; e (iv) um estudo de simulação da popularidade musical em cenários de competição pela preferência na música popular compartilhada por *streaming*.

Os resultados encontrados sugerem que o *Goliath Toolbox* se mostra uma ferramenta viável para pesquisadores e desenvolvedores porque permite o acesso a grandes conjuntos de dados da rede social *Last.Fm* e da *MusicBrainz Foundation* – dados estes que possibilitaram a realização dos estudos subsequentes. Os resultados também revelaram que as variáveis selecionadas para simular a preferência musical por meio de um algoritmo de rede neural artificial – dentre elas variáveis como popularidade, andamento, intensidade, dentre outras – são capazes de predizer a preferência com precisão e acurácia. Também mostraram que as redes neurais treinadas para predizer a preferência de usuários de toda a rede não foi capaz de predizer a preferência de um grupo específico de usuários, neste caso, usuários brasileiros. Tanto o Estudo II, quanto o Estudo III, mostraram que poucas faixas musicais são muito conhecidas pelo público e, pelo contrário, muitas faixas musicais são pouco conhecidas pelo público. O mesmo se aplica à preferência: muitas faixas são pouco preferidas pelo público, ao passo que poucas faixas musicais são muito preferidas pelo público. Finalmente, no Estudo IV, foi evidenciado o cenário de competição das faixas musicais pela popularidade, onde duas candidatas encontram-se coevoluindo durante um processo que pode ser descrito de acordo com a hipótese da rainha vermelha.

No começo do século passado, Kate Hevner publicou uma série de estudos buscando compreender como ocorre a preferência musical (Hevner, 1930; 1935; 1937). Para Hevner (1930), a necessidade de estudos experimentais na área da estética era equivalente à dificuldade em realizá-los. Além disso, a pesquisadora destacava a ideia de que o “bom gosto infalível” – ou seja, a ideia segundo a qual o “bom gosto” era universalmente aceito – era dificilmente comprovável, argumento também corroborado por Farnsworth (1950).

Embora “respostas estéticas” e “respostas afetivas” não tratem do mesmo constructo (Hargreaves & North, 2010), o trabalho de Hevner apresenta contribuições significativas tanto para o estudo da preferência musical, quanto para das emoções desencadeadas pela música. Em 1936, no artigo

intitulado *Experimental studies of the elements of expression in music*, a autora propõe uma lista de adjetivos distribuídos em oito categorias para investigar a expressividade musical. Segundo Hevner (1936), a expressividade é um recurso importante para obras que obtiveram grande sucesso popular, o que justificaria sua abordagem. Posteriormente, essa lista de adjetivos foi revisada por Schubert (2003), que sugeriu a redução para 46 adjetivos distribuídos em nove categorias. A Figura 23 apresenta uma tradução livre da lista de adjetivos original de Hevner (1936).



**Figura 23.** Lista de adjetivos utilizada para designar as expressões musicais.  
Fonte: adaptado de Hevner (1930).

A lista de adjetivos de Hevner (1936) se assemelha ao modelo circumplexo de Russell (1980), como notaram alguns pesquisadores posteriormente, a começar pela disposição dos grupos de adjetivos e dos limites que estabelecem entre si (North & Hargreaves, 2008; Schubert, 2003). Segundo North e Hargreaves (2008 p. 130-132):

Talvez o aspecto mais interessante [dos resultados encontrados por Hevner], entretanto, seja que as emoções que o modelo circumplexo classificaria como mais estimulantes parecem ser evocadas por propriedades musicais que Berlyne argumentaria possuir maior potencial de excitação. Por exemplo, Hevner argumenta que as emoções do Grupo 7, como "excitante", são produzidas particularmente por música rápida e com harmonias complexas; enquanto as emoções do Grupo 4, como "calma", são produzidas principalmente por música lenta e com harmonias simples. Em suma, a pesquisa sobre as respostas emocionais à música no contexto do modelo circumplexo pode, em última análise, ser reconciliada com a teoria da preferência musical de Berlyne. As respostas emocionais e de desgosto à música podem não ser tão diferentes como a literatura existente sugere.

Os resultados encontrados na presente pesquisa corroboram a perspectiva de North e Hargreaves (2008) a respeito da possibilidade de reconciliação entre os estudos sobre emoções desencadeadas pela música e preferência musical. Essa descoberta revela que a emoção sentida pelo ouvinte por meio da escuta parece influenciar a preferência musical, conforme também se pôde constatar no segundo estudo dessa tese.

Na década de 50, Farnsworth (1950) publicou *Musical taste: its measurement and cultural nature*, em que relata alguns de seus estudos sobre preferência musical. O autor investigou diferentes grupos com diferentes níveis de *expertise* musical e observou variação no padrão de preferência entre os grupos, mas não ao longo do tempo, quando entrevistados reiteradamente. Ele observou que as pessoas tendem a concordar com o seu grupo a respeito da preferência musical e que esta preferência tende a permanecer inerte ao longo do tempo. Além disso, cada grupo conhece um número limitado de compositores, que tende a ser os mesmos. Farnsworth (1950) denominou os principais compositores de cada grupo como eminentes. Para o autor, não apenas cada grupo gosta dos mesmos compositores eminentes, como também conhece os mesmos compositores, as rádios tocam os mesmos compositores e as orquestras possuem os mesmos programas, que se repetem ano após ano. Mueller e Hevner (1942 como citado em Farnsworth, 1950) denominaram esse fenômeno de repetição de programas pelas orquestras como pirâmide da popularidade. Segundo Farnsworth (1950), isso é válido para a música de concerto e para o *jazz*. Na Tabela 16, são apresentados os resultados de um estudo em que Farnsworth (1950) avaliou os programas da *Boston Symphony Orchestra*. A coluna "1925-1935" traz os compositores eminentes daquela década, ao passo que a coluna "1935-1945" traz os compositores eminentes da década seguinte.

**Tabela 16**Escolha de programas da *Boston Symphony Orchestra*

Ordem	1925-1935	1935-1945
1	Beethoven	Beethoven
2	Brahms	Brahms
3	Wagner	Mozart
4	Bach	Sibelius
5	R. Strauss	R. Strauss
6	Ravel	Ravel
7	Mozart	Wagner
8	Sibelius	Stravinsky
9	Stravinsky	Tchaikovsky
10	Tchaikovsky	Bach

Fonte: Farnsworth (1950).

A presença de faixas musicais eminentes foi algo a ser observado na presente pesquisa considerando os resultados obtidos nos Estudos II e III. Parece haver uma forte tendência para manter uma distribuição que favoreça a projeção de algumas poucas faixas, ao passo que a imensa maioria passa despercebida pelo grande público. No entanto, a literatura sugere que a manutenção econômica do mercado dependa justamente deste tipo de distribuição, em que pese o grande volume de negócios que estes artistas pouco conhecidos movimentam (Anderson, 2007).

Hargreaves e North (2010) revisaram algumas pesquisas conduzidas sob a perspectiva dos estudos do comportamento de conformidade, tal qual investigado por Solomon Asch na década de 50. Estes estudos parecem úteis para compreender os processos relacionados ao comportamento que leva à concordância das pessoas sobre um determinado assunto, dentre eles, possivelmente a própria preferência, indicando porque algumas faixas acabam se sobressaindo às demais. No experimento clássico de Asch (1955), os participantes confrontavam suas opiniões com a de outros sujeitos a respeito do tamanho de certas figuras. O estudo de Asch (1955) demonstrou que uma parcela dos participantes mudava de opinião depois de ouvir a maioria, se conformando com a opinião alheia. Para o autor:

Entre as pessoas extremamente submissas, encontramos um grupo que rapidamente chegou à conclusão: “Estou errado, eles estão certos”. Outros cederam para “não prejudicar seus resultados”. Muitos dos indivíduos que participaram suspeitaram que a maioria era “ovelha” após o primeiro respondente, ou que a maioria foi vítima de uma ilusão de ótica; no entanto, essas suspeitas não os libertaram no momento da decisão. Mais inquietantes foram as reações dos sujeitos que interpretaram sua diferença em relação à maioria como um sinal de alguma deficiência geral em si mesmos, que a todo custo deveriam ocultar. Com base nisso, eles tentaram desesperadamente se fundir com a maioria, sem perceber as consequências de longo prazo para eles próprios. Todos os sujeitos subestimados subestimaram a frequência com que se conformaram (Asch, 1955, p. 4).

Segundo Hargreaves e North (2010), dois tipos diferentes de conformidade podem ser descritos. *Compliance* diz respeito aos indivíduos que desejam se conformar com as opiniões dos grupos

sociais e, portanto, conferem *status* elevado a estes grupos (“concordo com alguém pois ele certamente sabe muito”), ao passo que *prestígio* se refere a informações específicas sobre uma música em questão, sendo particularmente importante quando pouco se conhece a respeito do objeto e, neste contexto, quando os efeitos da conformidade são mais evidentes por atuação da propaganda (“concordo com alguém pois não sei nada do assunto que estão falando”).

Inglefield (1968) realizou um estudo sobre preferência utilizando um delineamento inspirado no estudo de Asch (1955), encontrando evidências de *compliance* para o repertório do *jazz*: os participantes conferiram *status* elevado a esse gênero musical. Furman e Duke (1988), por outro lado, não encontraram evidências de *compliance* na música popular para músicos e não-músicos, porém identificaram *compliance* entre não-músicos na música de concerto: os não-músicos conferiram *status* elevado à música de concerto.

Crowther (1985 como citado em Hargreaves & North, 2010) elaborou uma tarefa em que os participantes deveriam escolher uma dentre quatro opções de escuta. Enquanto escolhiam suas peças para ouvir, tinham acesso a um painel que mostrava o que os outros participantes estavam ouvindo. No entanto, o pesquisador programou o painel para mostrar as recomendações ao contrário: ao invés de mostrar a recomendação com base no que os outros participantes estavam ouvindo, o painel mostrava as peças mais rejeitadas nos primeiros lugares do *ranking*. Os participantes foram influenciados pelo *ranking* e passaram a escolher as peças rejeitadas, apresentadas enganosamente como sendo as primeiras colocadas do *ranking*. Para Crowther (1985 como citado em Hargreaves & North, 2010), a minoria dos ouvintes foi capaz de influenciar o padrão dos gostos musicais.

Nos estudos sobre prestígio, Alpert (1982) verificou que a aprovação de repertórios por figuras de autoridade influencia positivamente a preferência musical de jovens. Estes dados corroboram a teoria de LeBlanc (1987) a respeito do papel das figuras de autoridade para a formação de preferência. Fiese (1990 como citado em Hargreaves & North, 2010) atribuiu a autoria de peças a Beethoven e Strauss em seu estudo e isso influenciou o julgamento de qualidade pelos estudantes participantes da pesquisa.

Embora esta variável não tenha sido considerada neste estudo, isto parece ser um caminho promissor para pesquisas futuras sobre a preferência musical, em que seja possível investigar os mecanismos relacionados à influência entre os usuários (*compliance*) e o papel do prestígio dos artistas na tomada de decisão dos ouvintes. Segundo Levitin (2010, p. 275):

As preferências musicais têm também um forte componente social, baseado em nosso conhecimento do cantor ou músico, naquilo que é apreciado por nossa família e nossos amigos, assim como no que a música representa. Historicamente, e em especial do ponto de vista evolutivo, a música sempre esteve envolvida em atividades sociais, o que talvez explique por que a forma mais comum de expressão musical,

dos Salmos de David a Tin Pan Alley e à música contemporânea, é a canção de amor, e porque elas são tão caras para a maioria de nós.

West e Martindale (1996) analisaram as mudanças no conteúdo das letras dos Beatles, colocando sob testagem a teoria exposta em *The Clockwork Muse* – ou seja, de que as demandas adaptativas do meio impostas pela audiência influenciam a criatividade dos artistas. Os autores incluíram em sua análise 183 músicas compostas *dos Beatles para os Beatles* (excluindo, por exemplo, obras de George Martin ou trabalhos solo de Lennon ou McCartney). Para analisar essas músicas, os autores utilizaram um software baseado na estatística das ocorrências dos termos empregados nas letras. A hipótese, segundo os autores, era de que:

Presumivelmente, os Beatles, que competiam com outros artistas e eventualmente uns com os outros para chamar a atenção do público, enfrentaram pressão contínua para produzir canções cada vez mais originais. Podemos avaliar se eles responderam a essa pressão implícita, como um grupo ou como indivíduos, escrevendo canções envolvendo cada vez mais novidade e complexidade e regressão cognitiva cada vez mais profunda. (West & Martindale, 1996, p. 107).

Foi observado o declínio de conteúdos semânticos e potencial de *arousal* nas letras das músicas conforme previsto originalmente na hipótese do estudo. Contudo, para West e Martindale (1996), este tipo de análise contém algumas limitações, a começar pelo fato de que ela se concentra apenas no conteúdo semântico das letras. No rock, em especial, existem outros elementos particularmente importantes a serem considerados (e. g., a melodia), como destacam os autores ou o timbre, como destaca Levitin (2010).

Os resultados encontrados no Estudo IV corroboram parcialmente a hipótese apresentada por West & Martindale (1996), particularmente o que diz respeito à pressão dos artistas e à competição pela atenção do público. No Estudo IV, isto se mostrou evidente no cenário de competição, em que as faixas se encontram em disputa pela popularidade entre os usuários. O Estudo IV não se pautou em uma avaliação dos artistas, mas sim entre as faixas; deste modo, indicou que as faixas tendem a coevoluir, isto é, crescer em popularidade, mas responder de forma diferente às necessidades adaptativas impostas pelos usuários, conforme a analogia com a hipótese da rainha vermelha (Van Valen, 1975).

O processo decisório possui um papel importante a cumprir nesse contexto, uma vez que estabelece a seleção das músicas que serão preferidas pelos ouvintes e, portanto, fomentará a popularidade (assim como a popularidade influenciará a preferência, conforme se apresentou no Estudo II). Para Damásio (2011), o processo decisório implica que o agente que tomará a decisão tenha conhecimento da situação, das opções disponíveis e das consequências de suas escolhas, embora nem sempre tais consequências estejam claras o suficiente na vida cotidiana. No terceiro

estudo dessa tese, os participantes tiveram que tomar uma decisão ao optar por uma dentre quatro opções de faixas musicais disponíveis em cada situação experimental. Neste cenário, os resultados sugerem que os participantes priorizaram algumas faixas musicais específicas, possivelmente aquelas que lhes foram mais familiares. Isto reforça a importância de estudos que investiguem métricas de popularidade e indicadores de familiaridade, sob a perspectiva da Nova Estética Experimental de Daniel Berlyne (1973; 1971).

Estes resultados fortalecem as descobertas de Porcaro e González (2019), que investigaram as recomendações musicais em *streamings* e rádios. Para os autores, os sistemas de recomendação tendem a homogeneizar o comportamento de escolha dos usuários. O objetivo desse estudo foi descrever as variações nos indicadores de popularidade e no conteúdo semântico relacionado a alguns gêneros musicais investigados. Mudanças mais significativas foram observadas na música veiculada pela rádio em relação ao *streaming*, embora os autores sugiram que mais estudos precisem ser realizados sobre esta temática.

Em suma, levando em conta a hipótese inicial desta pesquisa, os resultados do Estudo II, III e IV sugerem que as variáveis descritas na Nova Estética Experimental e na Teoria Unificada das Emoções Musicais incluídas nesta tese podem influenciar a preferência musical dos ouvintes no contexto da música difundida pelos serviços de *streaming*, na medida em que afetam diretamente a popularidade das faixas musicais.

Adicionalmente, é importante mencionar que a popularidade das faixas parece evoluir no tempo em um cenário de competição, sendo a preferência musical um mecanismo de seleção tal qual prevê a analogia com a hipótese da rainha vermelha (Van Valen, 1973).

Finalmente, na próxima seção são apresentadas as considerações finais.

## **4. CONSIDERAÇÕES FINAIS**

A hipótese central desta pesquisa era a de que as variáveis descritas na Nova Estética Experimental e na Teoria Unificada das Emoções Musicais poderiam influenciar a preferência musical dos ouvintes no contexto da música difundida pelos serviços de *streaming* na medida em que afetariam diretamente a popularidade das faixas musicais. Além de corroborar parcialmente tal hipótese, os resultados dos estudos realizados sugerem que a popularidade das faixas parece evoluir no tempo em um cenário de competição, sendo a preferência musical um mecanismo de seleção tal qual prevê a analogia com a hipótese da rainha vermelha (Van Valen, 1973).

Isto significa que a popularidade das faixas musicais se encontra em crescimento constante, sendo limitada pela preferência musical dos usuários dos sistemas de recomendação. A preferência musical, por sua vez, é de certa forma parcialmente influenciada pelas variáveis relacionadas às teorias emocionais e de preferência selecionadas nesta pesquisa.

Ademais, os resultados mostram, em suma, que as variáveis relacionadas às teorias em questão parecem ser úteis para a simulação computacional da preferência musical; porém, a popularidade se destacou nos estudos com a participação de humanos, exigindo novas análises. Os resultados sugerem que esta variável assume um lugar de proeminência sobre as demais.

Para chegar a estas conclusões, a pesquisa foi subdividida em quatro etapas, a saber:

- (a) Implementação do *Goliath Toolbox* para a recuperação de informações nas bases de dados da *Last.Fm API* e da *MetaBrainz Foundation*, que permitiu o acesso aos dados utilizados nos estudos subsequentes;
- (b) Simulação computacional da preferência musical de usuários da rede *Last.Fm* a partir de preditores derivados da Nova Estética Experimental de Daniel Berlyne e da Teoria Unificada das Emoções Musicais sintetizada por Patrik Juslin e seus colaboradores utilizando algoritmos de redes neurais artificiais, que demonstrou a viabilidade das variáveis em questão para a predição da preferência;
- (c) Testagem de adequação da simulação descrita na etapa anterior junto a uma amostra brasileira, que resultou em uma inconsistência entre os resultados da predição pela rede neural e os resultados da opinião dos participantes, que possivelmente tenderam a emitir respostas mais familiares;
- (d) Simulação da popularidade de faixas em cenários evolutivos, de acordo com estimativas temporais, que mostrou a viabilidade de utilização de um algoritmo de regressão linear para a predição da popularidade e a possibilidade de coevolução em cenários de competição.

Alguns detalhes necessitam ser observados. Em primeiro lugar, a simulação do terceiro estudo dessa tese se mostrou incompatível com o resultado esperado, que tende a se assemelhar a uma distribuição parecida com o padrão de popularidade musical, mas não com a simulação computacional.

Isso pode ter ocorrido devido ao tipo de algoritmo implementado, baseado em aprendizado supervisionado. Como o treinamento não fez uso de dados conhecidos, talvez o algoritmo tenha sido incapaz de prever a preferência em situações de incerteza. Desta forma, parece ser necessário o treinamento de um novo algoritmo específico para essa população, seja utilizando dados de usuários brasileiros, seja preparando um experimento híbrido pelo qual o algoritmo possa ser treinado a partir de dados de voluntários. Além disso, não foi testada a eficácia em comparação com outros algoritmos em nenhum dos estudos, o que poderia evidenciar abordagens distintas para os problemas de pesquisa aqui expostos, indo além das redes neurais artificiais e da regressão linear.

Deve-se destacar, também, que os impactos das novas tecnologias relacionadas ao mundo digital e a internet são observáveis em vários campos do saber, dentre os quais a cognição musical abordada aqui e a educação musical, cujo papel não pode ser negligenciado. Segundo Romanelli (2019, p. 60),

Essas transformações foram radicais e tão recentes que ainda é difícil medir seu impacto na forma com a humanidade se relaciona com a música. Essas mudanças certamente influenciaram a forma como a música é ensinada e, conseqüentemente como seus materiais didáticos são produzidos. Considerando-se que essas transformações afetam o próprio conteúdo do ensino, do ponto de vista do código disciplinar a música foi uma das disciplinas mais impactadas pelas transformações dos últimos cem anos.

Estudos futuros podem se dedicar a investigar a relação entre a Nova Estética Experimental e a Teoria Unificada das Emoções Musicais, explorando o modo como os processos psicológicos que subsidiam as emoções e as preferências encontram-se interligados. Ademais, é possível realizar estudos longitudinais, dando continuidade às observações sobre os cenários de competição por popularidade descritos nesta tese. Por fim, os pesquisadores da área devem atentar especialmente para os aspectos culturais relacionados à emoção e à preferência, uma vez que estes podem resultar em variáveis intervenientes nos estudos experimentais relacionando estes dois constructos.

Espera-se que a realização de estudos desta natureza possa trazer contribuições para a área de cognição musical e *music information retrieval*, em que pese o crescente interesse dos pesquisadores pelos processos relacionados à preferência e emoção musicais, tomada de decisão, julgamento e teorias de escolha. Acredita-se que esse interesse seja crescente devido ao volume cada vez maior de obras e serviços disponíveis massivamente para o grande público, levando em conta as recentes transformações nos hábitos de escuta musical dos usuários de *streaming*.

# REFERÊNCIAS

- Abe, L. A. (2019). *A influência do pareamento rítmico sobre respostas emocionais sentidas em trechos de música instrumental brasileira*. Dissertação de Mestrado (Programa de Pós-Graduação em Música da Universidade Federal do Paraná). Orientador: Prof. Dr. Danilo Ramos. Curitiba.
- Abib, J. A. D. (2009). Epistemologia pluralizada e história da psicologia. *Scientiae Studia*, 7(2), pp. 195-208.
- Afifi, A. K. & Bergman, R. A. (2007). *Neuroanatomia funcional: texto e atlas*. 2ª edição. São Paulo: Editora Roca.
- Alpert, J. (1982). The effect of disc-jockey, peer, and music teacher approval of music on music selection and preference. *Journal of Research in Music Education*, 30, pp. 173-186.
- Amaral, A., Aquino, M. C. (2009). “Eu recomendo... e etiqueto”: práticas de folksonomia de usuários no *Last.Fm*. *Líbero*, 12(24), pp. 117-130.
- Anderson, C. (2017). *A Cauda Longa*. Lisboa: Actual.
- Andrews, P. & Pane, J. (2013). Sense induction in folksonomies: a review. *Artificial Intelligence Review*, 40(2), pp. 147-174.
- Araújo, S. F. (2009). Wilhelm Wundt e a fundação do primeiro centro internacional de formação de psicólogos. *Temas em Psicologia*, 17(1), pp. 9-14.
- Araújo, C. S.; Cristo, M. & Giusti, R. (2019). Predicting Music Popularity on Streaming Platforms. *Anais do Simpósio Brasileiro de Computação Musical*. Disponível em <<https://sol.sbc.org.br/index.php/sbcm/article/view/10436>>. Acesso 24 de janeiro de 2021.
- Asch, S. (1955). Opinions and social pressure. *Scientific American*, 193(5), pp. 31-35.
- Atkinson, G. (1998). *Chess and Machine Intuition*. Exeter: Intellect.
- Becker, J. (2010). Exploring the habitus of listening: anthropological perspectives. In: Juslin, P. & Sloboda, J. (eds.). *The Handbook of Music and Emotion*. New York: Oxford University Press. pp. 128–157
- Belzung, C. (2007). *Biologia das Emoções*. Trad.: Armando Pereira da Silva. Lisboa: Instituto Piaget.
- Berlyne, D. E. (1969). Arousal, reward and learning. *Annals of New York Academy of Sciences*, 159(3), pp. 1059-1070.
- Berlyne, D. E. (1970). Novelty, complexity, and hedonic value. *Perception & Psychophysics*, 8(5), pp. 279-286.

- Berlyne, D. E. (1971). *Aesthetics and Psychobiology*. New York: Appleton-CenturyCrofts.
- Berlyne, D. E. (1973). The vicissitudes of aplopathematic and thelematospic pneumatology (or the hydrography of hedonism). In Berlyne, D. E. & Madsen, K. B. (eds). *Pleasure, Reward, Preference: their nature, determinants, and role in behavior*. New York: Academic Press.
- Berlyne, D. E & Parham, L. C. C. (1968). Determinants of subjective novelty. *Perception & Psychophysics*, 3(6), pp. 415-423.
- Berns, G. S.; Capra, C. M.; Moore, S. & Noussair, C. (2010). Neural Mechanisms of the Influence of Popularity on Adolescent Ratings of Music. *Neuroimage*, 49(3), pp. 2687-2696.
- Bertin-Mahieux, T., Ellis, D. P. W., Whitman, B. & Lamere, P. (2011). The Million Song Dataset. In: *Proceedings of 12th International Society for Music Information Retrieval Conference*. pp. 591-596.
- Bezerra, D. M., Guerra, M. A. & Silva, E. G. (2018). Preferência musical em sistemas de recomendação baseados em folksonomia: tendências de usuários brasileiros da rede Last.Fm. *Revista da ABEM*, 25(37), pp. 49-61.
- Bogdanov, D., Porter, A., Boyer, P. H. & Serra, X. Cross-collection evaluation for music classification tasks. *Proceedings of the 17th International Society for Music Information Retrieval Conference*, pp. 379-385.
- Bourdieu, P. (1989). *O poder simbólico*. Trad. Fernando Tomaz. Rio de Janeiro: Bertrand Brasil.
- Brandt, M. & Medeiros, M. B. B. (2010). Folksonomia: esquema de representação do conhecimento? *TransInformação*, 22(2), pp. 111-121.
- Brasil. Presidência da República. Casa Civil. Subchefia para Assuntos Jurídicos (2018). *Lei nº 13.709, de 14 de agosto de 2018* (Lei Geral de Proteção de Dados Pessoais). Disponível em <[http://www.planalto.gov.br/ccivil\\_03/\\_Ato2015-2018/2018/Lei/L13709.htm](http://www.planalto.gov.br/ccivil_03/_Ato2015-2018/2018/Lei/L13709.htm)>. Acesso em 17 de março de 2019.
- Bunge, M. (2002). *Dicionário de Filosofia*. São Paulo: Perspectivas.
- Callegari-Jacques, S. M. (2003). *Bioestatística: princípios e aplicações*. Porto Alegre: Artmed.
- Carvalho, L. A. M. C. & Macedo, H. T. (2014). Introdução aos Sistemas de Recomendação para Grupos. *RITA*, 21(1), pp. 77-109.
- Carvalho, L. L., Varenne, F. & Braga, E. M. (2014). Ontologias para a modelagem multiagente de sistemas complexos em ciências cognitivas. *Ciências & Cognição*, 19(1), pp. 58-75.

- Castilho, F. M. & Martins, L. A.-C. P. (2012). As concepções evolutivas de Darwin sobre a expressão das emoções no homem e nos animais. *Revista da Biologia*, 9(2), pp. 12-15.
- Cazella, S., Nunes, M. A. & Reategui, E. (2010). A Ciência da Opinião: Estado da arte em Sistemas de Recomendação. *Anais do Congresso da Sociedade de Computação*, pp. 161-216.
- Civai, C.; Teodorini, R. & Carrus, E. (2020). Does unfairness sound wrong? A cross-domain investigation of expectations in music and social decision-making. *Royal Society Open Science*, 7(9), pp. 1-21.
- Chanda, M. L. & Levitin, D. (2013). The neurochemistry of music. *Trends in Cognitive Science*, 17(4), pp. 179-193.
- Cupchik, G. C. & Berlyne, D. E. (1979). The perception of collative properties in visual stimuli. *Scandinavian Journal of Psychology*, 20(1), pp. 93-104.
- Damáσιο, A. (2011). *O Erro de Descartes: emoção, razão e o cérebro humano*. 3ª Ed. Trad.: Dora Vicente e Georgina Segurado. São Paulo: Companhia das Letras.
- Dancey, C. P. & Reidy, J. (2013). *Estatística sem matemática para a psicologia*. 5ª Ed. Porto Alegre: Penso.
- Darriba, V. A. & Bosse, C. (2013). O terapêutico e o analítico em Freud. *Psicologia em Estudo*, 18(2), 333-341.
- Darwin, C. (1890). *The Expression of Emotions in Man and Animals*. Cambridge: Cambridge University Press.
- Demšar, J., Curk, T., Erjavec, A., Gorup, C., Hocevar, T., Milutinovic, M., Mozina, M., Polajnar, M., Toplak, M., Staric, A., Stajdohar, M., Umek, L., Zagar, L., Zbontar, J., Zitnik, M. & Zupan, B. (2013). Orange: Data Mining Toolbox in Python. *Journal of Machine Learning Research*, 14, pp. 2349-2353.
- Downie, J. S. (2003). Music information retrieval. *Annual Review of Information Science and Technology*, 37, pp. 295-340. Disponível em <[http://music-ir.org/downie\\_mir\\_arist37.pdf](http://music-ir.org/downie_mir_arist37.pdf)>. Acesso em 27 de fevereiro de 2018.
- Dutra, A. A. (2014). *Explorando dados públicos de programação de rádios e playlists na web para recomendação em música*. Dissertação de mestrado (Programa de Pós-Graduação em Mestrado em Ciência da Computação). Orientador: Prof. Dr. Álvaro Rodrigues Pereira Junior. Universidade Federal de Ouro Preto.
- Eerola, T.; Lartillot, O. & Toiviainen, P. (2009). Prediction of Multidimensional Emotional Ratings in Music from Audio Using Multivariate Regression Models. *ISMIR*. Disponível em <<https://cite-seerx.ist.psu.edu/viewdoc/download?doi=10.1.1.205.9542&rep=rep1&type=pdf>> Acesso em 24 de janeiro de 2021.

- El-Hani, C. N. & Queiroz, J. (2005). Semiose e emergência. *Galáxia*, 9, pp. 113-140.
- Engelmann, A. (1986). Lep – uma lista, de origem brasileira, para medir a presença de estados de ânimo no momento em que está sendo respondida. *Ciência e Cultura*, 38(1), pp. 121-146.
- Eysenck, M. W. & Keane, M. T. (2010). *Cognitive Psychology: a student's handbook*. New York: Psychology Press.
- Farnsworth, P. R. (1950). *Musical taste: Its measurement and cultural nature*. Stanford: Stanford University Press.
- Farrell, S. & Lewandowsky, S. (2018). *Computational Modeling of Cognition and Behavior*. New York: Cambridge University Press.
- Ferreira, J., Tacla, C. & Silva, S. (2012). Uma proposta para o uso de folksonomias como conceitualizações compartilhadas na especificação de modelos conceituais. *Proceedings of the Seminar on Ontology Research in Brazil and International Workshop on Metamodels, Ontologies and Semantic Technologies*, pp. 230-235.
- Fielding, R. T., Gettys, J., Mogul, J., Frystyk, H. & Berners-Lee, T. (1997). Hypertext Transfer Protocol -- HTTP/1.1. *Network Working Group*. Disponível em <<http://www.ietf.org/rfc/rfc2068.txt>>. Acesso em 27 de fevereiro de 2018.
- Fielding, R. T. (2000). *Architectural Styles and the Design of Network-based Software Architectures*. Tese de Doutorado (Information and Computer Science). Orientador: Prof. PhD. Richard N. Taylor. University of California, Irvine.
- Figueira-Filho, F.; Geus, P. L. & Albuquerque, J. P. (2008). Sistemas de Recomendação e Interação na Web Social. *Anais do Workshop de Aspectos da Interação Humano-Computador na Web Social*, pp. 1-4.
- Fornari, J. E. (2013). Percepção, cognição e afeto musical. In: Keller, D. & Budasz, R. (orgs.). *Criação Musical e Tecnologias: teoria e prática interdisciplinar*. Goiânia: ANPPOM. pp. 6-38.
- Fung, C. V. (1996). Musicians' and Nonmusicians' Preferences for World Musics: Relation to Musical Characteristics and Familiarity. *Journal of Research in Music Education*, 44(1), pp. 60-83.
- Furman, C. E. & Duke, R. A. (1988). Effect of majority consensus on preferences for recorded orchestral and popular music. *Journal of Research in Music Education*, 36, pp. 220-231.
- Gjerdingen, R. O. (2002). The psychology of music. In Christensen, T. (ed.). *The Cambridge History of Western Music Theory*. Cambridge: Cambridge University Press.

- Gouveia, V. V.; Pimentel, C. E.; Santana, N. L.; Chaves, W. A. & Rodrigues, C. A. (2008). Escala abreviada de preferência musical (STOMP): evidências de sua validade fatorial e consistência interna. *Psico*, 39(2), pp. 201-210.
- Han, J.; Kamber, M. & Pei, J. (2012). *Data Mining: Concepts and Techniques*. Waltham: Elsevier.
- Hargreaves, D. J. (1986). *The Developmental Psychology of Music*. London: Cambridge University Press.
- Hargreaves, D. J. (2012). Musical imagination: Perception and production, beauty and creativity. *Psychology of Music*, 40(5), pp. 539-557.
- Hargreaves, D. J. & North, A. C. (2010). Experimental aesthetics and liking for music. In Juslin, P. N. & Sloboda, J. A. (eds). *Handbook of music and emotion: theory, research and applications*. New York: Oxford University Press, pp. 515–546.
- Hargreaves, D. J.; North, A. C. & Tarrant, M. (2016). The development of musical preference and taste in childhood and adolescence. In McPherson, G. (ed.). *The Child as Musician: Musical Development from Conception to Adolescence*. Oxford: Oxford University Press, pp. 135–154.
- Hemerly, J. (2011). Making Metadata: The Case of MusicBrainz. SSRN Electronic Journal. Disponível em <[https://papers.ssrn.com/sol3/papers.cfm?abstract\\_id=1982823](https://papers.ssrn.com/sol3/papers.cfm?abstract_id=1982823)>. Acesso 01 de Março de 2018.
- Hevner, K. (1930). Tests for the aesthetic appreciation in the field of music. *Journal of Applied Psychology*, 14, pp. 470-477.
- Hevner, K. (1935). Expression in music: A discussion of experimental studies and theories. *Psychological Review*, 47, pp. 186-204.
- Hevner, K. (1936). Experimental Studies of the Elements of Expression in Music. *The American Journal of Psychology*, 48(2), pp. 246-268.
- Hevner, K. (1937). The aesthetic experience: A psychological description. *Psychological Review*, 44, 257.
- Hinds Jr, H. H. (2002). Popularity: How to Make a Key Concept Count in Building a Theory of Popular Culture. In Hinds Jr, H. H.; Motz, M. F. & Nelson, A. M. S. (orgs.). *Popular Culture Theory and Methodology*. Madison: The University of Wisconsin Press.
- Holm, E. A. (2019). In defense of the black box. *Science*, 364(6435), pp. 26-27.
- Hu, X., Downie, J. S., Laurier, C., Bay, M. & Ehmann, A. F. (2008). The 2007 MIREX Audio Mood Classification Task: Lessons learned. In: *Proceedings of International Society for Music Information Retrieval Conference*, p. 462–467.

- Huron, D. (2000). Perceptual and Cognitive Applications in Music Information Retrieval. *1st ISMIR 2000*. Disponível em <<https://dblp.org/db/conf/ismir/ismir2000.html>>. Acesso em 24 de janeiro de 2021.
- Huron, D. (2001). Is music an evolutionary adaptation? *Annals of the New York Academy of Sciences*, 930, 43-61.
- Inglefield, H. G. (1968). *The relationship of selected personality variables to conformity behaviour reflected in the musical preferences of adolescents when exposed to peer group leader influences*. Tese de Doutorado (Ohio State University). Orientador: Dr. Henry L. Cady.
- Jannach, D. & Bonnin, G. (2017). Music Recommendation. In: Wheis, C., Jannach, D., Vatulkin, I. & Rudolph, G. (eds.). *Music Data Analysis: Foundations and Applications*. New York: CRC. pp. 563-588.
- Jordan, J. S., Srinivasan, N. & van Leeuwen, C. (2015). The role of complex systems theory in cognitive science. *Cognitive Processing*, 16(4), pp. 315-317.
- Juslin, P. N. (2000). Cue Utilization in Communication of Emotion in Music Performance: Relating Performance to Perception. *Journal of Experimental Psychology: Human Perception and Performance*, 26(6), pp. 1797-1813.
- Juslin, P. N. (2013a). From everyday emotions to aesthetic emotions: Towards a unified theory of musical emotions. *Physics of Life Reviews*, 10, pp. 235-266.
- Juslin, P. N. (2013b). What does music express? Basic emotions and beyond. *Frontiers in Psychology*, 4(596), pp. 1-14.
- Juslin, P. N. (2016). Emotional reactions to music. In Hallam, S.; Cross, I. & Thaut, M. (eds.). *The Oxford Handbook of Music Psychology*. Oxford: Oxford University Press, pp. 197-214.
- Juslin, P. N. (2019). *Musical Emotions Explained: Unlocked the secrets of musical affect*. New York: Oxford University Press.
- Juslin, P. N.; Barradas, G. & Eerola, T. (2015). From Sound to Significance: Exploring the Mechanisms Underlying Emotional Reactions to Music. *The American Journal of Psychology*, 128(3), pp. 281-304.
- Juslin, P. N., Harmat, L. & Eerola, T. (2014). What makes music emotionally significant? Exploring the underlying mechanisms. *Psychology of Music*, 42(4), pp. 599-623.
- Juslin, P. N. & Isaksson, S. (2014). Subjective criteria for choice and aesthetic judgment of music: a comparison of psychology and music students. *Research Studies em Music Education*, 36(2), pp. 179-198.

- Juslin, P. N. & Scherer, K. (2005). Vocal expression of affect. In Harrigan, J. A., Rosenthal, R. & Scherer, K. (eds.). *The New Handbook of Methods in Nonverbal Behavior Research*. Oxford: Oxford University Press, pp. 65–135.
- Juslin, P. N. & Sloboda, J. A. (2010). Past, present and future of music and emotion research. In Juslin, P. N. & Sloboda, J. A. (eds). *Handbook of music and emotion: theory, research and applications*. New York: Oxford University Press, pp. 933–955.
- Juslin, P. N. & Västjäll, D. (2008). Emotional responses to music: the need to consider underlying mechanisms. *Behavioral Brain Sciences*, 31(5), pp. 559-575.
- Keltner, D. & Lerner, J. S. (2010). Emotion. In Fiske, S. T., Gilbert, D. T. & Lindzey, G. (eds.). *Handbook of social psychology*. Hoboken: John Wiley & Sons, pp. 317-352.
- Kim, P. (2017). *MATLAB Deep Learning with Machine Learning, Neural Networks and Artificial Intelligence*. New Jersey: Apress.
- Kim, Y.; Suh, B. & Lee, K. (2014). #nowplaying the future billboard: mining music listening behaviors of twitter users for hit song prediction. *SoMeRA '14: Proceedings of the first international workshop on Social media retrieval and analysis*. Disponível em <<https://dl.acm.org/doi/10.1145/2632188.2632206>>. Acesso 24 de janeiro de 2021.
- Koelsch, S. (2013). From Social Contact to Social Cohesion—The 7 Cs. *Music and Medicine*, 5(4), pp. 204–209.
- Konečni, V. J. (1975). The mediation of aggressive behavior: arousal level versus anger and cognitive labeling. *Journal of Personality and Social Psychology*, 32(4), pp. 706-712.
- Konečni, V. J. (2010). The influence of affect in music choice. In Juslin, P. N. & Sloboda, J. A. (eds). *Handbook of music and emotion: theory, research and applications*. New York: Oxford University Press, pp. 698–723.
- Kovács, Z. (2006). *Redes Neurais Artificiais: Fundamentos e Aplicações*. São Paulo: Livraria da Física.
- Kramer, A., Guillory, J. E. & Hancock, J. T. (2014). Experimental evidence of massive-scale emotional contagion through social networks. *PNAS*, 111(24), pp. 8788-8790.
- Krugman, P. & Wells, R. (2017). *Microeconomia: uma abordagem moderna*. São Paulo: Elsevier.
- Kuzelewska, U. & Ducki, R. (2013). Collaborative filtering recommender systems in music recommendation. *Advances in Computer Science Research*, 10, pp. 67-79.
- Lamb, L. C., Villavicencio, A., Idiart, M., Buriol, L., Ribeiro, L. & Silva, R. (2007). Modelagem de sistemas computacionais complexos: em direção a uma fundamentação científica e aplicações

tecnológicas. *Anais do XXVII Congresso da SBC*. Disponível em <[http://www.inf.ufrgs.br/~bu-riol/papers/Lamb\\_SEMISH07.pdf](http://www.inf.ufrgs.br/~bu-riol/papers/Lamb_SEMISH07.pdf)>. Acessado em 17 de março de 2019.

- LeBlanc, A. (1987). The Development of Music Preference in Children. In Peery, J. C., Peery, I. W. & Draper, T. W. (eds.). *Music and Child Development*. New York: Springer, pp 137-157.
- Lee, D. (2008). Game theory and neural basis of social decision making. *Nature Neuroscience*, 11(4), pp. 404-409.
- Lee, J. & Lee, J.-S. (2015). Predicting Music Popularity Patterns based on Musical Complexity and Early Stage Popularity. *SLAM '15: Proceedings of the Third Edition Workshop on Speech, Language & Audio in Multimedia*. Disponível em <<https://dl.acm.org/doi/abs/10.1145/2802558.2814645>>. Acesso em 24 de janeiro de 2021.
- Lefford, N. & Thompson, P. A. (2018). Naturalistic Artistic Decision-making and Metacognition in the Music Studio. *Cognition, Technology and Work*, 20, pp. 543-554.
- Lena, J. C. (2012). *Banding Together: How communities create genres in popular music*. New York: Princeton University Press.
- Lent, R. (2005). *Cem bilhões de neurônios: conceitos fundamentais de neurociência*. São Paulo: Editora Atheneu.
- Lent, R.; Azevedo, F. A. C.; Andrade-Moraes, C. H. & Pinto, A. V. O. (2012). How many neurons do you have? Some dogmas of quantitative neuroscience under revision. *European Journal of Neuroscience*, 35, pp. 1-9.
- Lerner, J.; Li, Y.; Valdesolo, P. & Kassam, K. (2015). Emotion and Decision Making. *Annual Review of Psychology*, 66, pp. 799-823.
- Levin, J., Fox, J. A. & Forde, D. R. (2012). *Estatística para Ciências Humanas*. São Paulo: Pearson.
- Levitin, D. (2010). *A música no seu cérebro: a ciência de uma obsessão humana*. Rio de Janeiro: Civilização Brasileira.
- Levitin, D. (2015). *A mente organizada: como pensar com clareza na era da sobrecarga de informação*. Rio de Janeiro: Objetiva.
- Li, T., Ogihara, M. & Tzanetakis, G. (2011). *Music Data Mining*. New York: CRC.
- Liu, M.; Hu, X. & Schedl, M. (2018). The relation of culture, socio-economics, and friendship to music preferences: A large-scale, cross-country study. *Plos One*, 13(12), pp. 1-29

- Liljeström, S., Juslin, P. N. & Västfjäll, D. (2013). Experimental evidence of the roles of music choice, social context, and listener personality in emotional reactions to music. *Psychology of Music*, 41(5), pp. 579-599.
- Lima, J. N. F. C. (2009). *Towards Gathering and Mining Last.Fm User-Generated Data*. Dissertação de Mestrado (Informatics and Computing Engineering). Orientador: Prof. Dr. Rui Camacho. Universidade do Porto.
- Martindale, C. (1990). *The Clockwork Muse: The predictability of artistic change*. New York: Basic Books.
- Mayr, E. (2009). *O que é evolução?* São Paulo: Rocco.
- Menezes-Filho, A. P. (2003). *Não-Extensividade Termodinâmica, Invariância Discreta de Escala e Elasto-Plasticidade: Estudo Numérico de um Modelo Geomecânico Auto-Organizado Criticamente*. Tese de doutorado (Programa de Pós-Graduação em Engenharia Civil/PUC-RJ). Orientador: Prof. Dr. Eurípedes do Amaral Vargas Jr. Rio de Janeiro.
- Meyer, L. B. (1956). *Emotion and Meaning in Music*. Chicago: Chicago University Press.
- Mithen, S. (2007). *The Singing Neanderthals: the origins of music, language, mind, and body*. New York: Harvard University Press.
- Morgan, J. P.; MacDonald, R. A. & Pitts, S. E. (2014). “Caught between a scream and a hug”: Women’s perspectives on music listening and interaction with teenagers in the family unit. *Psychology of Music*, 43(5), pp. 611-626.
- Nash Jr., J. F. (1949). Equilibrium points in n-person games. *Proceedings of the National Academy of Sciences*, 36(1), pp. 48-49.
- Nave, G., Minxha, J., Greenberg, D. M., Kosinski, M., Stillwell, D. & Rentfrow, J. (2018). Musical Preferences Predict Personality: Evidence From Active Listening and Facebook Likes. *Psychological Science*, 29(7), pp. 1145-1158.
- Nicolelis, M. (2011). *Muito além do nosso eu*. São Paulo: Companhia das Letras.
- North, A. C. & Hargreaves, D. J. (2008). *The Social and Applied Psychology of Music*. New York: Oxford University Press.
- Olds, J. & Milner, P. (1954). Positive reinforcement produced by electrical stimulation of septal area and other regions of rat brain. *Journal of Comparative and Physiological Psychology*, 47(6), pp. 419-427.
- Oliveira, L. F. (2014). O estudo da música a partir do paradigma dinâmico da cognição. *Percepta*, 2(1), pp. 17-36.

- Pachet, F. (2011). Hit Song Science. In Li, T., Ogiwara, M. & Tzanetakis, G. (2011). *Music Data Mining*. New York: CRC, pp. 305-326.
- Padilha, N. P. (2016). *O ponto focal de Schelling como solução de interação estratégica resultante de múltiplos equilíbrios de Nash*. Monografia (Curso de Bacharelado em Ciências Econômicas). Orientador: Prof. Dr. José Henrique Félix da Silva. Universidade Federal do Ceará. Fortaleza.
- Paluszek, M. & Thomas, S. (2017). *MATLAB Machine Learning*. New Jersey: Apress.
- Panda, R. & Paiva, R. P. (2012). Music Emotion Classification: Dataset Acquisition and Comparative Analysis. In: *Proceedings of the 15th International Conference on Digital Audio Effects (DAFx-12)*, pp. 1-6.
- Peretz, I. (2010). Towards a neurobiology of musical emotions. In Juslin, P. N. & Sloboda, J. A. (orgs.) *Handbook of Music and Emotion: Theory, Research, Applications*. New York: Oxford University Press, pp. 99-126.
- Pimentel, C. E. & Donnely, E. D. O. P. (2008). A relação da preferência musical com os cinco grandes fatores da personalidade. *Psicologia: Ciência e Profissão*, 28(4), 696-713.
- Pimentel, C. E.; Gouveia, V. V.; Coelho-Júnior, L. L.; Aguiar-Athayde, R. A. & Lima, T. J. S. (2014). Preferência musical e busca de sensações entre jovens. *Psicologia: Ciência e Profissão*, 34(1), pp. 4-17.
- Pimentel, C. E.; Gouveia, V. V. & Pessoa, V. S. (2007). Escala de Preferência Musical: construção e comprovação de sua estrutura fatorial. *Psico-USF*, 12(2), pp. 145-155.
- Pimentel, C. E.; Gouveia, V. V.; Santana, N. L.; Chaves, W. A. & Rodrigues, C. A. (2009). Preferência musical e risco de suicídio entre jovens. *Jornal Brasileiro de Psiquiatria*, 58(1), pp. 26-33.
- Pimentel, C. E.; Gouveia, V. V. & Vasconcelos, T. C. (2005). Preferência musical, atitudes e comportamentos anti-sociais entre estudantes adolescentes: um estudo correlacional. *Estudos de Psicologia (Campinas)*, 22(4), pp. 403-413.
- Platz, F. & Kopiez, R. (2013). When the first impression counts: Music performers, audience and the evaluation of stage entrance behaviour. *Musicae Scientiae*, 17(2), pp. 167-197.
- Plutchik, R. (1982). A psychoevolutionary theory of emotions. *Social Science Information*, 21(4-5), pp. 529-553.
- Plutchik, R. (1980). A general psychoevolutionary theory of emotion. In Plutchik, R. & Kellerman, H. (eds.). *Emotion: Theory, Research, and Experience*. New York: Academic Press, pp. 3-33.

- Porcaro, L. & Gómez, E. (2019). A Model for Evaluating Popularity and Semantic Information Variations in Radio Listening Sessions. In Sar Shalom, O.; Jannach, D.; Guy, I. (eds.). *Proceedings of the 1st Workshop on the Impact of Recommender Systems co-located with 13th ACM Conference on Recommender Systems (ACM RecSys 2019)*. Disponível em <<https://repositori.upf.edu/handle/10230/42288>>. Acesso em 24 de janeiro de 2021.
- Porter, A., Bogdanov, D. & Serra, X. (2016). Mining metadata from the web for AcousticBrainz. *Proceedings of the 3rd International Workshop on Digital Libraries for Musicology*. pp. 53-56.
- Quadros-Júnior, J; F. S. & Brito, M. P. (2012). Avaliação de performances por ouvintes: um estudo com estudantes de licenciatura em música da FAMES. *Per Musi*, 26, pp. 110-120.
- Raimond, Y., Abdallah, A., Sandler, M. B. & Giasson, F. (2007). The Music Ontology. *Proceedings of the 8th International Society for Music Information Retrieval Conference*. Disponível em <<http://raimond.me.uk/pubs/Raimond-ISMIR2007-Submitted.pdf>>. Acesso em 20 de fevereiro de 2018.
- Raimond, Y. & Sandler, M. B. (2008). A web of musical information. *Proceedings of the 9th International Society for Music Information Retrieval Conference*. Disponível em <[http://ismir2008.ismir.net/papers/ISMIR2008\\_109.pdf](http://ismir2008.ismir.net/papers/ISMIR2008_109.pdf)>. Acesso em 20 de fevereiro de 2018.
- Ramos, D. (2008). *Fatores emocionais durante uma escuta musical afetam a percepção temporal de músicos e não músicos?* Tese de doutorado (Programa de Pós-Graduação em Psicologia/USP). Orientador: Prof. Dr. José Lino Oliveira Bueno. Ribeirão Preto.
- Ramos, D. & Bueno, J. L. O. (2012). Emoções de uma escuta musical afetam a percepção subjetiva de tempo. *Psicologia: Reflexão e Crítica*, 25(2), pp. 286-292.
- Ramos, D. & Lamur, J. (2015). Respostas emocionais à música variam conforme a metodologia de mensuração empregada: um estudo comparativo entre os testes de escolha forçada e as descrições livres. *Anais do Simpósio Internacional de Cognição e Artes Musicais*. Pirenópolis, pp. 185-193.
- Reeve, J. (2006). *Motivação & emoção*. 4º Ed. São Paulo: LTC.
- Rentfrow, J., Goldberg, L. R. & Levitin, D. (2011). The structure of musical preference: a five-factor model. *Journal of Personality and Social Psychology*, 100(6), pp. 1139-1157.
- Ricklefs, R. E. (2010). *Economia da Natureza*. Rio de Janeiro: Guanabara Koogan.
- Romanelli, G. G. (2019). Entre o digital e o impresso: perspectivas nos manuais e mídias para o ensino de música no Brasil. *Revista Latinoamericana de Tecnología Educativa*, 18(2), pp. 57-67.
- Russel, S. & Norvig, P. (2013). *Inteligência Artificial*. 3ª Ed. Trad.: Regina Célia Simille de Macedo. Rio de Janeiro: Elsevier.

- Russell, J. A. (1980). A circumplex model of affect. *Journal of Personality and Social Psychology*, 39(6), pp. 1161–1178.
- Sanfey, A. G. (2007). Social Decision-Making: Insights from Gaming Theory and Neuroscience. *Science*, 318(5850), pp. 598-602.
- Santini, R. M. & Souza, R. F. Classificação colaborativa de conteúdos não-textuais na internet: as novas formas de mediação e organização da informação da música através da folksonomia. *Anais do XI Encontro Nacional de Pesquisa em Ciência da Informação*. Disponível em <<http://enancib.ibict.br/index.php/enancib/xienancib/schedConf/presentations>>. Acesso em 08 de junho de 2017.
- Schäfer, T. (2008). *Determinants of Music Preference*. Tese de Doutorado. Orientador: Prof. Dr. Peter Sedlmeier. Chemnitz University of Technology.
- Schedl, M.; Gómez, E. & Urbano, J. (2014). Music Information Retrieval: Recent Developments and Applications. *Foundations and Trends in Information Retrieval*, 8(2-3), pp. 127-261.
- Schelling, T. C. (1958). The Strategy of Conflict Prospectus for a Reorientation of Game Theory. *The Journal of Conflict Resolution*, 2(3), pp. 203-264.
- Schubert, E. (2003). Update of the Hevner adjective checklist. *Perceptual Motor Skills*, 96, pp. 1117–1122.
- Schubert, E. (2006). Modeling Perceived Emotion With Continuous Musical Features. *Music Perception*, 21, 4, pp. 561-585.
- Song, Y.; Dixon, S. & Pearce, M. (2012a). A Survey of Music Recommendation Systems and Future Perspectives. *9th International Symposium on Computer Music Modelling and Retrieval (CMMR 2012)*. Disponível em <<https://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.414.6614&rep=rep1&type=pdf>>. Acesso em 24 de janeiro de 2021.
- Song, Y.; Dixon, S. & Pearce, M. (2012b). Evaluation of musical features for emotion classification. *13th International Society for Music Information Retrieval Conference (ISMIR 2012)*. Disponível em <[https://www.researchgate.net/profile/Yading-Song/publication/277715954\\_Evaluation\\_of\\_Musical\\_Features\\_for\\_Emotion\\_Classification/links/557187c408ae7467f72ca201/Evaluation-of-Musical-Features-for-Emotion-Classification.pdf](https://www.researchgate.net/profile/Yading-Song/publication/277715954_Evaluation_of_Musical_Features_for_Emotion_Classification/links/557187c408ae7467f72ca201/Evaluation-of-Musical-Features-for-Emotion-Classification.pdf)>. Acesso em 24 de janeiro de 2021.
- Souza, F. M.; Silva, P. K. O.; Pereira, M. B. & Souza, L. C. (2012). Avaliação do desempenho de estimadores dos parâmetros da distribuição Pareto corrigidos por *Bootstrap*. *Ciência e Natura UFMS*, 34(1), pp. 7-22.
- Swartz, A. (2002). MusicBrainz: A Semantic Web Service. *IEEE Intelligent Systems*, 17(1), pp. 76-77.

- Tagg, P. (2003). Analisando a música popular: teoria, método e prática. *Em Pauta*, 14(23), pp. 5-42.
- Teixeira, J. F. (2011). *Mente, cérebro e cognição*. São Paulo: Vozes.
- Ticianeli, J. G. & Baraúna, M. A. (2002). Teoria da neuromatrix: uma nova abordagem para o entendimento da dor fantasma. *Fisioterapia & Pesquisa*, 9(1), pp. 17-22.
- Toassa, G. (2012). Vigotski contra James-Lange: crítica para uma teoria histórico-cultural das emoções. *Psicologia USP*, 23(1), pp. 91-110.
- Turing, A. (1950). Computing Machinery and Intelligence. *Mind*, 49, pp. 433-460.
- Vasconcellos, A. R.; Rodrigues, C. G. & Luzzi, R. (2015). Complexidade, auto-organização e informação em sistemas dinâmicos. *Rev. Bras. Ens. Fis.*, 37(2), pp. 1-30.
- Van Valen, L. (1973). A new evolutionary law. *Evolutionary Theory*, 1, pp. 1-30.
- Varenne, F. (2009). Models and simulations in the historical emergence of the Science of complexity. In: Aziz-Alaoui, M. A. & Bertelle, C. (eds.). *From System Complexity to Emergent Properties*. New York: Springer, pp 3-21.
- Vernon, D.; Lowe, R.; Thill, S. & Ziemke, T. (2015). Embodied cognition and circular causality: on the role of constitutive autonomy in the reciprocal coupling of perception and action. *Frontiers in Psychology*, 6, pp. 1-9.
- West, A. & Martindale, C. (1996). Creative trends in the content of Beatles lyrics. *Popular Music and Society*, 20(4), pp. 103-125.
- Wheis, C. & Glasmachers, T. (2017). Supervised Classification. In: Wheis, C., Jannach, D., Vatulkin, I. & Rudolph, G. (eds.). *Music Data Analysis: Foundations and Applications*. New York: CRC. pp. 303-327.
- Wheis, C. (2017a). Unsupervised Learning. In: Wheis, C., Jannach, D., Vatulkin, I. & Rudolph, G. (eds.). *Music Data Analysis: Foundations and Applications*. New York: CRC. pp. 283-302.
- Wheis, C. (2017b). Statistical Methods. In: Wheis, C., Jannach, D., Vatulkin, I. & Rudolph, G. (eds.). *Music Data Analysis: Foundations and Applications*. New York: CRC. pp. 217-262.
- Wheis, C., Jannach, D., Vatulkin, I. & Rudolph, G. (2017). *Music Data Analysis: Foundations and Applications*. New York: CRC.
- Yang, Y.-H. & Chen, H. H. (2012). Machine Recognition of Music Emotion: A Review. *ACM Transactions on Intelligent Systems and Technology*, 3(3), pp. 1-30.

Zangerle, E.; Pichl, M.; Hupfauf, B. & Specht, G. (2016). Can microblogs predict music charts? An analysis of the relationship between #nowplaying tweets and music charts. *Proceedings of the 17th International Society for Music Information Retrieval Conference, ISMIR*. Disponível em <<https://www.semanticscholar.org/paper/Can-Microblogs-Predict-Music-Charts-An-Analysis-of-Zangerle-Pichl/b4f0a83229319f6db1c73fe446707a2eb1a05d91>>. Acesso em 25 de janeiro de 2021.

## APÊNDICES

---

## APÊNDICE A

---

### *Goliath Toolbox*

Apresenta-se, a seguir, o código do Goliath Toolbox, em escrito em linguagem Matlab.

```

function [] = ArtInfo(art_mbid,art_name)
%ARTINFO Artist Information
%
%ArtInfo() returns a struct with data of a single artist retrieved from
%MusicBrainz Database.
%
%Variables:
%art_mbid - the artist mbid identifier. See <https://musicbrainz.org>.
%art_name - the artist name.
%
%Example:
%ArtInfo('0ab49580-c84f-44d4-875f-d83760ea2cfe','Maroon 5')
%
%See also TrInfoMB, TrInfoLFM
%

url_art='https://musicbrainz.org/ws/2/artist/';
url_art_compl='?inc=aliases&fmt=json';

url=strcat(url_art,art_mbid,url_art_compl);

    try
        res=webread(url);
        disp(res);
        save((strcat('ArtInfo_',art_name)), 'res');
    catch ME
        warning('PAGE NOT FOUND!')
    end

end

```

```

function [] = geochart(AK,pg,n, country)
%GEOCHART Geo Chart
%
%geochart() returns a struct with the rank of musical preference of Last.Fm us-
ers by country.
%
%Variables:
%AK - User Last.Fm API Key. See <https://last.fm/api>.
%pg - number of pages (min. 2).
%n - number of results per page (max. 99).
%country - country name in string (compound nouns are in format
%'nnnn+nnnn' - example 'united+states').
%
%Example:
%geochart(AK,5,10,'brazil')
%
%See also glochart.
%

h = waitbar(0,'Retrieving data from Last.Fm...');

n=string(n);
country=string(country);
url_charts=strcat('http://ws.audioscrobbler.com/2.0/?method=geo.gettop-
tracks&country=',country,'&api_key=');
url_charts_comp=strcat('&format=json&limit=',n,'&page=');

url_str=string();

for i=1:pg

    url=strcat(url_charts,AK,url_charts_comp,(num2str(i)));
    url_str=vertcat(url_str,url);

end

Tracks=table;
Artists=table;

for i=2:pg
    url_temp=url_str(i,1);
    try
        response=webread(url_temp);
        tab_tr=struct2table(response.tracks.track);
        temp_tab_art=struct2table(tab_tr.artist);
        Tracks=vertcat(Tracks,tab_tr);
        Artists=vertcat(Artists,temp_tab_art);
    catch ME
        disp(url_temp)
        warning('PAGE NOT FOUND!');

    end

    pause(15);
    waitbar(i/pg,h)

end

tab_art=unique(Artists,'stable');
mbid_name=Tracks.name;
mbid_mbid=Tracks.mbid;

```

```
mbid=mbid_mbid(~cellfun('isempty',mbid_mbid));
tracks_mbid=horzcat(mbid_name,mbid_mbid);
tracks_mbid=tracks_mbid(~cellfun(@isempty, tracks_mbid(:,2)), :);
save((strcat((string(country)),'-tracks-',(string(datetime('today'))))), 'Tracks');
save((strcat((string(country)),'-artists-',(string(datetime('today'))))), 'tab_art');
save((strcat((string(country)),'-tracks-mbid-',(string(datetime('today'))))), 'tracks_mbid');

delete(h)

end
```

```

function [] = glochart(AK,pg,n)
%GLOCHART Global Chart
%
%glochart() returns a struct with the rank of musical preference of Last.Fm users.
%
%Variables:
%AK - User Last.Fm API Key. See <https://last.fm/api>.
%pg - number of pages (min. 2).
%n - number of results per page (max. 99).
%
%Example:
%glochart(AK,5,10)
%
%See also geochart.
%
%
h = waitbar(0,'Retrieving data from Last.Fm...');

n=string(n);
url_charts='http://ws.audioscrobbler.com/2.0/?method=chart.gettop-tracks&api_key=';
url_charts_comp=strcat('&format=json&limit=',n,'%page=');

url_str=string();

for i=1:pg

    url=strcat(url_charts,AK,url_charts_comp,(num2str(i)));
    url_str=vertcat(url_str,url);

end

Tracks=table;
Artists=table;

for i=2:pg
    url_temp=url_str(i,1);
    try
        response=webread(url_temp);
        tab_tr=struct2table(response.tracks.track);
        temp_tab_art=struct2table(tab_tr.artist);
        Tracks=vertcat(Tracks,tab_tr);
        Artists=vertcat(Artists,temp_tab_art);
    catch ME
        disp(url_temp)
        warning('PAGE NOT FOUND!');

    end

    pause(10);
    waitbar(i/pg,h)

end

tab_art=unique(Artists,'stable');
mbid_name=Tracks.name;
mbid_mbid=Tracks.mbid;
mbid=mbid_mbid(~cellfun('isempty',mbid_mbid));
tracks_mbid=horzcat(mbid_name,mbid_mbid);
tracks_mbid=tracks_mbid(~cellfun(@isempty, tracks_mbid(:,2)), :);

```

```
save((strcat('tracks-',(string(datetime('today'))))), 'Tracks');  
save((strcat('artists-',(string(datetime('today'))))), 'tab_art');  
save((strcat('tracks-mbid-',(string(datetime('today'))))), 'tracks_mbid');  
  
delete(h)  
  
end
```

```

function [] = highM(filename,n)
%HIGHM High-level Data of Multiple Tracks
%
%highM() returns a struct with high-level data from AcousticBrainz.
%
%Variables:
%file - a cell array save into a Matlab file (*.mat) with the name and the
%mbid of tracks.
%n - number of results (max. number of rows of file).
%
%Example:
%highM('Tracks-mbid-24-Aug-2018.mat',50)
%
%See also highS, lowM, lowS, tabhigh.
%
%
h=waitbar(0,'Retrieving high-level data from Acoustic Brainz...');

url_ab = 'https://acousticbrainz.org/api/v1/';
url_ab_hl = '/high-level';

data=importdata(filename);
data=string(data);
mbid=data(1:n,2);
ns=data(1:n,1);
url=strcat(url_ab,mbid,url_ab_hl);

Files=table;

for i=1:n
    name=ns(i,1);
    url_temp=url(i,1);
    pause(2);
    try
        res_high=webread(url_temp);
        save((strcat('ac_feat_high_',name)), 'res_high');
        file_name=table(strcat('ac_feat_high_',name, '.mat'));
        Files=vertcat(Files,file_name);
    catch ME
        disp(name)
        disp(url_temp)
        warning('PAGE NOT FOUND!')
    end
    end
    waitbar(i/n,h)

end

save('high_files','Files');

delete(h)

end

```

```

function [] = highS(tr_mbid, tr_name)

%HIGHS High-level Data of a Single Track
%
%highS() returns a struct with high-level data of a single track from Acoustic-
Brainz.
%
%Variables:
%mbid - the mbid identifier of a single track.
%tr_name - track's name.
%
%Example:
%highS('d0b884c8-6100-4ca2-855f-5ef27d963807','Africa')
%
%See also highM, lowM, lowS, tabhigh.
%
%
url_ab = 'https://acousticbrainz.org/api/v1/';
url_ab_hl = '/high-level';

url=strcat(url_ab, tr_mbid, url_ab_hl);

try
    res_high=webread(url);
    save((strcat('ac_feat_high_', tr_name)), 'res_high');
catch ME
    warning('PAGE NOT FOUND!')
end

end

```

```

function [] = lowM(filename,n)
%LOWM Low-level Data of Multiple Tracks
%
%lowM() returns a struct with a low-level data from AcousticBrainz.
%
%Variables:
%file - a cell array save into a Matlab file (*.mat) with the name and the
%mbid of tracks.
%n - number of results (max. number of rows of file).
%
%Example:
%lowM('Tracks-mbid-24-Aug-2018.mat',50)
%
%See also lowS, highM, highS, tablow.
%
%
h=waitbar(0,'Retrieving low-level data from Acoustic Brainz...');

url_ab = 'https://acousticbrainz.org/api/v1/';
url_ab_ll = '/low-level';

data=importdata(filename);
data=string(data);
mbid=data(1:n,2);
ns=data(1:n,1);
url=strcat(url_ab,mbid,url_ab_ll);

Files=table;

for i=1:n
    name=ns(i,1);
    url_temp=url(i,1);
    pause(2);
    try
        res_low=webread(url_temp);
        save((strcat('ac_feat_low_',name)), 'res_low');
        file_name=table(strcat('ac_feat_low_',name, '.mat'));
        Files=vertcat(Files,file_name);
    catch ME
        disp(name)
        disp(url_temp)
        warning('PAGE NOT FOUND!')
    end
    waitbar(i/n,h)

end

save('low_files','Files');

delete(h)

end

```

```

function [] = lowS(tr_mbid, tr_name)
%LOWS Low-level Data of a Single Track
%lowS() returns a struct with low-level data of a single track from Acoustic-
Brainz.
%
%Variables:
%mbid - the mbid identifier of a single track.
%tr_name - track's name.
%
%Example:
%lowS('d0b884c8-6100-4ca2-855f-5ef27d963807','Africa')
%
%See also lowM, highM, highS, tablow.
%
%
url_ab = 'https://acousticbrainz.org/api/v1/';
url_ab_ll = '/low-level';

url=strcat(url_ab, tr_mbid, url_ab_ll);

try
    res_low=webread(url);
    save((strcat('ac_feat_low_', tr_name)), 'res_low');
catch ME
    warning('PAGE NOT FOUND!')
end

end

```



```

tronic.all.house,res_high.highlevel.genre_electronic.all.techno,res_high.high-
level.genre_electronic.all.trance,res_high.highlevel.genre_rosa-
merica.all.cla,res_high.highlevel.genre_rosamerica.all.dan,res_high.high-
level.genre_rosamerica.all.hip,res_high.highlevel.genre_rosa-
merica.all.jaz,res_high.highlevel.genre_rosamerica.all.pop,res_high.high-
level.genre_rosamerica.all.rhy,res_high.highlevel.genre_rosa-
merica.all.roc,res_high.highlevel.genre_rosamerica.all.spe,res_high.high-
level.genre_tzanetakis.all.blu,res_high.highlevel.genre_tzane-
takis.all.cla,res_high.highlevel.genre_tzanetakis.all.cou,res_high.high-
level.genre_tzanetakis.all.dis,res_high.highlevel.genre_tzane-
takis.all.hip,res_high.highlevel.genre_tzanetakis.all.jaz,res_high.high-
level.genre_tzanetakis.all.met,res_high.highlevel.genre_tzane-
takis.all.pop,res_high.highlevel.genre_tzanetakis.all.reg,res_high.high-
level.genre_tzanetakis.all.roc,res_high.highlevel.is-
mir04_rhythm.all.ChaChaCha,res_high.highlevel.is-
mir04_rhythm.all.Jive,res_high.highlevel.ismir04_rhythm.all.Quick-
step,res_high.highlevel.ismir04_rhythm.all.Rumba_American,res_high.highlevel.is-
mir04_rhythm.all.Rumba_International,res_high.highlevel.is-
mir04_rhythm.all.Rumba_Misc,res_high.highlevel.is-
mir04_rhythm.all.Samba,res_high.highlevel.is-
mir04_rhythm.all.Tango,res_high.highlevel.is-
mir04_rhythm.all.VienneseWaltz,res_high.highlevel.is-
mir04_rhythm.all.Waltz,res_high.highlevel.mood_acoustic.all.acous-
tic,res_high.highlevel.mood_acoustic.all.not_acoustic,res_high.high-
level.mood_aggressive.all.aggressive,res_high.highlevel.mood_aggres-
sive.all.not_aggressive,res_high.highlevel.mood_electronic.all.elec-
tronic,res_high.highlevel.mood_electronic.all.not_electronic,res_high.high-
level.mood_happy.all.happy,res_high.high-
level.mood_happy.all.not_happy,res_high.high-
level.mood_party.all.party,res_high.high-
level.mood_party.all.not_party,res_high.highlevel.mood_relaxed.all.re-
laxed,res_high.highlevel.mood_relaxed.all.not_relaxed,res_high.high-
level.mood_sad.all.sad,res_high.highlevel.mood_sad.all.not_sad,res_high.high-
level.moods_mirex.all.Cluster1,res_high.highlevel.moods_mirex.all.Clus-
ter2,res_high.highlevel.moods_mirex.all.Cluster3,res_high.high-
level.moods_mirex.all.Cluster4,res_high.highlevel.moods_mirex.all.Clus-
ter5,res_high.highlevel.timbre.all.bright,res_high.highlevel.tim-
bre.all.dark,res_high.highlevel.tonal_atonal.all.tonal,res_high.highlevel.to-
nal_atonal.all.atonal,res_high.highlevel.voice_instrumen-
tal.all.voice,res_high.highlevel.voice_instrumental.all.instrumental};
    tab_temp=cell2table(cell_temp);
    tab_temp.Properties.VariableNames={'name' 'Artist' 'Danceable'
'Not_danceable' 'Male' 'Female' 'Genre_Dortmund_Alternative' 'Genre_Dort-
mund_Blues' 'Genre_Dortmund_Electronic' 'Genre_Dortmund_Folkcountry'
'Genre_Dortmund_FunkSoulRnB' 'Genre_Dortmund_Jazz' 'Genre_Dortmund_Pop'
'Genre_Dortmund_RapHipHop' 'Genre_Dortmund_Rock' 'Genre_Electronic_Ambient'
'Genre_Electronic_DnB' 'Genre_Electronic_House' 'Genre_Electronic_Techno'
'Genre_Electronic_Trance' 'Genre_Rosamerica_Cla' 'Genre_Rosamerica_Dan'
'Genre_Rosamerica_Hip' 'Genre_Rosamerica_Jaz' 'Genre_Rosamerica_Pop'
'Genre_Rosamerica_Rhy' 'Genre_Rosamerica_Roc' 'Genre_Rosamerica_Spe'
'Genre_Tzanetakis_Blu' 'Genre_Tzanetakis_Cla' 'Genre_Tzanetakis_Cou'
'Genre_Tzanetakis_Dis' 'Genre_Tzanetakis_Hip' 'Genre_Tzanetakis_Jaz'
'Genre_Tzanetakis_Met' 'Genre_Tzanetakis_Pop' 'Genre_Tzanetakis_Reg'
'Genre_Tzanetakis_Roc' 'ISMIR_Rhythm_ChaChaCha' 'ISMIR_Rhythm_Jive' 'IS-
MIR_Rhythm_Quickstep' 'ISMIR_Rhythm_Rumba_American' 'ISMIR_Rhythm_Rumba_Interna-
tional' 'ISMIR_Rhythm_Rumba_Misc' 'ISMIR_Rhythm_Samba' 'ISMIR_Rhythm_Tango' 'IS-
MIR_Rhythm_VienneseWaltz' 'ISMIR_Rhythm_Waltz' 'Mood_Acoustic' 'Mood_Not_Acous-
tic' 'Mood_Aggressive' 'Mood_Not_Aggressive' 'Mood_Electronic' 'Mood_Not_Elec-
tronic' 'Mood_Happy' 'Mood_Not_Happy' 'Mood_Party' 'Mood_Not_Party' 'Mood_Re-
laxed' 'Mood_Not_Relaxed' 'Mood_Sad' 'Mood_Not_Sad' 'Mood_MIREX_Cluster1'
'Mood_MIREX_Cluster2' 'Mood_MIREX_Cluster3' 'Mood_MIREX_Cluster4'
'Mood_MIREX_Cluster5' 'Timbre_Bright' 'Timbre_Dark' 'Tonal' 'Atonal' 'Voice'
'Instrumental'};

```

```
        HighLevelData=vertcat(HighLevelData,tab_temp);
    catch
        disp(filename)
        warning('An error was occurred!')
    end

    waitbar(i/n,h)

end

save('HighLevelData','HighLevelData');

display(HighLevelData)

delete(h)

end
```

```

function [] = tablow(filename)
%TABLOW Low-level Data Tab
%
%Variables:
%filename - a cell array save into a Matlab file (*.mat) with the name of all
%tracks into the dataset.
%
%Example:
%tablow('low_files.mat')
%
%See also lowS, lowM, tabhigh.
%
%
h=waitbar(0,'Wait please...');

data=importdata(filename);
n=size(data,1);

LowLevelData=table(1,1,1,1,1,1,1,1,1,1,1,1,1,1);
LowLevelData.Properties.VariableNames={'name' 'Artist' 'Genre' 'Av_Loudness'
'Dissonance' 'Pitch_Salience' 'Beats_Count' 'bpm' 'Danceability' 'Key'
'Key_Scale' 'Chords_Key' 'Chords_Scale' 'Chords_Change_Rate'};
LowLevelData(1,:)=[];

for i=1:n
    filename=data(i,1);
    filename=table2array(filename);
    try
        load(filename);
        cell_temp={res_low.metadata.tags.title,res_low.metadata.tags.art-
ist,res_low.metadata.tags.genre,res_low.lowlevel.average_loudness,res_low.low-
level.dissonance.mean,res_low.lowlevel.pitch_sali-
ence.mean,res_low.rhythm.beats_count,res_low.rhythm.bpm,res_low.rhythm.dancea-
bility,res_low.tonal.key_key,res_low.tonal.key_scale,res_low.to-
nal.chords_key,res_low.tonal.chords_scale,res_low.tonal.chords_changes_rate};
        tab_temp=cell2table(cell_temp);
        tab_temp.Properties.VariableNames={'name' 'Artist' 'Genre' 'Av_Loudness'
'Dissonance' 'Pitch_Salience' 'Beats_Count' 'bpm' 'Danceability' 'Key'
'Key_Scale' 'Chords_Key' 'Chords_Scale' 'Chords_Change_Rate'};
        LowLevelData=vertcat(LowLevelData,tab_temp);
    catch
        disp(filename)
        warning('An error was occurred!')
    end

    waitbar(i/n,h)

end

save('LowLevelData','LowLevelData');

display(LowLevelData)

delete(h)

end

```

```

function [] = TrInfoLFM(AK,tr_name,art_name)
%TRINFOLFM Track Information (Last.FM API)
%
%TrInfoLFM() returns a struct with data of a single track retrieved from
%Last.Fm API.
%
%Variables:
%AK - User Last.Fm API Key. See <https://last.fm/api>.
%tr_name - track's name.
%art_name - the artist name.
%
%Example:
%TrInfoLFM(AK,'Bitter Sweet Symphony','The Verve')
%
%See also TrInfoMB, ArtInfo.
%
%
url_tracks='http://ws.audioscrobbler.com/2.0/?method=track.search&track=';
url_tracks_AK='&api_key=';
url_tracks_artist='&artist=';
url_tracks_compl='&format=json';

url=strcat(url_tracks,tr_name,url_tracks_AK,AK,url_tracks_art-
ist,art_name,url_tracks_compl);
    try
        res=webread(url);
    catch ME
        warning('PAGE NOT FOUND!')
    end

    disp(res);
    save((strcat('TrInfoLFM_',tr_name)), 'res');

end

```

```

function [] = TrInfoMB(tr_mbid,tr_name)
%TRINFOMB Track Information (MusicBrainz Database)
%
%TrInfoMB() returns a struct with data of a single track retrieved from
%MusicBrainz Database.
%
%Variables:
%tr_mbid - track's mbid identifier. See <https://musicbrainz.org>.
%tr_name -track's name.
%
%Example:
%TrInfoMB('8b6d9029-1990-4660-bd57-24b5bc0fb626','Bitter Sweet Symphony')
%
%See also TrInfoLFM, ArtInfo.
%
%
url_tr='https://musicbrainz.org/ws/2/recording/';
url_tr_compl='?inc=aliases&fmt=json';

url=strcat(url_tr,tr_mbid,url_tr_compl);

    try
        res=webread(url);
        disp(res);
        save((strcat('TrInfoMB_',tr_name)), 'res');
    catch ME
        warning('PAGE NOT FOUND!')
    end
end
end

```

## **APÊNDICE B**

---

### **Tutorial**

**Goliath**  
**Tutorial**

## SUMÁRIO

**APRESENTAÇÃO, 154**

**WEB SERVICES, 154**

*Last.Fm API, 155*

*Passo-a-passo para obter uma API Key na Last.Fm API, 155*

*MetaBrainz Foundation, 156*

**MATLAB<sup>®</sup>, 157**

**INSTALAÇÃO, 158**

**FUNÇÕES, 160**

**COMO CITAR, 167**

**REFERÊNCIAS, 168**

**SITES RECOMENDADOS, 168**

## APRESENTAÇÃO

**Goliath** consiste em um conjunto de funções desenvolvidas e implementadas em MATLAB® R2017b com o objetivo de extrair dados musicais através de serviços disponibilizados pela Internet. Este tipo de aplicação é denominado web crawler, web spider ou bot. Seu nome deriva da aranha-golias (*Theraphosa blondi*), uma das maiores espécies de aracnídeos endêmica da região amazônica.

A versão atual (1.0) foi desenvolvida no contexto de uma pesquisa de doutorado realizada no Programa de Pós-Graduação em Música da Universidade Federal do Paraná, sob orientação do Prof. Dr. Danilo Ramos, abrangendo consultas a banco de dados da Last.Fm e da MetaBrainz Foundation.

Neste Guia do Usuário apresentamos uma breve introdução ao **Goliath** para facilitar sua utilização na pesquisa em música e ciência de dados, em especial na concepção de rotinas de mineração e recuperação de informações musicais.

## WEB SERVICES

Web Services são definidos como um conjunto de tecnologias que permitem a comunicação interativa entre diversas aplicações da rede mundial de computadores através de um protocolo HTTP. **Goliath** estabelece uma comunicação com *web services* baseada em REST (*representational state transfer*) empregando o método GET. Com efeito, os dados são recuperados pelo cliente através da internet e armazenados em tabelas no formato \*.m compatíveis com o MATLAB® e de fácil manuseio pelo usuário, podendo, inclusive, serem exportadas para formatos como \*.xlsx utilizando outros *toolboxes* (a exemplo do *Spreadsheet Link*).

Em geral, estes dados correspondem a informações sobre músicas e artistas, abrangendo popularidade, preferência musical e características sonoras das faixas disponibilizadas pela Last.Fm API e pela MetaBrainz Foundation.

### ***Last.Fm API***

Last.Fm é uma rede social baseada em um sistema de recomendação musical. Usuários cadastrados na rede podem fazer o *download* do aplicativo Audioscrobbler, que coleta informações sobre os hábitos de escuta musical em diferentes dispositivos (computador, celular ou tablet) interagindo com diversos serviços de *streaming*, como Spotify, Deezer e Google Play Music, dentre outros.

A rede oferece uma API (*application programming interface*) que permite o acesso a informações sobre a popularidade e a preferência de artistas e faixas, bem como informações sobre usuários específicos e as tags utilizadas para indexar os conteúdos (cf. Bezerra, Guerra & Silva 2017). Para tanto, o desenvolvedor deve possuir uma conta de usuário e solicitar uma chave de acesso (API Key) que será necessária para identificar a aplicação de solicitação.

### ***Passo-a-passo para obter uma API Key na Last.Fm API***

1. Acesse <<https://last.fm/>> e crie uma conta de usuário;
2. Faça o login e acesse <<https://last.fm/api/account/create/>>;

3. Preencha com as informações solicitadas. No campo “*Application name*”, recomenda-se a inclusão do título público do projeto. Não é necessário preencher os campos “*Callback URL*” e “*Application homepage*”.

4. A API Key fornecida contém uma sequência de 32 caracteres. Guarde-a no seu computador em um local de fácil acesso. Para uso do **Goliath**, recomenda-se o seguinte procedimento:

4.1 Abra o MATLAB®;

4.2 Acesse a pasta onde o **Goliath** encontra-se instalado;

4.3 Digite o seguinte comando, substituindo a sequência do exemplo pela API Key do usuário:

```
AK=string('1111aaaa2222bbbb3333cccc4444dddd');  
save(AK);  
rehash toolboxcache;
```

Nota: Após salvar o arquivo AK.mat no diretório do **Goliath**, a API Key se encontrará vinculada à instalação do *toolbox*.

### ***MetaBrainz Foundation***

MetaBrainz Foundation é uma iniciativa criada para subsidiar o MusicBrainz e os demais projetos correlatos. Criado em 2000 por Robert Kaye, MusicBrainz consiste em uma enciclopédia

musical aberta cujo objetivo é armazenar a maior quantidade possível de metadados editoriais através da utilização de identificadores específicos (MusicBrainz Identifiers ou simplesmente mbid).

De forma complementar, outros projetos têm sido desenvolvidos no âmbito da MetaBrainz Foundation procurando ampliar a disponibilidade de dados musicais públicos, a exemplo do AcousticBrainz, que consiste em um banco de dados de alta disponibilidade sobre características sonoras de obras musicais (garantindo ao pesquisador, portanto, a possibilidade de analisar grandes conjuntos de dados sem infringir questões legais de direitos autorais).

Os identificadores mbid são utilizados por todas as iniciativas da MetaBrainz Foundation, incluindo MusicBrainz e AcousticBrainz, assim como compartilhados com outras plataformas digitais - como Spotify e Last.Fm. Deste modo, são estes identificadores que permitem a **Goliath** integrar as requisições a partir de diferentes instâncias.

## MATLAB<sup>®</sup>

MATLAB<sup>®</sup> é um software de computação científica baseado em uma linguagem de programação própria (chamada MATLAB ou apenas m) originalmente voltado para a solução de problemas matemáticos.

A interface gráfica do MATLAB<sup>®</sup> inclui um ambiente de desenvolvimento (IDE) que permite ao programador escrever e executar linhas de código para a resolução de problemas na área de engenharia, psicologia, neurociências e biologia, dentre outras. Atualmente, MATLAB<sup>®</sup> suporta uma grande variedade de aplicações, como aprendizado de máquina e *deep learning*, processamento de sinais, robótica e sistemas embarcados.

Os pacotes de funções desenvolvidos para solucionar problemas específicos são denominados *toolboxes*. Em música, por exemplo, o grupo de pesquisadores liderados por Olivier Lartillot no âmbito do projeto Brain Tuning apresentou o MIRToolbox destinado especialmente ao processamento digital de sinais sonoros no contexto da recuperação de informações musicais (Lartillot, Toiviainen & Eerola, 2007).

**Goliath**, por sua vez, se constitui a partir de um conjunto de funções destinadas exclusivamente à recuperação de dados musicais públicos constantes em bases de dados da Last.Fm e Meta-Brainz Foundation, com potencial aplicação em estudos relacionados à mineração de dados, à cognição musical e à etnografia digital.

Para informações, download e instruções a respeito da instalação e uso do MATLAB<sup>®</sup>, acesse <<https://www.mathworks.com/>>.

## INSTALAÇÃO

Para *download* através do GitHub:

1. Acesse <<https://github.com/eldergomes/goliath>> e faça download da pasta ZIP contendo os arquivos do **Goliath**;
2. Extraia a pasta em seu computador, certificando-se de salvá-la com o nome “goliath”;
3. Copie e cole a pasta /goliath para o diretório de instalação dos *toolboxes* do MATLAB<sup>®</sup> (ex. C:/Program Files/MATLAB/R2017b/toolbox);

4. Abra o MATLAB®;

5. Clique em "Set Path" e "Add Folder";

6. Selecione a pasta que você acabou de mover e clique em "Save";

7. No terminal de comando, digite:

```
help goliath
```

Nota: se a instalação estiver correta, aparecerá uma mensagem com informações da versão instalada e das funções disponíveis.

Para *download* através do repositório File Exchange:

1. Abra o MATLAB®;

2. Clique em "Add-ons" e, em seguida, "Get add-ons";

3. Faça uma busca por **Goliath**;

4. Abra a página do *toolbox* e clique em "Install" e novamente "Install";

5. Na caixa de diálogo, clique em "Agree";

6. Quando o *download* e a instalação se encerrarem, feche a janela do File Exchange;

7. No terminal do MATLAB<sup>®</sup>, digite:

```
help goliath
```

Nota: se a instalação estiver correta, aparecerá uma mensagem com informações da versão instalada e das funções disponíveis.

## FUNÇÕES

### 1. ARTINFO (MUSICBRAINZ DATABASE)

**Descrição:** Recupera informações disponíveis no MusicBrainz Database sobre um artista específico.

**Sintaxe:**

```
ArtInfo(art_mbid, art_name)
```

**Variáveis:**

art\_mbid – identificador mbid associado ao artista;

art\_name – nome do artista.

## 2. TRINFO (MUSICBRAINZ DATABASE)

**Descrição:** Recupera informações disponíveis no MusicBrainz Database sobre uma faixa específica.

**Sintaxe:**

TrInfoAB(tr\_mbid, tr\_name)

**Variáveis:**

tr\_mbid – identificador mbid associado à faixa;

tr\_name – título da faixa.

## 3. TRINFO (LAST.FM API)

**Descrição:** Recupera informações disponíveis na Last.Fm API sobre uma faixa específica.

**Sintaxe:**

TrInfoLFM(AK, tr\_name, art\_name)

**Variáveis:**

AK – API Key do usuário;

tr\_name – título da faixa;

art\_name – nome do artista.

#### 4. GEOCHART

**Descrição:** Recupera informações disponíveis na Last.Fm sobre a preferência musical dos usuários de um país.

**Sintaxe:**

geochart(AK, pg, n, country)

**Variáveis:**

AK – API Key do usuário;

pg – número de páginas consultadas (mín. 2);

n – número de resultados por página (máx. 99);

country – nome do país (string) informado em língua inglesa (nomes compostos devem ser informados no formato “nnnnn+nnnnn” – por exemplo, “united+states”).

#### 5. GLOCHART

**Descrição:** Recupera informações disponíveis na Last.Fm sobre a preferência musical global, incluindo todos os usuários da rede social.

**Sintaxe:**

glochart(AK, pg, n)

**Variáveis:**

AK – API Key do usuário;

pg – número de páginas consultadas (mín. 2);

n – número de resultados por página (máx. 99).

## 6. LOWS

**Descrição:** Recupera informações disponíveis na plataforma AcousticBrainz sobre as características sonoras de baixo nível (low-level) de uma faixa específica. Equivale a highS().

**Sintaxe:**

lowS(tr\_mbid, tr\_name)

**Variáveis:**

tr\_mbid – identificador mbid associado à faixa;

tr\_name – título da faixa.

## 7. LOWM

**Descrição:** Recupera informações disponíveis na plataforma AcousticBrainz sobre as características sonoras de baixo nível (low-level) de múltiplas faixas. Equivale a highM().

**Sintaxe:**

```
lowM(filename, n)
```

**Variáveis:**

filename – arquivo contendo a tabela com os nomes e os identificadores das faixas cujas informações serão requisitadas (obs.: este arquivo é gerado automaticamente como resultado das funções geochart() e glochart(), nomeado como “Tracks-mbid-DD-MMM-AAAA.mat”, onde DD representa o dia, MMM o mês e AAAA o ano em que a requisição foi realizada; entretanto, o usuário pode criar manualmente sua própria tabela e salvá-la na pasta de trabalho, observando que os títulos das faixas devem se manter na primeira coluna e os identificadores mbid na segunda);

n – número de instâncias consultadas no interior da tabela (por exemplo, quando n = 50, lowM() buscará informações das primeiras 50 entradas da tabela, descartando as demais).

## 8. HIGHS

**Descrição:** Recupera informações disponíveis na plataforma AcousticBrainz sobre as características sonoras de alto nível (high-level) de uma faixa específica. Equivale a lowS().

**Sintaxe:**

```
highS(tr_mbid, tr_name)
```

**Variáveis:**

tr\_mbid – identificador mbid associado à faixa;

tr\_name – título da faixa.

## 9. HIGHM

**Descrição:** Recupera informações disponíveis na plataforma AcousticBrainz sobre as características sonoras de alto nível (high-level) de múltiplas faixas. Equivale a lowM().

**Sintaxe:**

highM(filename, n)

**Variáveis:**

filename – arquivo contendo a tabela com os nomes e os identificadores das faixas cujas informações serão requisitadas (obs.: este arquivo é gerado automaticamente como resultado das funções geochart() e glochart(), nomeado como “Tracks-mbid-DD-MMM-AAAA.mat”, onde DD representa o dia, MMM o mês e AAAA o ano em que a requisição foi realizada; entretanto, o usuário pode criar manualmente sua própria tabela e salvá-la na pasta de trabalho, observando que os títulos das faixas devem se manter na primeira coluna e os identificadores mbid na segunda);

n – número de instâncias consultadas no interior da tabela (por exemplo, quando n = 50, lowM() buscará informações das primeiras 50 entradas da tabela, descartando as demais).

## 10. TABLOW

**Descrição:** Tabulação dos aspectos sonoros de baixo nível (low-level). Equivale a tabhigh().

**Sintaxe:**

```
tablow(filename)
```

**Variáveis:**

filename - arquivo contendo a tabela com a lista de nomes de arquivos gerados durante a requisição de dados de baixo nível (a função lowM() gera automaticamente o arquivo “low\_files.mat” com esta finalidade; o usuário pode alterar a estrutura do arquivo, retirando ou adicionando os nomes dos arquivos onde se encontram os dados low-level desejados).

## 11. TABHIGH

**Descrição:** Tabulação dos aspectos sonoros de baixo nível (low-level). Equivale a tablow().

**Sintaxe:**

```
tabhigh(filename)
```

**Variáveis:**

filename - arquivo contendo a tabela com a lista de nomes de arquivos gerados durante a requisição de dados de baixo nível (a função highM() gera automaticamente o arquivo “high\_files.mat” com esta finalidade; o usuário pode alterar a estrutura do arquivo, retirando ou adicionando os nomes dos arquivos onde se encontram os dados high-level desejados).

## COMO CITAR

Silva, E. G. (2021). *Preferência e emoção em ambientes de escuta musical mediados pela tecnologia*. Tese de Doutorado (Universidade Federal do Paraná, Programa de Pós-Graduação em Música). Orientador: Prof. Dr. Danilo Ramos. Curitiba.

## REFERÊNCIAS

Bezerra, D. M., Guerra, M. A.; Silva, E. G. (2017). Preferência musical em sistemas de recomendação baseados em folksonomia: tendências de usuários brasileiros da rede Last.Fm. *Revista da ABEM*, 25(37).

Lartillot, O.; Toiviainen, P.; Eerola, T. A (2007). Matlab Toolbox for Music Information Retrieval. In Preisach, C.; Burkhardt, H.; Schmidt-Thieme, L.; Decker, R. (orgs.). *Data Analysis, Machine Learning and Applications* - Proceedings of the 31st Annual Conference of the Gesellschaft für Klassifikation. Berlin: Springer-Verlag.

## SITES RECOMENDADOS

### **Grupo de Pesquisa Música e Expertise – GRUME (UFPR)**

<<https://grumeufpr.wordpress.com/>>

### **Last.Fm**

<<https://www.last.fm/>>

### **MetaBrainz Foundation**

<<https://metabrainz.org/>>

### **MusicBrainz**

<<https://musicbrainz.org/>>

### **AcousticBrainz**

<<https://acousticbrainz.org/>>

### **MathWorks Inc.**

<<https://www.mathworks.com/>>

