



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

Daniel Gondim Ernesto de Mélo

**Explorando a Importância da Personalização na
Criação de Playlists**

Campina Grande – PB

2020

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

Explorando a Importância da Personalização na Criação de Playlists

Daniel Gondim Ernesto de Mélo

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

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

Nazareno Ferreira de Andrade
(Orientador)

Campina Grande, Paraíba, Brasil

©Daniel Gondim Ernesto de Mélo, 02/03/2020

M528e Mélo, Daniel Gondim Ernesto de.
Explorando a importância da personalização na criação de playlists /
Daniel Gondim Ernesto de Mélo. – Campina Grande, 2020.
86 f. : il. color.

Tese (Doutorado em Ciência da Computação) – Universidade Federal
de Campina Grande, Centro de Engenharia Elétrica e Informática, 2020.
"Orientação: Prof. Dr. Nazareno Ferreira de Andrade".
Referências.

1. Computação e Música. 2. Computação - Metodologia e Técnicas.
3. Músicas para Relaxamento. 4. Música – Playlists – Personalização.
I. Andrade, Nazareno Ferreira de. II. Título.

CDU 004.4:78(043)

**EXPLORANDO A IMPORTÂNCIA DA PERSONALIZAÇÃO NA CRIAÇÃO DE
PLAYLISTS**

DANIEL GONDIM ERNESTO DE MÉLO

TESE EM EXIGÊNCIA EM 09/03/2020

**NAZARENO FERREIRA DE ANDRADE, Dr., UFCG
Orientador(a)**

**CLÁUDIO ELÍZIO CALAZANS CAMPELO, PhD., UFCG
Examinador(a)**

**LEANDRO BALBY MARINHO, Dr., UFCG
Examinador(a)**

**GIORDANO RIBEIRO EULALIO CABRAL, Dr., UFPE
Examinador(a)**

**FLAVIO VINICIUS DINIZ DE FIGUEIREDO, Dr., UFMG
Examinador(a)**

CAMPINA GRANDE - PB

Resumo

Muitas vezes ouvir música não é apenas um hobby, ou uma atividade de lazer, mas sim uma maneira de alcançar um certo estado emocional ou psicológico, ou mesmo de realizar mais facilmente, ou melhor, uma atividade, e.g. relaxar. Entender as preferências dos usuários ao escutar músicas para realizar determinadas atividades é primordial para aperfeiçoar um recomendador musical baseado em contexto. Entretanto, até o momento, os estudos desta área têm focado em identificar características gerais de músicas de acordo com determinados contextos, ou seja, consideram que uma música para, por exemplo, relaxar, possui as mesmas características independentemente de usuário. Deste modo, a fim de explorar possíveis diferentes preferências e percepções entre usuários, ao criarem playlists para relaxamento, este trabalho realizou uma análise com aproximadamente 91.000 playlists criadas por cerca de 8.000 usuários nas plataformas 8tracks e Spotify, que são bastante utilizadas para o compartilhamento de músicas. Neste estudo, consideramos a preferência musical de um usuário como sendo um modelo representativo das características das músicas escolhidas por ele em suas playlists. Estas características compreendem informações de alto e baixo nível das músicas e foram obtidas por meio da utilização da API do Spotify. Informações de alto nível se referem a características que seres humanos podem reconhecer ao escutar música, como por exemplo o quão dançante é uma música, se é instrumental, quão enérgica é, etc. Por outro lado, informações de baixo nível se referem a características do sinal do áudio, tais como o timbre, que é utilizado neste trabalho. Os resultados obtidos com as análises realizadas sugerem que de fato existem grandes diferenças nas percepções dos usuários ao criarem playlists para relaxamento. Foi possível identificar a existência de diferentes grupos de usuários, onde cada grupo possui um conjunto específico de características relevantes que definem suas percepções sobre músicas relaxantes. Outrossim, também foram observadas desigualdades entre os usuários quando comparamos a diferença entre suas percepções de músicas não-relaxantes e relaxantes. Dessa forma, estes resultados sugerem que deve haver um tratamento específico para cada um destes grupos de usuários, por exemplo, ao se recomendar músicas para relaxamento. Além dos resultados obtidos, este trabalho tem como contribuição a disponibilização de um novo conjunto de dados para futuras pesquisas sobre playlists musicais para relaxamento.

Abstract

Often listening to music is not just a hobby or a leisure activity, but a way of reaching a certain emotional or psychological state, or even to better perform an activity, e.g. relaxing. Understanding users' preferences when listening to music to perform certain activities is primordial to improve context-aware music recommender. However, until now, studies in this area have focused on identifying general characteristics of music according to certain contexts, that is, they consider that a song, for example, to relax, has the same characteristics regardless of user. Thus, in order to explore possible different preferences and perceptions between users, when creating playlists for relaxation, this work carried out an analysis with approximately 91,000 playlists created by about 8,000 users on the 8tracks and Spotify platforms, which are widely used for sharing songs. In this study, we consider a user's musical preference to be a representative model of the characteristics of the songs chosen by him in his playlists. These characteristics comprise high and low-level information of the songs and were obtained through the use of the Spotify API. High-level information refers to characteristics that human beings can recognize when listening to music, such as how danceable a song is, if it is instrumental, how energetic it is, etc. On the other hand, low-level information refers to characteristics of the audio signal, such as the timbre, which is used in this work. The results obtained with the analyses performed suggest that there are great differences in the perceptions of users when creating playlists for relaxation. It was possible to identify the existence of different groups of users, where each group has a specific set of relevant characteristics that define their preferences about relaxing music. Furthermore, inequalities between users were also observed when we compared the difference between their perceptions of non-relaxing and relaxing music. Moreover, inequalities between users were also observed when we compared the difference between their perceptions of non-relaxing and relaxing music. Hence, these results suggest that there must be a specific treatment for each of these groups of users, for example, when recommending songs for relaxation. In addition to the results obtained, this work contributes to the provision of a new dataset for future research on musical playlists for relaxation.

Agradecimentos

Agradeço imensamente aos meus pais, Fátima e Carlos. Obrigado por tudo que me proporcionaram até este momento em minha vida, principalmente o incentivo aos meus estudos, o amor e compreensão sempre abundantes por essa longa caminhada universitária. Se pude chegar neste momento, boa parte foram vocês que construíram.

Agradeço bastante a minha esposa Emília, por ter sido sempre muito paciente e motivadora nesta longa jornada. Obrigado por todo o amor e carinho que sempre me serviram de alavanca para conquistar meus objetivos. Você é parte fundamental nesta conquista.

Agradeço aos meus irmãos, por todos os bons momentos de convivência e por sempre acreditarem em mim.

Agradeço ao meu avô Hermes, que foi um grande exemplo de professor, sempre deixando claro para a nossa família a importância da educação. Tenho certeza que de onde ele esteja, estará orgulhoso da carreira que seu neto está trilhando. Obrigado por todos os ensinamentos, Vô.

Agradeço ao meu orientador, Nazareno, pelas inúmeras conversas formais e informais que muito me engrandeceram, não apenas como pesquisador, mas como ser humano. Obrigado por ter aceitado o convite de me guiar nessa caminhada árdua. Foram muitos ensinamentos durante esses quatro anos, desafios superados, que me fazem ser hoje em dia um melhor profissional. Por fim, agradeço pela amizade durante esses anos de convívio no LSD.

Agradeço aos amigos que sempre me apoiaram e motivaram, seja em conversas virtuais, causadas pela distância física, ou pessoais.

Sou grato a todos que fazem parte do Laboratório de Sistemas Distribuídos. Obrigado por tornarem nosso ambiente de trabalho tão leve e acolhedor. Serei eternamente grato. Um agradecimento especial ao pessoal que dividiu sala comigo durante esse tempo de pesquisa: Talita, David, Dandara, Felipe e Luiz. Nossas conversas e risadas foram primordiais para o desenvolvimento deste trabalho. Um agradecimento especial também a Cleide e Elayne, pessoas fundamentais para o bom funcionamento do nosso laboratório.

Por fim, sou extremamente grato aos professores Cláudio Campelo, Flavio Figueiredo, Giordano Cabral e Leandro Balby pelos ótimos comentários feitos durante a minha qualificação de doutorado. Estes comentários foram essenciais para a evolução deste trabalho.

Agradeço também por terem aceitado o convite de avaliar novamente esta pesquisa, agora na defesa da tese.

Conteúdo

1	Introdução	1
1.1	Contexto e Motivação	1
1.2	Problema	3
1.3	Perguntas de Pesquisa	3
1.4	Resumo dos Resultados e Contribuições	4
1.5	Organização do Documento	6
2	Fundamentação Teórica e Trabalhos Relacionados	7
2.1	Música como Tecnologia	7
2.2	Preferências Musicais para o Desempenho de Atividades Específicas	8
2.3	Propriedades de Músicas Relaxantes	10
2.4	Sistemas de Recomendação Musical Baseados em Contexto	11
2.4.1	Abordagens Tradicionais	12
2.4.2	Abordagens Contextualizadas	14
2.5	Considerações Finais	14
3	Obtenção e Enriquecimento dos Dados Utilizados nas Análises	16
3.1	Fontes dos Dados	16
3.2	Obtenção de Playlists	17
3.3	Enriquecimento dos Dados	19
3.4	Caracterizando o Conjunto de Dados	21
3.5	Considerações Finais	24
4	Modelando as Preferências dos Usuários	27

4.1	Utilizando <i>Features</i> Musicais de Alto Nível para Modelar as Preferências dos Usuários	27
4.2	Utilizando <i>Features</i> Musicais de Baixo Nível para Modelar as Preferências dos Usuários	29
4.3	Considerações Finais	33
5	Explorando Preferências Musicais em Playlists Relaxantes	35
5.1	Analisando os Usuários da Plataforma 8tracks	35
5.1.1	Identificando as <i>Features</i> Relevantes de Maneira Geral	36
5.1.2	Agrupando os Usuários De Acordo com Suas Preferências Musicais	37
5.1.3	Identificando as <i>Features</i> Relevantes de Cada Grupo Encontrado . .	42
5.1.4	Considerações Finais Sobre os Grupos Identificados no 8tracks . . .	50
5.2	Analisando os Usuários da Plataforma Spotify	50
5.2.1	Identificando as <i>Features</i> Relevantes de Maneira Geral	50
5.2.2	Agrupando os Usuários De Acordo com Suas Preferências Musicais	52
5.2.3	Identificando as <i>Features</i> Relevantes de Cada Grupo Encontrado . .	56
5.2.4	Considerações Finais Sobre os Grupos Identificados no Spotify . .	58
6	Explorando as Diferenças das Preferências Musicais dos Usuários entre as Playlists Relaxantes e as Playlists Gerais	64
6.1	Analisando os Usuários da Plataforma 8tracks	65
6.1.1	Agrupando os Usuários De Acordo com Suas Diferenças das Preferências Musicais	65
6.1.2	Analisando os Grupos Identificados	69
6.2	Analisando os Usuários da Plataforma Spotify	71
6.2.1	Agrupando os Usuários De Acordo com Suas Diferenças das Preferências Musicais	71
6.2.2	Analisando os Grupos Identificados	73
6.3	Considerações Finais	73
7	Conclusões e Trabalhos Futuros	76
7.1	Limitações e Trabalhos Futuros	78

Lista de Símbolos

RIM - *Recuperação de Informação Musical*

SRM - *Sistemas de Recomendação Musical*

GMM - *Gaussian Mixture Models*

API - *Application Programming Interface*

Lista de Figuras

3.1	Distribuição da quantidade de playlists por usuário nas duas plataformas. . .	23
3.2	Distribuição do tamanho das playlists entre relaxantes e não relaxantes. . .	23
3.3	Distribuição do tamanho das playlists nas duas plataformas.	24
3.4	Popularidade das músicas nas duas plataformas estudadas.	25
3.5	Distribuição de algumas <i>features</i> de alto nível nas músicas das duas plataformas.	26
4.1	Método do cotovelo para a métrica BIC	31
4.2	Gradientes da métrica BIC	32
5.1	Soma total dos erros quadrados em diferentes configurações de quantidade de grupos a serem identificados pelo algoritmo k-means nos modelos dos usuários do 8tracks.	40
5.2	Gradientes das somas totais dos erros quadrados em diferentes configurações de quantidade de grupos a serem identificados pelo algoritmo k-means nos modelos dos usuários do 8tracks.	41
5.3	Soma total dos erros quadrados em diferentes configurações de quantidade de grupos a serem identificados pelo algoritmo k-means nos modelos dos usuários do Spotify.	54
5.4	Gradientes das somas totais dos erros quadrados em diferentes configurações de quantidade de grupos a serem identificados pelo algoritmo k-means nos modelos dos usuários do Spotify.	55

6.1	Soma total dos erros quadrados em diferentes configurações de quantidade de grupos a serem identificados pelo algoritmo k-means nos modelos das diferenças entre as preferências relaxantes e gerais dos usuários do 8tracks.	67
6.2	Gradientes das somas totais dos erros quadrados em diferentes configurações de quantidade de grupos a serem identificados pelo algoritmo k-means nos modelos das diferenças entre as preferências relaxantes e gerais dos usuários do 8tracks.	68
6.3	Soma total dos erros quadrados em diferentes configurações de quantidade de grupos a serem identificados pelo algoritmo k-means nos modelos das diferenças entre as preferências relaxantes e gerais dos usuários do Spotify.	71
6.4	Gradientes das somas totais dos erros quadrados em diferentes configurações de quantidade de grupos a serem identificados pelo algoritmo k-means nos modelos das diferenças entre as preferências relaxantes e gerais dos usuários do Spotify.	72

Lista de Tabelas

3.1	Quantidade de usuários filtrados	19
3.2	Quantidade de músicas e playlists filtradas	19
3.3	<i>Features</i> extraídas das músicas utilizadas nas análises	22
4.1	Playlist de um usuário do 8tracks	28
4.2	O vetor de preferência do usuário do 8tracks, considerando apenas as <i>features</i> de alto nível	29
4.3	O vetor final de representação de cada música.	32
4.4	Vetor de representação da preferência musical de um usuário do Spotify	34
5.1	Resultados da regressão logística aplicada nos modelos de preferências relaxantes dos usuários do 8tracks	38
5.2	Resultados da regressão logística aplicada no Grupo 1 nos modelos de preferências relaxantes dos usuários do 8tracks	44
5.3	Resultados da regressão logística aplicada no Grupo 2 nos modelos de preferências relaxantes dos usuários do 8tracks	45
5.4	Resultados da regressão logística aplicada no Grupo 3 nos modelos de preferências relaxantes dos usuários do 8tracks	47
5.5	Resultados da regressão logística aplicada no Grupo 4 nos modelos de preferências relaxantes dos usuários do 8tracks	48
5.6	Resultados da regressão logística aplicada no Grupo 5 nos modelos de preferências relaxantes dos usuários do 8tracks	49
5.7	Resultados das regressões logísticas aplicadas nos 5 grupos identificados nos usuários do 8tracks	51

5.8	Resultados da regressão logística aplicada nos modelos de preferências relaxantes dos usuários do Spotify	53
5.9	Resultados da regressão logística aplicada no Grupo 1 nos modelos de preferências relaxantes dos usuários do Spotify	57
5.10	Resultados da regressão logística aplicada no Grupo 2 nos modelos de preferências relaxantes dos usuários do Spotify	59
5.11	Resultados da regressão logística aplicada no Grupo 3 nos modelos de preferências relaxantes dos usuários do Spotify	60
5.12	Resultados da regressão logística aplicada no Grupo 4 nos modelos de preferências relaxantes dos usuários do Spotify	61
5.13	Resultados das regressões logísticas aplicadas nos 4 grupos identificados nos usuários do Spotify	63
6.1	Exemplo de cálculo do vetor para representar as diferenças entre as preferências do usuário entre playlists relaxantes e playlists gerais.	66
6.2	Valores dos centroides calculados após a aplicação do algoritmo k-means para a identificação de 3 grupos nos dados das diferenças entre as preferências relaxantes e demais preferências dos usuários do 8tracks	70
6.3	Valores dos centroides calculados após a aplicação do algoritmo k-means para a identificação de 3 grupos nos dados das diferenças entre as preferências relaxantes e demais preferências dos usuários do Spotify	74

Capítulo 1

Introdução

1.1 Contexto e Motivação

Ouvir música é um hábito diário de muitas pessoas, porém mais do que um hábito ou atividade de lazer, ouvir música pode ser visto como um facilitador para atingir um certo estado emocional, psicológico ou fisiológico, e até para auxiliar na realização de outras tarefas [60]. As pessoas ouvem músicas, por exemplo, para se exercitar, para relaxar depois de um dia de trabalho, para estudar, para dormir, dentre outras atividades do dia a dia. Ou seja, a música é frequentemente usada para adaptar o humor do usuário para desempenhar certas atividades. Neste sentido, podemos considerar o uso da música como uma tecnologia, como proposto por Demetriou et al. [16].

Para atividades distintas, uma mesma pessoa pode ter diferentes preferências musicais. Para dormir, por exemplo, uma música relaxante pode ser provavelmente melhor, enquanto que para o exercício físico uma música energizante pode ser preferível. Outrossim, é possível que pessoas diferentes tenham preferências distintas para uma mesma atividade, às vezes de maneira extrema, como, por exemplo, escutar *death metal* para relaxar. Dessa forma, se faz necessário uma busca por músicas adequadas para determinadas situações de acordo com as preferências de cada pessoa. Porém, devido a existência de milhões de músicas em plataformas de transmissão como Spotify, 8tracks, Youtube, Deezer, Soundcloud, entre outros, realizar esta tarefa pode se tornar algo custoso para os usuários.

Para ilustrar, tomemos como exemplo o Spotify. Segundo seu site oficial¹ existe em seu

¹<https://newsroom.spotify.com/company-info/>

catálogo mais de 50 milhões de músicas. Escutar músicas arbitrariamente até encontrar uma que se encaixe nas suas preferências para determinado contexto, é impraticável. Talvez uma alternativa seria o usuário procurar por músicas em playlists criadas para o contexto adequado ou até mesmo buscar informações em algum site de conteúdo musical, que contenha recomendações, e escutar música por música do que foi pesquisado até encontrar alguma que lhe agrade. Mesmo assim, é possível perceber que isto demandaria bastante esforço.

Portanto, entender as preferências musicais dos usuários é um aspecto fundamental para diversas atividades na área de Recuperação de Informação Musical (RIM), como, por exemplo, para a recomendação de músicas.

Diante da grande disponibilidade de plataformas de transmissão de músicas através de dispositivos móveis, sistemas de recomendação começaram a adotar uma nova dimensão em suas sugestões: o contexto do usuário. Esses sistemas, conhecidos como Sistemas de Recomendação Baseados em Contexto [1], utilizam informações atuais dos usuários para aprimorar suas recomendações, tais como: seu estado emocional, sua localização, o clima do local que o usuário se encontra, entre outras. Dentre os vários tipos de contextos que usuários podem estar inseridos, o tipo de atividade que ele deseja desempenhar ao escutar música é um deles [60; 16]. Dessa forma, compreender as preferências musicais dos usuários ao realizarem atividades específicas auxilia no processo de escolha de músicas relevantes para o que se deseja.

Dentre as atividades mais comuns que usuários realizam, ou desejam realizar, escutando música, está o relaxamento [60]. De acordo com a área de musicoterapia [14; 12], personalizar a escolha de músicas para relaxamento é essencial para uma melhor experiência do usuário. Dessa forma, expandir os achados da musicoterapia, utilizando soluções computacionais com aspectos da musicologia e uma grande quantidade de dados, é um passo significativo para a evolução de sistemas de RIM.

Buscando entender melhor o comportamento e preferências dos usuários de plataformas de transmissão de músicas, algumas pesquisas foram desenvolvidas tentando criar representações dos usuários por meio de modelos estatísticos [5; 49; 50]. Este esforço para modelar de maneira fiel as preferências dos usuários permite que, com o passar do tempo, plataformas de transmissão de músicas proporcionem experiências cada vez mais personalizadas para seus usuários. Essa personalização se dá, por exemplo, no auxílio durante a criação de

uma playlist ou apenas na sugestão de uma música para o usuário escutar em um determinado contexto que esteja inserido.

É neste escopo de recomendação musical baseada em contexto e modelagem de usuários que este trabalho busca explorar e entender a importância da personalização durante a criação de playlists relaxantes.

1.2 Problema

Recomendações musicais baseadas em contexto se tornou uma importante linha de pesquisa na área de RIM. Vários trabalhos vem evoluindo o estado da arte em diversos contextos que usuários podem estar submetidos [45; 28; 11; 59; 32; 43; 3; 24].

Apesar desta evolução, atualmente, pelo que foi levantado sobre o estado da arte, dos trabalhos que tentam ajudar os usuários na escolha de músicas para auxiliar/facilitar a execução de atividades específicas, nenhum utiliza a personalização como critério determinante para a escolha. Os trabalhos encontrados [19; 60; 59] não consideram as preferências individuais dos usuários, levando em consideração as preferências gerais de todos os usuários para cada atividade específica.

Diante deste quadro, essa pesquisa se concentrou em identificar se as preferências de consumidores de música variam quando escolhendo músicas para uma mesma atividade, e como variam. Procurando assim fomentar o desenvolvimento futuro de abordagens personalizadas para esse contexto.

1.3 Perguntas de Pesquisa

Com o intuito de expandir o entendimento sobre diferentes preferências musicais que usuários possuem ao criar playlists para a realização de atividades específicas, optamos por conduzir análises em corpora de playlists. De acordo com [60], a atividade mais comum que usuários desempenham ou desejam desempenhar escutando música é o relaxamento. Dessa forma, escolhemos analisar playlists criadas por usuários com o intuito de relaxar.

Isto posto, podemos elencar as seguintes perguntas de pesquisa que guiaram os estudos conduzidos neste trabalho:

- **Questão de Pesquisa 1:** Há, e se há, quais são as diferenças nas preferências dos usuários ao criarem playlists para uma mesma atividade?
- **Questão de Pesquisa 2:** Existem e quais são as diferenças nas preferências de diferentes grupos de usuários entre suas playlists criadas para uma atividade específica e suas playlists para outros fins?
- **Questão de Pesquisa 3:** Quão satisfatório é modelar as preferências dos usuários ao criarem playlists relaxantes, utilizando *features* musicais de alto e baixo nível?

É relevante comentar que todo este trabalho de pesquisa teve sua origem em discussões relacionadas à **Questão de Pesquisa 1**, uma vez que, ao ler trabalhos sobre recomendações musicais baseadas em contexto, onde o contexto é a realização de atividades comuns, não foi possível identificar o uso da personalização como um critério primordial para as recomendações [60; 19; 59]. Nestes trabalhos, eles consideram que todos os usuários têm uma mesma preferência musical.

Com o intuito de responder a **Questão de Pesquisa 1**, deu-se início a uma revisão da literatura com o intuito de achar meios de identificar e modelar as preferências musicais de usuários de plataformas de transmissão de músicas ao criarem playlists. Dessa forma, surgiu a **Questão de Pesquisa 3**. Estudando essa pergunta, desenvolvemos primeiro um modelo estatístico contendo apenas *features* musicais de alto nível.

Com este primeiro modelo, foi conduzida uma análise em dois corpora de playlists, onde foi possível identificar diferenças nas preferências dos usuários ao criarem playlists para uma mesma atividade: relaxamento. Foi também durante esta primeira análise que surgiu uma nova discussão, visando caracterizar as diferenças entre as preferências dos usuários entre suas playlists relaxantes e as não relaxantes, o que acarretou no surgimento da **Questão de Pesquisa 2**.

1.4 Resumo dos Resultados e Contribuições

A partir da análise dos dados obtidos e leituras de trabalhos relacionados, é possível resumir os principais resultados e contribuições deste trabalho da seguinte forma:

Em relação à **Questão de Pesquisa 3**, inicialmente foi construído um modelo estatístico mais simples para representar as preferências dos usuários ao criarem palylists relaxantes. Neste modelo inicial, um vetor com valores de 9 *features* musicais de alto nível foi criado, onde cada valor representava a média dos valores dessas mesmas *features* de cada música presente nas playlists de um determinado usuário. Por não ser sensível à dispersão nos dados e por não possuir *features* musicais de baixo nível, este primeiro modelo foi modificado e evoluído. Neste novo modelo, que foi baseado em [62], foram adicionadas *features* relacionadas ao timbre das músicas, bem como medidas de dispersão de todas as *features* de alto nível. Com este segundo modelo, foi possível identificar mais diferenças e similaridades entre as preferências dos usuários ao criarem playlists relaxantes em comparação com o primeiro modelo.

No que se refere à **Questão de Pesquisa 1**, para identificar a existência ou não de diferenças nas preferências dos usuários ao criarem playlists relaxantes, foi utilizado um método de aprendizagem de máquina não supervisionado de agrupamento. Este método foi aplicado na coleção de vetores de representação das preferências dos usuários. Neste agrupamento, foi possível identificar 5 grupos distintos em um corpus de playlists e 4 em outro. Outrossim, também foi possível verificar que cada grupo identificado possui diferentes conjuntos de *features* relevantes que definem suas preferências musicais acerca de relaxamento.

Por fim, no tocante à **Questão de Pesquisa 2**, foi conduzida uma análise semelhante à reproduzida para responder a **Questão de Pesquisa 1**. Para esta análise geramos um terceiro vetor de representação das preferências dos usuários, além dos vetores de preferências de relaxamento e não relaxamento. Este terceiro vetor é o resultado da subtração dos componentes do vetor de relaxamento com os componentes do vetor de não relaxamento. Após aplicarmos o algoritmo de agrupamento neste terceiro vetor, foi possível identificar diferentes grupos, mais especificamente 3, onde cada um deles possui características específicas.

De maneira geral, os resultados obtidos nesta pesquisa apontam que as preferências dos usuários ao criarem playlists para contextos específicos são muito diferentes e devem ser levadas em consideração durante, por exemplo, tarefas de recomendação musical. Uma parte dos resultados obtidos nesta pesquisa estão presentes na seguinte publicação:

- MÉLO, Daniel; ANDRADE, Nazareno. Exploiting the Importance of Personalization When Selecting Music for Relaxation. In: **International Conference on Multimedia**

Modeling. Springer, Cham, 2020. p. 49-61.

1.5 Organização do Documento

Quanto à estrutura do documento, no Capítulo 2, são apresentados os principais conceitos da área de pesquisa, discorrendo sobre o uso de música como tecnologia, preferências musicais para atividades específicas e recomendação musical baseada em contexto. Além disso, são comentadas as contribuições realizadas por outros trabalhos.

No Capítulo 3, é descrito como foi realizado o processo de aquisição dos dados utilizados nas análises efetuadas. Também está descrito neste capítulo o procedimento efetuado para a adição de features acústicas às músicas das playlists. Por fim, os dados e suas fontes são caracterizados por meio de métricas que descrevem seus tamanhos e suas distribuições, assim como também indicam a popularidade das músicas utilizadas e a distribuição dos valores de algumas *features* musicais nos corpora.

O processo realizado para a modelagem das preferências musicais dos usuários, utilizando *features* musicais de alto e baixo nível é esmiuçado no Capítulo 4.

O Capítulo 5 explica todas as etapas que foram percorridas para a realização da análise da existência de diferentes grupos de usuários em relação às suas preferências ao criarem playlists relaxantes. Além disso, é feita uma discussão sobre cada um dos grupos identificados. De forma bem semelhante está estruturado o Capítulo 6, diferindo apenas no fato de que esta análise é feita em relação às diferenças nas preferências dos usuários entre músicas relaxantes e não relaxantes.

Por fim, no Capítulo 7, as principais etapas do trabalho realizadas são sumarizadas, apontando as principais conclusões alcançadas, limitações e ameaças à validade. Discute-se, ainda, possibilidades de trabalhos futuros.

Capítulo 2

Fundamentação Teórica e Trabalhos Relacionados

2.1 Música como Tecnologia

Ouvir músicas é um hábito bastante antigo e que com a evolução das tecnologias de reprodução de mídias se tornou bastante popular. Hoje em dia, com o avanço dos serviços de transmissão de músicas, o acesso à uma infinidade de diferentes canções se tornou bem maior a toda a população.

Juntamente com esse avanço, escutar música passou a ser mais do que apenas um hábito diário ou uma atividade de lazer de muitas pessoas, passou a ser uma maneira de facilitar o ouvinte a atingir um determinado estado emocional, psicológico ou fisiológico, e até mesmo para auxiliar na realização de atividades específicas [60; 23].

Desse modo, [16] sugere que analisemos a música também como uma tecnologia. Para entender melhor o uso do termo "*música como tecnologia*", primeiro se faz necessário entender o significado da palavra *tecnologia*. Para este contexto, o uso do termo *tecnologia* remete ao significado de ser *uma maneira de alcançar um objetivo especialmente utilizando processos técnicos, métodos ou conhecimento*¹. Ou seja, é sugerido que existem alguns casos em que ouvintes usam a música como uma ferramenta direta para alcançar um determinado objetivo, por exemplo melhorar seu rendimento ao fazer algum exercício físico, ou apenas para realizar alguma atividade diária/específica [41; 46;

¹<http://www.merriam-webster.com/dictionary/technology>

57], tais como: relaxar, estudar, trabalhar, etc.

Apesar do uso desse termo ter sido sugerido em um trabalho recente na área de Recuperação de Informação Musical, essa noção de música como tecnologia é mais antiga e já utilizada em trabalhos da área de sociologia, como em [17] em 1999. Neste trabalho a música é caracterizada como parte de um processo contínuo de autodesenvolvimento, e também indicou que as pessoas usam a música para manter uma identidade social, bem como regular suas emoções, humores, níveis de energia, enfim, condições do seu bem estar.

O aumento no consumo de músicas que acompanham outras atividades trouxe junto também a crença de que seleções musicais específicas podem potencializar seu uso como tecnologia [41]. Dessa forma, se torna importante escolher músicas de acordo com o objetivo que se deseja alcançar, pois como mostra [40], usuários relataram que a música desempenha funções diferentes para diferentes situações.

Atualmente, com a infinidade de músicas disponíveis para os ouvintes escolherem, se tornou um grande desafio fazer boas escolhas para o uso da música como tecnologia. Para tal, o uso de sistemas de recomendações para este contexto vem se tornando algo mais comum. Na subseção 2.4 é discutido mais sobre esses sistemas e seu uso no contexto de música como tecnologia.

2.2 Preferências Musicais para o Desempenho de Atividades Específicas

Como comentado na Seção 2.1, a música pode ser um facilitador para uma pessoa atingir um determinado estado emocional, psicológico ou fisiológico. Apesar de serem constatados ultimamente em trabalhos da área de RIM, estes achados provêm também de pesquisas realizadas na área da musicoterapia. Nestas pesquisas, são exploradas as formas de como a música pode influenciar e intervir no estado clínico de pacientes. Dentre estes trabalhos, encontra-se uma linha de pesquisa que investiga a importância da personalização durante a escolha de músicas a serem utilizadas em tratamentos clínicos.

Em [14], foi realizado um estudo com 18 pacientes, onde foram examinados os efeitos do uso de músicas preferidas para a diminuição da ansiedade e aumento do relaxamento destes pacientes. Foi constatado que, dentre as músicas escolhidas pelos próprios pacientes para

relaxar, havia uma grande variedade de gêneros musicais, incluindo rock, músicas clássicas e jazz, e também uma diversidade de valores de *features* musicais como o tempo e ritmo. Além disso, mais de 68% das músicas possuíam letra. Os resultados deste estudo confirmaram a diminuição da ansiedade dos pacientes, bem como um aumento no nível de relaxamento. Também foi observado que dentre os critérios utilizados pelos pacientes para escolher as músicas, estavam a familiaridade, preferências e as percepções dos elementos das músicas, como sua estrutura, tempo e ritmo.

Ainda na área de musicoterapia, [12] elaborou uma pesquisa onde pacientes foram divididos em dois grupos. Em um grupo, os pacientes foram entrevistados por musicoterapeutas e tiveram suas preferências musicais identificadas e utilizadas durante o processo de tratamento clínico, enquanto que no outro grupo os pacientes não foram entrevistados, tendo suas músicas escolhidas diretamente pelos musicoterapeutas, sem qualquer conhecimento de suas preferências. Os resultados desta pesquisa mostraram que os pacientes que foram submetidos ao tratamento musicoterápico utilizando músicas de acordo com suas preferências, sinalizaram um maior relaxamento e diminuição de estresse durante suas sessões semanais de radioterapia.

Quanto à área de RIM, o estudo sobre as preferências musicais dos usuários para desempenharem atividades específicas tem ganhado importância com o passar do tempo. Trabalhos que visam identificar quais são as atividades que possuem mais playlists criadas por usuários para desempenhá-las, bem como as preferências gerais dos usuários para cada uma dessas atividades vem sendo desenvolvidos. [60] conduziu uma pesquisa onde foram minerados dados provenientes do YouTube², uma plataforma para compartilhamento de vídeos. Nesta mineração, foram identificadas três principais atividades que os usuários executam enquanto escutam músicas: (i) relaxar, (ii) estudar e (iii) exercitar. Além de identificar as principais atividades, os autores propuseram uma metodologia para classificar as músicas pertencentes a cada uma destes contextos, fazendo uso de *features* de baixo e alto nível.

Um outro trabalho que segue a linha de estudar as preferências musicais dos usuários ao realizar atividades específicas, é descrito em [59]. Nesta pesquisa, os autores desenvolveram um modelo probabilístico para inferir a atividade que um determinado usuário está desempenhando, por meio do uso de sensores de dispositivos móveis, bem como recomen-

²<https://www.youtube.com/>

dar músicas para esta atividade. Para classificar as músicas para cada uma das atividades, os autores fizeram uso de um modelo treinado por um conjunto de 1200 músicas anotadas por 10 estudantes. Para a construção desses modelos, foram utilizadas *features* de baixo nível, tais como o timbre. Este modelo, assim como o desenvolvido por [60], identifica um padrão geral para todas as músicas de cada atividade específica.

Como pode-se perceber, estas pesquisas, de uma forma geral, não fazem uso da personalização como um critério fundamental para a recomendação de músicas para o desempenho de atividades específicas, mas sim indicam configurações gerais de características que possibilitam a classificação das músicas em cada um dos contextos estudados. Dessa forma, neste trabalho busca-se explorar a importância da personalização nestes contextos de recomendações e criações de playlists. Mais especificamente, explora-se as diferenças nas preferências dos usuários ao escutarem músicas para relaxar. A escolha da atividade de relaxamento se deu baseada no fato de ser uma atividade comum bastante popular, como demonstrado em [60].

2.3 Propriedades de Músicas Relaxantes

Dentre as atividades mais comuns que usuários realizam, ou desejam realizar, escutando música, está o relaxamento [60], que é o foco das análises realizadas neste trabalho. Neste escopo, pesquisadores buscam identificar e entender quais as características que fazem uma música ser relaxante. Trabalhos, inclusive na área da psicoacústica, tentaram identificar características que se mostraram eficazes para o relaxamento, e também evidenciaram a importância da familiaridade e preferência musical dos ouvintes para que as músicas cumpram seu papel relaxante.

Em [26] os autores conduziram um estudo com quarenta estudantes universitárias com idades entre 18 e 27 anos. Neste trabalho, cada participante escutou cerca de 50 minutos de músicas que variavam em relação ao timbre, amplitude e tempo. Segundo os autores, pesquisas anteriores indicaram que se o ritmo de uma música for muito lento ou muito rápido, os ouvintes têm dificuldade para relaxar. Dessa forma, de acordo com os resultados obtidos por meio das respostas dos participantes, é possível que a condição mais relaxante inclua um tempo de 65 BPM, amplitude mais baixa e timbre suave, como de um clarinete baixo, ou

clarone.

No estudo conduzido em [58], onde quatorze terapeutas recomendaram e analisaram trinta seleções de músicas relaxantes, foi verificado que as músicas tendiam a ter um tempo de aproximadamente 60 BPM, com pequenas mudanças dinâmicas ao longo da sua estrutura. Além disso, as seleções de músicas com ritmos muito simples foram percebidas como mais relaxantes. Percebeu-se que o grau de relaxamento aumentou com a diminuição do tempo e da complexidade melódica e rítmica, bem como com menores combinações de instrumentos. Em uma outra etapa desta pesquisa, as seleções musicais foram escutadas por 80 adultos, e após isto os participantes classificaram sua familiaridade, preferência e grau de relaxamento. Após a análise desses dados, verificou-se a existência de uma correlação positiva significativa entre a preferência musical e o grau de relaxamento percebido, bem como entre a familiaridade com a música e o grau de relaxamento percebido.

Nota-se então que, apesar dos esforços de estudos que visam identificar as propriedades das músicas relaxantes, como por exemplo mensurar o tempo ideal para uma música ser relaxante, ou até mesmo designar quais instrumentos soam mais relaxantes, existe um fator subjetivo que influencia a percepção de relaxamento. Esse fator subjetivo, como por exemplo a preferência ou familiaridade musical do ouvinte, pode ser mais determinante do que as próprias características acústicas das músicas, para desempenhar seu papel de relaxamento.

2.4 Sistemas de Recomendação Musical Baseados em Contexto

Nos dias atuais, com a quantidade de informações e com a disponibilidade facilitada das mesmas pelo acesso a internet, as pessoas se deparam com uma diversidade muito grande de opções quando estão desejando comprar algum produto ou consumir algum serviço. Em alguns casos, as pessoas possuem pouca ou nenhuma experiência pessoal ou conhecimento prévio para realizar escolhas dentre uma gama de opções de produtos/serviços que lhe são ofertados. Para tentar contornar este problema, diminuindo dúvidas, geralmente confiamos em recomendações que são fornecidas por outras pessoas. Essas recomendações podem ser obtidas indiretamente por meio de textos em fóruns de internet, opiniões de críticos de cinema (caso estejamos escolhendo algum filme para assistir, por exemplo), jornais, blogs,

dentre outros, ou de forma direta como relatado em [55], conhecido como boca a boca.

2.4.1 Abordagens Tradicionais

Neste escopo, os sistemas de recomendação surgiram para auxiliar no aumento da capacidade e eficácia deste processo de indicação já existente na relação social entre os seres humanos [47]. Em um típico sistema de recomendação, podem ser utilizadas três abordagens [2] para a geração de sugestões de produtos para potenciais clientes: (i) filtragem colaborativa, (ii) filtragem baseada em conteúdo e (iii) método híbrido. A seguir, descrevemos cada um deles de forma breve:

- A filtragem colaborativa é uma técnica que recomenda itens a um usuário baseado no que usuários similares a ele se interessaram anteriormente;
- Na filtragem baseada em conteúdo o usuário receberá recomendações de itens similares a itens preferidos no passado;
- Os métodos híbridos, como o nome sugere, combinam técnicas tanto da filtragem colaborativa como da baseada em conteúdo.

Dentre as aplicações de sistemas de recomendação, uma que recentemente vem ganhando um substancial interesse tanto no mundo acadêmico quanto na indústria, como exposto em [52], é a de recomendar músicas. Isso se deve aos serviços de streaming de músicas tais como Spotify, Pandora, Deezer, Apple Music, entre outros, que permitem acesso a milhões de músicas.

Porém, diferentemente dos sistemas de recomendação tradicionais, os Sistemas de Recomendação Musical (SRM) possuem algumas particularidades inerentes às características dos itens que processam, os distinguindo em relação àqueles sistemas que recomendam outros itens, tais como: filmes, livros ou produtos. De acordo com [51], os aspectos que diferenciam a música de outros itens podem ser descritos da seguinte maneira:

- *Duração dos itens.* Em recomendações tradicionais de filmes, os itens de interesse possuem tipicamente 90 minutos de duração ou mais. Na recomendação de livros, o consumo dos itens é comumente mais lento ainda. Por outro lado, a duração de uma

música varia entre 3 e 5 minutos (com algumas exceções, como por exemplo músicas clássicas).

- *Magnitude dos itens.* Os tamanhos de catálogos musicais, como no Spotify, estão na faixa de dezenas de milhões de itens, enquanto que serviços de streaming de filmes e séries lidam com catálogos bem menores. Portanto, escalabilidade é um fator bem mais importante em recomendadores musicais do que em recomendadores de filmes, por exemplo.
- *Consumo sequencial.* Diferentemente de filmes, músicas são mais frequentemente consumidas de forma sequencial, por exemplo em playlists musicais.
- *Recomendação de itens já recomendados.* Recomendar uma mesma música novamente para um mesmo usuário, em algum momento futuro, pode ser apreciado pelo usuário. O que não ocorre por exemplo em recomendadores de produtos, onde recomendações repetidas geralmente não são bem quistas.
- *Comportamento do consumo.* Música é frequentemente consumida de forma passiva, como uma atividade secundária.
- *Contexto.* Aspectos contextuais [18; 4] têm uma forte influência na preferência musical, no consumo e no comportamento de interação do usuário. Por exemplo, um usuário provavelmente criaria uma playlist diferente para um jantar romântico do que criaria para um churrasco com amigos [22]. Os tipos de contexto mais frequentemente considerados incluem localização (por exemplo, ouvir música no local de trabalho ou em casa) [28] e horário (normalmente classificados em, por exemplo, manhã, tarde e noite) [10]. O contexto pode, além disso, também se relacionar com a atividade do ouvinte [59], clima [44], ou o uso de diferentes dispositivos de escuta, por exemplo, fones de ouvido em um smartphone vs. caixas de som [22], dentre outros contextos. Como escutar música também é uma atividade social, investigar o contexto social dos ouvintes é crucial para entender suas preferências e comportamentos de escuta [13; 42].

2.4.2 Abordagens Contextualizadas

Dentre os aspectos mencionados, entender o contexto do usuário ao escutar música é atualmente uma grande tendência na área de pesquisa de sistemas de recomendação musical [53], inclusive se tornando uma linha específica de pesquisa, conhecida como Sistemas de Recomendação Baseado em Contexto [1]. Nesta nova perspectiva de recomendação, temos uma nova dimensão a ser considerada: o contexto, diferentemente das abordagens de filtragem colaborativa e baseada em conteúdo, onde as únicas dimensões consideradas eram a dos usuários e a dos itens. Na Equação 2.1 estão identificadas as dimensões utilizadas em abordagens tradicionais de recomendação, enquanto que na Equação 2.2 observamos a presença de uma terceira dimensão, o contexto.

$$Usuários \times Itens \rightarrow Recomendações \quad (2.1)$$

$$Usuários \times Itens \times Contextos \rightarrow Recomendações \quad (2.2)$$

É justamente neste escopo de recomendação musical baseada em contexto que esta tese está inserida. Mais especificamente, o contexto considerado é a atividade que o usuário está desempenhando ou deseja desempenhar ao escutar música, que, no nosso caso, é o relaxamento. Neste escopo também se encaixa o conceito que já foi comentado na Seção 2.1, o do uso da música como tecnologia.

2.5 Considerações Finais

Neste capítulo, apresentamos os principais conceitos, trabalhos e exemplos fundamentais para a construção do embasamento teórico necessário para melhor entender as contribuições deste trabalho, assim como os estudos já realizados relacionados com esta tese. São eles: i) os conceitos do uso de música como tecnologia e de sistemas de recomendação musical; ii) exemplos de aspectos particulares e importantes relacionados à recomendação de músicas; iii) as características identificadas em trabalhos que visam identificar o que faz uma música ser relaxante; iv) discussão sobre a importância da personalização durante a escolha de músicas para o desempenho de atividades específicas; v) os conceitos sobre sistemas de re-

comendações baseadas em contexto; e vi) trabalhos que abrangem a recomendação musical baseada em contexto e o uso da música como tecnologia.

Capítulo 3

Obtenção e Enriquecimento dos Dados Utilizados nas Análises

Neste capítulo, os dados que foram utilizados para a realização da pesquisa são identificados e caracterizados. São descritos os processos de obtenção e enriquecimento dos dados para a posterior construção de modelos matemáticos para representação das preferências musicais dos usuários.

O processo de aquisição e enriquecimento dos dados se deu basicamente em três etapas: (i) obtenção de playlists relaxantes e não relaxantes de usuários; (ii) busca pelos identificadores do Spotify¹ de cada música das playlists obtidas e; (iii) adição de *features* musicais de alto e baixo nível das músicas dessas playlists. Nas seções 3.2 e 3.3, todos esses processos são detalhados. Na Seção 3.4, pode-se encontrar uma caracterização do conjunto de dados utilizado nesta pesquisa.

3.1 Fontes dos Dados

Uma vez que o intuito desta pesquisa é explorar a importância da personalização durante a escolha de músicas a serem ouvidas por usuários que desejam desempenhar atividades específicas, buscamos dados em serviços de transmissão de músicas onde usuários podem criar e compartilhar playlists. Duas plataformas foram utilizadas para a aquisição dos dados:

¹<https://www.spotify.com/br/>

8tracks² e Spotify.

8tracks

O 8tracks era uma rádio de internet e uma rede social onde usuários podiam compartilhar e descobrir músicas de forma simples, legal e gratuita. Uma característica muito importante de se ressaltar é que no 8tracks as playlists eram concebidas manualmente, por cerca de seus 20 milhões de usuários registrados, sem a interferência de mecanismos para criações automáticas de playlists, o que fez com que as listas lá criadas e compartilhadas representassem, de fato, as preferências musicais de seus criadores. As playlists criadas deviam possuir no mínimo 8 músicas (mas a prática mais comum dos usuários era criar playlists com exatamente 8 músicas), que podiam ser enviadas pelo próprio usuário, ou pesquisadas na biblioteca do 8tracks.

Spotify

O Spotify é um serviço de streaming de músicas, *podcasts* e vídeos. Além disso, a plataforma fornece vários outros recursos, tais como: informações sobre turnês de artistas, recomendações musicais diárias, ranking de músicas mais tocadas em diversos países e em todo o mundo, entre outras informações. Também é possível, no Spotify, criar e compartilhar playlists. É atualmente o serviço mais popular do mundo em seu contexto [56], contando com aproximadamente 250 milhões de usuários ativos.

3.2 Obtenção de Playlists

Para cada fonte de dados foi necessária uma abordagem específica para a aquisição de playlists. A primeira plataforma que se obteve dados foi o 8tracks. Para tanto, foi utilizado uma cópia da sua base de dados, fornecida pelos próprios administradores da plataforma. Nesta cópia, estão contemplados dados de Setembro de 2007 a Junho de 2012. Estes dados contêm informações sobre os usuários da plataforma, sobre músicas e playlists criadas e compartilhadas.

²<https://8tracks.com/>

Nesta cópia fornecida é possível recuperar, sobre cada playlist, seu nome, sua descrição, a quantidade de músicas, suas tags, seu criador, entre outras informações. Dessa forma, como o interesse era verificar a existência ou não de diferentes perfis de usuários com relação à sua preferência musical para músicas relaxantes, e também comparar suas preferências em músicas não relaxantes, foi feita uma busca para retornar os usuários que tinham criado pelo menos uma playlist relaxante e uma não relaxante com mais de uma música. Para tal, utilizamos o critério de existência das tags *relax* ou *chill* em suas playlists. Com esta filtragem foram recuperados 4.880 usuários, como é possível observar na Tabela 3.1.

A outra fonte utilizada, o Spotify, não forneceu diretamente seus dados, porém é disponibilizada uma API³ (*Application Programming Interface* - um conjunto de rotinas e padrões estabelecidos por um software para que aplicativos tenham acesso as suas funcionalidades) bastante rica onde é possível acessar vários detalhes da plataforma. Com esta API é possível recuperar informações de usuários, músicas, artistas, álbuns, playlists, entre outras diversas opções.

Fazendo uso desta API, foi realizada uma pesquisa por playlists com os termos de busca *relax* e *chill*. Diferentemente do 8tracks, onde todas as playlists são criadas de forma manual pelos usuários, o Spotify permite maneiras de geração automática de playlists. Além disso, alguns perfis de usuários do Spotify não representam apenas uma pessoa, mas sim uma empresa, e criam centenas de playlists com grandes quantidades de músicas. Com o intuito de diminuir a presença desses dados que não trazem a real preferência de um usuário, foi feita a remoção de perfis de usuários que possuíam mais de 100 playlists criadas e também a remoção de playlists com mais de 200 músicas.

A partir desse conjunto de usuários e playlists, foi realizada uma consulta no perfil de cada usuário para verificar se os mesmos possuíam outras playlists criadas no Spotify, já que o critério de filtragem para a análise é que o usuário tivesse criado pelo menos uma playlist relaxante e uma não relaxante, uma vez que o interesse era também estudar as diferenças das preferências dos usuários entre músicas para relaxar e músicas para outros fins. Desse modo, foi finalizada a obtenção de dados, com informações de playlists de 2.854 usuários, como podemos verificar na Tabela 3.1

Neste trabalho, ao se utilizar o termo músicas/playlists relaxantes, estar-se referindo às

³<https://developer.spotify.com/documentation/web-api/>

Tabela 3.1: Quantidade de usuários filtrados

	8tracks	Spotify
Número de Usuários	4.880	2.854

Tabela 3.2: Quantidade de músicas e playlists filtradas

	Spotify	8tracks
Número de Playlists Relaxantes	5.855	11.937
Número de Playlists Não Relaxantes	39.337	51.811
Média de Músicas por Playlist	48,45	7,08
Número de Músicas Relaxantes	271.297	52.290
Número de Músicas Não Relaxantes	1.918.512	399.160

músicas/playlists filtradas no 8tracks que possuem as tags relax ou chill, ou às músicas/playlists filtradas no Spotify pelos termos de busca relax ou chill. Ao mesmo tempo que ao utilizar o termo músicas/playlists não relaxantes, estar-se referindo a todas as outras músicas/playlists dos mesmos usuários filtrados por estas buscas.

Na Tabela 3.2, é possível verificar a quantidade de playlists e músicas que foram incluídas nas análises realizadas. Além disso, também é apresentada a média de músicas por playlist em cada plataforma. Como era de se esperar, o Spotify possui playlists bem mais longas, uma vez que o intuito do 8tracks, como o nome sugere, é que usuários criem playlists mais curtas, por volta de 8 músicas.

3.3 Enriquecimento dos Dados

Uma vez que as preferências dos usuários, ao criarem playlists, estão diretamente ligadas às características das músicas presentes nessas playlists, se fez necessária a adição de *features* musicais que pudessem caracterizar cada uma delas.

Para este enriquecimento dos dados, duas abordagens poderiam ser utilizadas: (i) processar todos os áudios das músicas e extrair as *features* de interesse, ou (ii) utilizar um serviço que já possui diversas *features* de milhões de músicas. Por não possuímos o áudio

das músicas, a primeira abordagem não era factível. Sendo assim, foi escolhida a segunda abordagem.

Após uma extensiva busca por serviços que fornecem *features* musicais de alto e baixo nível de diversas canções, foi definido o uso da API do Spotify, que, dentre os vários serviços disponibilizados, possui exatamente o que se desejava. Durante essa busca, também foi testado o uso do serviço do AcousticBrainz⁴, que é um projeto de contribuição coletiva, onde usuários processam músicas e disponibilizam suas *features* nesta plataforma, porém menos de 22% das músicas contidas nos nossos dados estavam presentes no AcousticBrainz, enquanto que no serviço do Spotify 96% estavam presentes.

Como define no seu próprio site, a API do Spotify é baseada em princípios REST, onde seus *endpoints* retornam metadados sobre músicas, artistas e álbuns, em formato JSON⁵, diretamente do catálogo de dados do Spotify. Para realizar a comunicação com a API foi utilizada a linguagem de programação Python, mais especificamente a biblioteca Spotipy⁶. Dentre os serviços disponibilizados por esta API, foram utilizados dois para este trabalho de enriquecimento de dados:

- **/audio-features/{id}**: Neste *endpoint* é retornada uma série de *features* acústicas de alto nível de uma determinada música, que deve ser distinguida por meio do seu identificador Spotify. As *features* recuperadas por este endpoint e utilizadas neste trabalho estão listadas na Tabela 3.3.
- **/audio-analysis/{id}**: Neste *endpoint* é retornado um conjunto de *features* acústicas de baixo nível de uma determinada música, que deve ser distinguida por meio do seu identificador Spotify. São *features* que descrevem características como o ritmo e timbres da música. As *features* de baixo nível utilizadas neste trabalho podem ser identificadas na Tabela 3.3.

É importante ressaltar que foi necessário, antes de utilizar a API do Spotify para obter *features* acústicas das músicas, buscar o identificador Spotify de todas as músicas do 8tracks, uma vez que essa informação não estava presente na fonte de dados que foi fornecida pelos administradores da plataforma. Para tal, utilizamos o seguinte serviço da API do Spotify:

⁴<https://acousticbrainz.org/>

⁵<https://pt.wikipedia.org/wiki/JSON>

⁶<https://spotipy.readthedocs.io/en/2.7.0/>

- **/search:** Neste *endpoint*, é possível procurar por álbuns, artistas, playlists e músicas. Dessa forma, para cada música presente nos dados do 8tracks, foi realizada uma busca onde era fornecido o título da música e o artista, e era retornada uma série de informações da canção, incluindo seu identificador Spotify.

Além de identificar e descrever cada uma das *features* utilizadas no processo de enriquecimento dos dados, na Tabela 3.3, é possível também reconhecer a dimensionalidade de cada uma delas. As dimensões estão especificadas em valores que estão entre parênteses após o nome de cada *feature*. Com isso, podemos perceber que todas as *features* de alto nível possuem apenas uma dimensão, enquanto que as de baixo nível, que descrevem o timbre, possuem 12 dimensões.

3.4 Caracterizando o Conjunto de Dados

Após todo o processo de enriquecimento dos dados obtidos do 8tracks e Spotify, foi possível dissecá-los um pouco mais. Para tal, foram calculadas algumas características destes dados que vão desde o comportamento da distribuição da quantidade de playlists por usuário em cada plataforma à distribuição dos valores das *features* de alto nível.

Primeiramente, na Figura 3.1, apresentam-se duas visualizações que discorrem sobre a distribuição da quantidade de playlists por usuário em cada uma das duas plataformas estudadas. Analisando estes gráficos, pode-se perceber que os usuários do 8tracks, em sua maioria (mais de 51,8%, especificamente), possuem até 5 playlists apenas. Por outro lado, no Spotify, apenas 32% dos usuários possuem 5 ou menos playlists. Estas diferenças podem existir pelo fato do Spotify ser uma plataforma mais difundida que o 8tracks.

Nas Figuras 3.2 e 3.3 é possível explorar a distribuição do tamanho das playlists relaxantes e não relaxantes, e entre as duas plataformas, respectivamente. Observando os Gráficos 3.2a e 3.2b verifica-se um comportamento semelhante, de forma proporcional, na distribuição do tamanho das playlists relaxantes e não relaxantes, havendo uma grande diferença apenas na quantidade de playlists em cada um dos contextos, com um número bem maior de playlists não relaxantes. Em relação à distribuição do tamanho das playlists nas duas plataformas, nota-se, de acordo com os gráficos 3.3a e 3.3b, que no 8tracks grande parte das playlists é pequena, com menos de 25 músicas, enquanto que no Spotify o tamanho

Tabela 3.3: *Features* extraídas das músicas utilizadas nas análises

<i>Features de Alto Nível</i>	
<i>Feature</i>	<i>Descrição</i>
<i>Acousticness</i> - Acusticidade (1)	Uma medida de confiança que vai de 0.0 a 1.0 que determina se a faixa é acústica. 1.0 representa alta confiança de que a música é acústica.
<i>Danceability</i> - Dançabilidade (1)	Descreve o quão compatível é uma música com a dança, baseado em uma combinação de elementos musicais incluindo compasso, estabilidade de ritmo, força da bateria e regularidade geral. O valor 0.0 é para menos dançável, e 1.0, para mais dançável.
<i>Energy</i> - Energia (1)	Vai de 0.0 a 1.0 e representa uma medida perceptiva de intensidade e atividade. Normalmente, as faixas enérgicas são rápidas, altas e barulhentas.
<i>Instrumentalness</i> - Instrumentalidade (1)	Prevê se a faixa não contém vocais. Quanto mais perto o indicador estiver de 1.0, maior a probabilidade de a música não ter conteúdo vocal.
<i>Liveness</i> - Vivacidade (1)	Detecta a presença de um público na gravação. Os valores maiores representam uma probabilidade mais alta da faixa ter sido tocada ao vivo. Vai de 0.0 a 1.0.
<i>Speechiness</i> - Fala (1)	Detecta a presença de palavras faladas em uma faixa. Quanto mais uma gravação tiver presença de fala (como talk shows, audiolivros, poesia), mais perto o atributo fica do valor 1.0.
<i>Tempo</i> - Tempo (1)	É a estimativa geral do ritmo de uma faixa em batidas por minuto (BPM).
<i>Valence</i> - Valência (1)	Uma medida de 0.0 a 1.0 que descreve a positividade musical transmitida na faixa. Faixas com alta valência soam mais positivas (felizes, alegres, eufóricas, por exemplo), enquanto faixas com baixa valência soam mais negativas (tristes, deprimidas, por exemplo).
<i>Loudness</i> - Sonoridade (1)	O volume total de uma faixa em decibéis (dB). Valores típicos variam entre -60 e 0dB.
<i>Features de Baixo Nível</i>	
<i>Feature</i>	<i>Descrição</i>
Média do Timbre (12)	O timbre permite distinguir diferentes fontes sonoras (instrumentos). Na API do Spotify, é representado por vetores de 12 dimensões.
Variância do Timbre (12)	

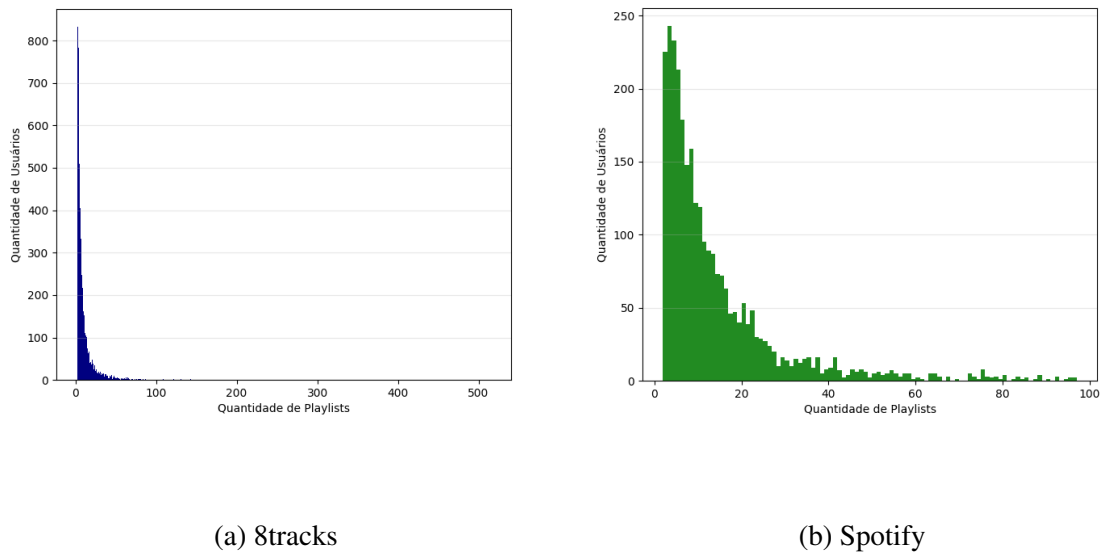


Figura 3.1: Distribuição da quantidade de playlists por usuário nas duas plataformas.

das playlists é mais distribuído, não concentrando claramente uma grande maioria em uma pequena região.

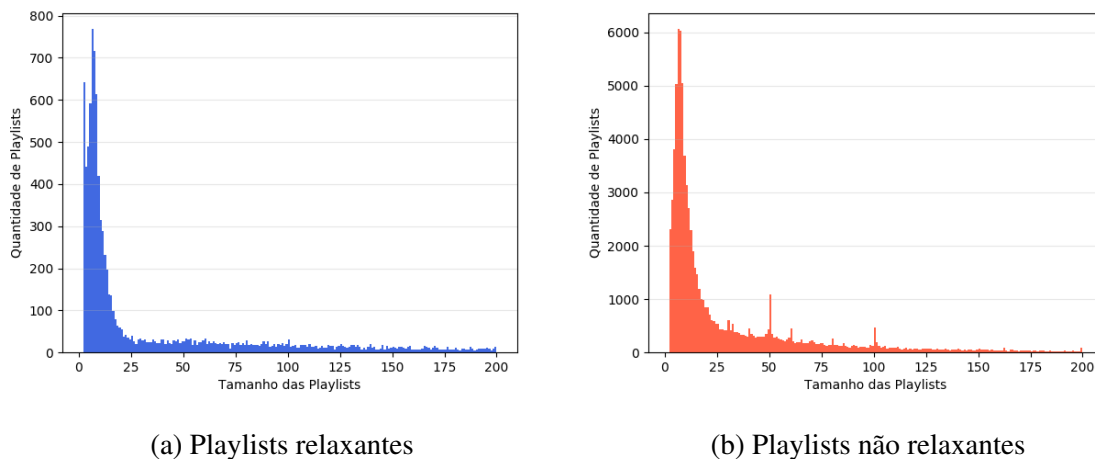


Figura 3.2: Distribuição do tamanho das playlists entre relaxantes e não relaxantes.

Uma outra característica interessante de se analisar nas músicas dos dois corpora é a popularidade. Assim como as *features* de alto nível, a popularidade das músicas também foi extraída utilizando a API do Spotify. De acordo com esta API, a popularidade de uma música é um valor entre 0 e 100, sendo 100 a mais popular. A popularidade é calculada por um algoritmo específico e baseia-se, em sua maioria, no número total de reproduções que a

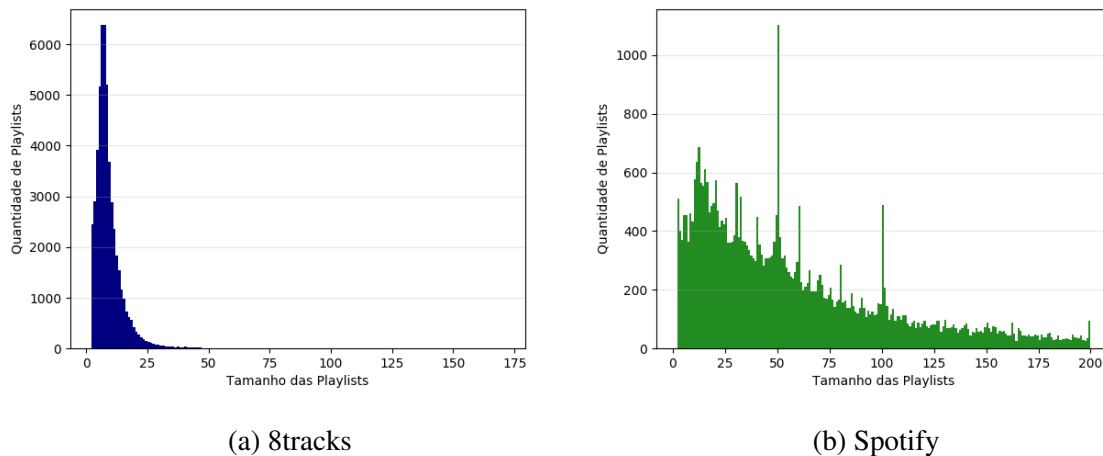


Figura 3.3: Distribuição do tamanho das playlists nas duas plataformas.

música teve e em quão recentes são essas reproduções. De acordo com a Figura 3.4, pode-se inferir que o 8tracks possui, proporcionalmente, mais músicas populares que o Spotify, nos dados utilizados nas análises.

Por fim, outra maneira de descrever os dados utilizados neste trabalho, é caracterizando as distribuições de algumas *features* de alto nível das músicas dos dois corpora. Foram escolhidas *features* que possuem um intervalo específico de domínio dos seus valores. As *features energy, liveness, speechiness, acousticness, instrumentalness, danceability e valence* possuem valores entre 0 e 1, como descritas na Tabela 3.3. Por outro lado, a *feature loudness* possui valores entre -60dB e 0dB. Esses valores de *loudness* são normalizados automaticamente pelo Spotify, com o intuito de equilibrar o volume de todas as músicas enviadas para a plataforma. Estas distribuições estão descritas na Figura 3.5. De uma forma proporcional, as distribuições dos valores dessas *features* se comportam de maneiras similares entre os dados das duas plataformas.

3.5 Considerações Finais

Neste capítulo, foi apresentado todo o processo para a obtenção dos dados, desde a apresentação das plataformas utilizadas como fontes: 8tracks e Spotify, bem como todo o processo para a escolha e recuperação das playlists e músicas a serem analisadas neste trabalho. Tabelas com algumas estatísticas sobre os dados obtidos também foram mostradas, mais




Figura 3.4: Popularidade das músicas nas duas plataformas estudadas.

especificamente as Tabelas 3.1 e 3.2.

Além disso, foi discutido a necessidade de enriquecer os dados com informações acústicas de baixo e alto nível de todas as músicas recuperadas, com o intuito de caracterizar as preferências musicais dos usuários. Cada uma das *features* extraídas foram identificadas e descritas na Tabela 3.3. O desenvolvimento de modelos matemáticos para representar as preferências dos usuários ao criarem playlists, que são discutidos no Capítulo 4, só foi possível após este enriquecimento dos dados, tornando essa etapa fundamental para o trabalho.

Posteriormente ao enriquecimento dos dados, os mesmos foram descritos por uma série de características. Todas as descrições foram calculadas sempre comparando uma plataforma com a outra ou um contexto com o outro, neste caso músicas/playlists relaxantes e músicas/playlists não relaxantes. Com estas descrições foi possível vislumbrar diferenças e similaridades entre os dois corpora utilizados nas análises desenvolvidas neste trabalho.

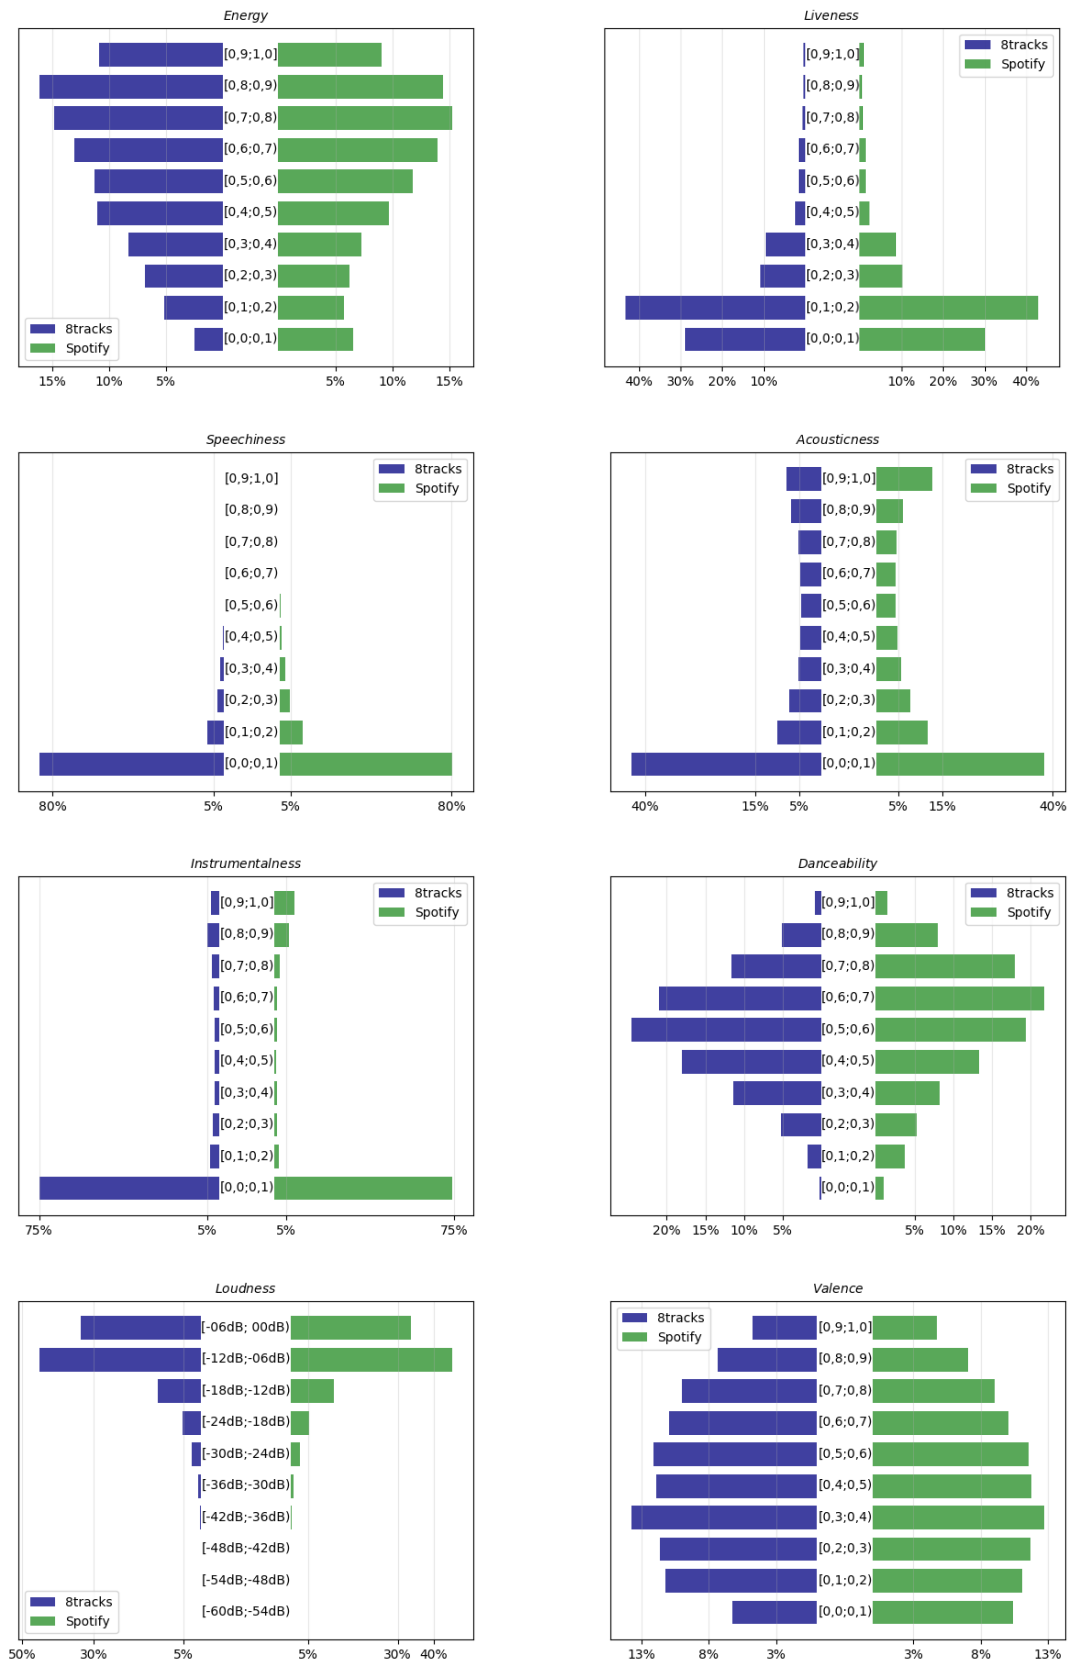


Figura 3.5: Distribuição de algumas *features* de alto nível nas músicas das duas plataformas.

Capítulo 4

Modelando as Preferências dos Usuários

Após a obtenção e enriquecimento dos dados, descritos no Capítulo 3, se fez necessária uma manipulação nos mesmos, com o intuito de criar modelos matemáticos para representar as preferências dos usuários. Essa manipulação para a criação de modelos probabilísticos ocorreu de duas formas: (i) cálculo de médias e desvios padrões de valores de *features* musicais de alto nível e; (ii) utilização de Modelos de Mistura de Gaussianas (GMM - do inglês *Gaussian Mixture Models* [48]) em *features* musicais de baixo nível.

4.1 Utilizando *Features* Musicais de Alto Nível para Modelar as Preferências dos Usuários

Com o intuito de modelar as preferências de cada usuário do conjunto de dados utilizado neste trabalho, foram utilizadas inicialmente na criação do modelo, as *features* acústicas de alto nível das músicas inseridas por cada usuário.

Neste momento, após o enriquecimento dos dados tratado no Capítulo 3, cada música existente no conjunto de dados estava sendo representada por um vetor de 33 dimensões, onde:

- 9 dimensões representam o valor de cada *feature* de alto nível, que são: *Acousticness*, *Danceability*, *Energy*, *Instrumentalness*, *Liveness*, *Speechiness*, *Tempo*, *Valence* e *Loudness*;

Tabela 4.1: Playlist de um usuário do 8tracks

<i>spotify_id</i>	<i>energy</i>	<i>liveness</i>	...	<i>loudness</i>	<i>valence</i>	Timbre - Média				Timbre - Variância					
0DAsxISzun85PbsqAfIzeC	0,778	0,128	...	-8,871	0,152	43,969	-100,904	...	-4,576	13,897	29,446	2610,833	...	180,008	83,604
2n3ZC86PWS5IFHASxfim9D	0,478	0,125	...	-22,865	0,0839	29,265	20,629	...	-19,121	-8,912	48,004	6284,655	...	684,650	448,436
0SwUDplbBp66rM5sMC0eD7	0,539	0,12	...	-5,828	0,392	49,361	36,461	...	-9,437	11,290	41,996	2369,735	...	213,960	142,098
2gFBh7NnEfSeBoZZDB5d2C	0,179	0,12	...	-14,852	0,183	37,192	-67,258	...	-8,602	-0,729	69,100	4817,471	...	313,940	206,221
3ghXwIS6cr3P5InauKlqFy	0,288	0,098	...	-10,726	0,268	41,062	-53,674	...	-9,721	-4,989	65,135	3481,432	...	297,635	158,815
0vbdsjmVzoJDFTKqa1Dz6W	0,197	0,0906	...	-11,858	0,167	41,452	-5,757	...	-8,454	2,516	58,459	3609,127	...	321,116	216,468
42raDMAj1FDvMtNxcRExux	0,119	0,112	...	-16,584	0,0893	36,884	-124,961	...	-9,934	0,012	70,580	6187,304	...	315,784	144,306
1UR0lWHLSCx2naiD7bq9FW	0,462	0,153	...	-9,135	0,23	44,970	8,630	...	-11,102	3,247	61,701	3055,865	...	236,495	235,960
1bSpwPhAxZwIR2enJsv7U	0,393	0,113	...	-10,654	0,118	46,854	-12,640	...	-9,827	-12,817	13,228	1808,333	...	113,539	150,930
4BmtCb6sdMqECAItGmFDvU	0,4	0,108	...	-10,256	0,101	43,992	-71,148	...	-6,631	10,926	57,840	5649,735	...	159,175	182,204
5wdRNfTX2ajSwEMkMGJQhq	0,167	0,175	...	-13,337	0,168	39,901	-37,540	...	-9,482	1,271	50,021	4587,599	...	390,455	195,151
1hhnbJZ7FywEL7YCyLKDgv	0,448	0,11	...	-8,081	0,164	44,433	-0,301	...	-4,671	4,320	114,315	3729,795	...	196,518	236,913
7lqu0alUmT0wKqF8cGyg1a	0,401	0,333	...	-12,062	0,211	43,881	-38,103	...	-7,450	7,872	31,048	2579,645	...	179,042	192,055

- 24 dimensões representam a média e a variância dos valores do timbre, a *feature* de baixo nível, em cada um dos 12 canais utilizados para análise pelo Spotify.

Os detalhes de cada uma dessas *features* podem ser visualizados na Tabela 3.3. Na Tabela 4.1 é possível ter uma visão geral da representação de uma playlist de um usuário do 8tracks, após o processo de enriquecimento dos dados. Além dos valores das *features*, também está presente o identificador Spotify de cada canção.

A ideia utilizada nesta abordagem inicial foi de fazer uso de métricas que conseguissem capturar características médias dos valores das *features* de alto nível, mas que também fossem sensíveis a dispersão de tais valores. Dessa forma, para representar as preferências dos usuários, em relação às *features* de alto nível, se adotou o uso da média e desvio padrão. Sendo assim, para cada *feature* de alto nível das músicas presentes nas playlists de um determinado usuário, foi calculada sua média e seu desvio padrão.

Portanto, na construção do vetor que representa as preferências de um usuário, no que diz respeito às *features* de alto nível, foram geradas 18 *features*. Por exemplo, para a *feature Energy*, foram geradas 2 *features*:

- *energy_mean*: que indica o valor médio da *feature Energy* de todas as músicas do usuário;
- *energy_stddev*: que indica o desvio padrão da *feature Energy* de todas as músicas do usuário.

Tabela 4.2: O vetor de preferência do usuário do 8tracks, considerando apenas as *features* de alto nível

	energy_mean	energy_stdev	liveness_mean	liveness_stdev	...	loudness_mean	loudness_stdev	valence_mean	valence_stdev
Usuário 8tracks	0,373	0,182	0,137	0,062	...	-11,931	4,348	0,179	0,084

Assim sendo, foi obtido, por exemplo, para o usuário que adicionou a playlist descrita na Tabela 4.1, o vetor de representação da sua preferência musical exposto na Tabela 4.2.

Para as análises deste trabalho, estes vetores de representação das preferências dos usuários ainda serão adicionados de informações sobre as *features* de baixo nível das músicas escolhidas pelos usuários. Os detalhes da obtenção destas outras informações estão descritos na Seção 4.2.

4.2 Utilizando Features Musicais de Baixo Nível para Modelar as Preferências dos Usuários

É comum utilizar o timbre como *feature* para o desenvolvimento de algoritmos em várias tarefas da área de RIM, tais como: classificação de músicas [54; 37; 21; 31], similaridade entre músicas [36; 15; 34; 33; 27] e recomendação musical [39; 9; 6; 29; 35; 61]. A ampla utilização desta *feature* está associada ao fato dela ser um eficiente descritor para distinguir fontes sonoras. Por estes motivos, o timbre também foi extraído de cada uma das músicas presentes no conjunto de dados.

Como é possível visualizar na Tabela 4.1 e na Seção 4.1, cada música do conjunto de dados possui 12 valores que descrevem a média de cada um dos coeficientes do timbre retornado pela API do Spotify, bem como 12 valores descrevendo a variância desses coeficientes.

Diferentemente da abordagem utilizada com as *features* de alto nível, para as de baixo nível não foram calculadas a média e desvio padrão, mas sim foi utilizado um Modelo de Mistura de Gaussianas [48] (GMM - do inglês *Gaussian Mixture Model*), onde cada música possui uma probabilidade de pertencer a cada um dos componentes (grupos) deste modelo.

A escolha e desenvolvimento deste modelo foram baseados em [62]. Neste trabalho, são avaliados modelos de representação da preferência musical de usuários, baseados nas características acústicas das músicas. Dentre os modelos avaliados, o que obteve melhores

resultados para a tarefa de recomendação, foi o modelo que fez uso de valores médios e desvio padrão das *features* acústicas, e também do GMM. Além disso, com o uso do GMM foi possível tornar a interpretação de milhões de vetores de números representando o timbre das músicas, mais simples de ser compreendida. Essa análise passou a ser feita em grupos de músicas com características similares de timbre.

Um modelo de misturas pode ser descrito como um modelo probabilístico que provê a representação da presença de sub-populações em uma população geral. De forma similar ao algoritmo K-means [25], o GMM também é utilizado para a tarefa de agrupamento, e foi com este intuito que este conceito foi utilizado neste trabalho. Porém, diferentemente do K-means, que é um algoritmo de agrupamento *hard*, ou seja, que associa cada ponto a apenas um grupo, o GMM define uma função de densidade de probabilidade, onde cada ponto tem uma probabilidade específica de pertencer a um determinado grupo.

Para a construção do GMM, foram utilizadas, como população geral, todas as músicas filtradas do 8tracks e Spotify. Porém, foram consideradas apenas suas *features* acústicas de baixo nível, relacionadas ao timbre. Para definir o número ideal de componentes/grupos (gaussianas) do modelo, foi utilizado o método do cotovelo como estimativa inicial. Neste método, plotamos um gráfico que identifica a variância dos dados analisados em função do número de grupos criados. Após isto, analisando este gráfico, buscamos identificar o seu cotovelo, utilizando este valor como o número ideal de grupos a serem identificados nos dados. Por exemplo, na Figura 4.1, podemos perceber que o cotovelo se encontra na configuração de 8 grupos (*clusters*) criados. No nosso cenário analisamos o gráfico do Critério de Informação Bayesiana (BIC - do inglês *Bayesian Information Criteria*). Este critério nos fornece uma estimativa de quanto o GMM é bom em termos de previsão dos dados que realmente temos. Quanto mais baixo for o BIC, melhor será o modelo para prever os dados. Para evitar *overfitting*, essa técnica penaliza modelos com grande número de clusters. Na Figura 4.1, é possível identificar que o número ideal indicado está próximo de 8, pois é onde se encontra o cotovelo do gráfico. Para validar esta estimativa, calculamos o gradiente da curva do BIC. O conceito de gradiente é simples: se dois pontos consecutivos possuem o mesmo valor, seu gradiente é zero. Se eles tiverem valores diferentes, seu gradiente poderá ser negativo, se o segundo ponto tiver um valor menor, ou positivo, caso contrário. A magnitude do gradiente nos diz o quanto os dois valores são diferentes. Dessa forma, analisando os gradientes do

BIC na Figura 4.2, podemos confirmar que a estimativa de 8 grupos está adequada, uma vez que, com mais grupos, há pouca variância nos gradientes.




Figura 4.1: Método do cotovelo para a métrica BIC

Após a construção do GMM com 8 grupos, foi calculada a probabilidade de cada música pertencer a cada um dos grupos identificados. Para cada música, estas probabilidades foram armazenadas e adicionadas ao seu vetor de representação, como pode-se verificar na Tabela 4.3. Nesta tabela está caracterizada uma música que possui, por exemplo, uma probabilidade de 98,7% de pertencer ao *cluster1* e 0,4% de pertencer ao *cluster7*. Este é o vetor final de representação das músicas analisadas neste trabalho, incluindo *features* de alto e baixo nível.

Após isto, foi possível construir a representação final de cada usuário para as análises desenvolvidas neste trabalho. É possível verificar na Tabela 4.4, que o vetor de representação de um usuário (neste exemplo um usuário da plataforma Spotify) no conjunto de dados, passou a ser composto por 26 dimensões, onde as 18 primeiras contém valores para as métricas das *features* de alto nível, e as 8 últimas representam as médias das probabilidades de pertinência das músicas que o usuário adicionou em suas playlists, a cada um dos clusters

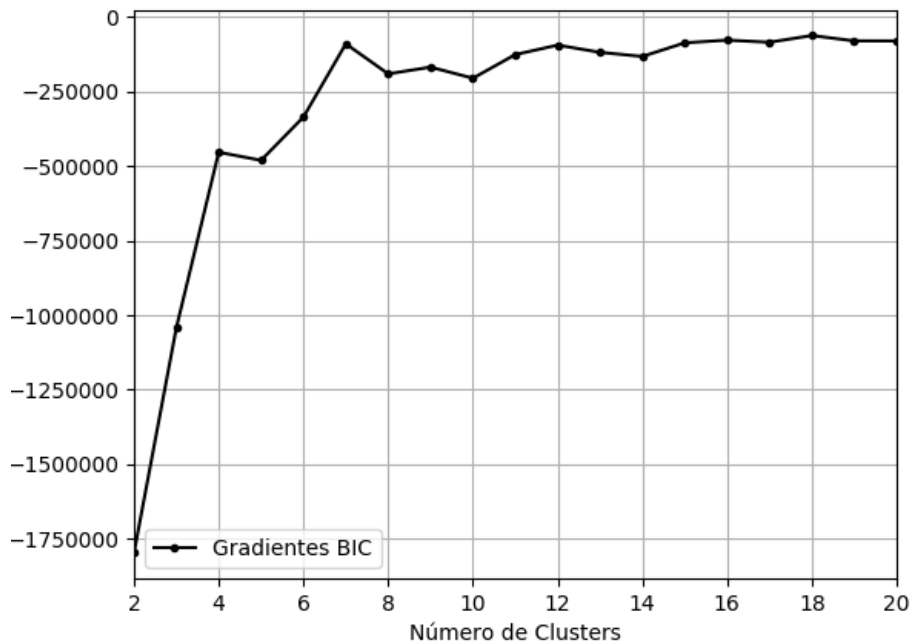


Figura 4.2: Gradientes da métrica BIC

Tabela 4.3: O vetor final de representação de cada música.

<i>spotify_id</i>	<i>energy</i>	<i>liveness</i>	...	<i>loudness</i>	<i>valence</i>	<i>cluster1</i>	<i>cluster2</i>	...	<i>cluster7</i>	<i>cluster8</i>
36dFSVGORZsU4QmZgC43v9	0.597	0.0898	...	-8.071	0.202	0.987	6.828E-33	...	0.004	8.503E-07

identificados no GMM.

Além da utilização das probabilidades de pertinência das músicas a cada um dos grupos identificados no GMM, foi realizada uma análise buscando reconhecer padrões e características de cada um desses grupos. Uma vez que as *features* de baixo nível descrevem características do timbre das músicas, os agrupamentos gerados pelo GMM evidenciaram, principalmente, as diferenças de gêneros e fontes sonoras. Fazendo uma validação facial em cada um destes grupos, foi possível verificar que:

- o Grupo 1 é composto por músicas pop;
- o Grupo 2 possui, em sua maioria, músicas executadas em piano;
- o Grupo 3 compreende as músicas clássicas;
- o Grupo 4 é constituído por músicas eletrônicas;

- o Grupo 5 é formado por músicas do gênero rock;
- o Grupo 6 detém faixas do gênero *lounge music*;
- o Grupo 7 engloba músicas executadas por instrumentos de corda, em sua maioria;
- o Grupo 8 conta com músicas que apresentam sons da natureza em sua execução.

4.3 Considerações Finais

Neste capítulo foi apresentado o processo de criação dos modelos estatísticos para representar as preferências dos usuários. Inicialmente, foi descrita a metodologia aplicada às *features* de alto nível, onde se fez uso de cálculos para identificar médias e dispersões nos dados. Logo após, foi discutido o processo de representação das *features* acústicas de baixo nível. Para tal, foi construído um GMM utilizando apenas tais *features* como representação dos dados. Como resultado da aplicação deste modelo, foram gerados valores de probabilidades que definem o grau de pertinência de uma determinada música aos grupos identificados nos dados utilizados. Esses valores foram incorporados ao vetor de representação de cada música e, por fim, suas médias foram adicionadas ao vetor de representação das preferências do usuário.

Tabela 4.4: Vetor de representação da preferência musical de um usuário do Spotify

<i>Feature</i>	<i>Valor</i>
user_id (índice)	tylerd
energy_mean	0.5927586206896551
energy_stdev	0.17451722288571933
liveness_mean	0.16979310344827586
liveness_stdev	0.11495594787021209
tempo_mean	127.38417241379311
tempo_stdev	31.48613998715372
speechiness_mean	0.03525172413793103
speechiness_stdev	0.00924181571096654
acousticness_mean	0.3994206896551724
acousticness_stdev	0.3107868370769475
instrumentalness_mean	0.19749263793103447
instrumentalness_stdev	0.27321074272985213
danceability_mean	0.5527586206896552
danceability_stdev	0.1305788363875068
loudness_mean	-8.268137931034483
loudness_stdev	4.1533049553005545
valence_mean	0.5274137931034483
valence_stdev	0.19676173358393564
cluster1	0.1871281182274398
cluster2	6.784207467605392e-12
cluster3	0.0010730667545803092
cluster4	0.039730896928228066
cluster5	0.47388889264139855
cluster6	0.06702408273158798
cluster7	0.22846165461527834
cluster8	4.173525538862751e-05

Capítulo 5

Explorando Preferências Musicais em Playlists Relaxantes

Posteriormente à definição dos modelos representativos das preferências musicais dos usuários ao criarem playlists relaxantes e playlists não relaxantes (playlists gerais), descritos no Capítulo 4, foi possível desenvolver uma análise e explorar a existência, ou não, de diferentes grupos de usuários que possuem preferências musicais distintas.

As análises englobam todos os usuários do conjunto de dados descrito no Capítulo 3, porém eles foram analisados de acordo com a plataforma que usaram para compartilhar suas playlists. Esta separação foi definida a fim de identificar possíveis diferenças nos padrões de comportamento dos usuários dessas plataformas.

5.1 Analisando os Usuários da Plataforma 8tracks

Para a plataforma 8tracks, foram analisadas as preferências musicais de 4.880 usuários. Inicialmente, foi criado um modelo de regressão logística com os vetores de preferências de todos os usuários, buscando identificar as *features* relevantes que definem o tipo de percepção do usuário: relaxante ou não relaxante. Após isto, grupos de usuários com preferências similares foram identificados nos dados e, para cada um desses grupos, foi definido um modelo de regressão logística com o mesmo intuito de identificar as *features* significativas que definem o tipo de preferência dos usuários. Nas subseções 5.1.1, 5.1.2 e 5.1.3 todos estes processos são detalhados.

5.1.1 Identificando as *Features* Relevantes de Maneira Geral

O primeiro passo para explorar a existência de diferenças nas preferências dos usuários ao criarem playlists relaxantes, foi construir um modelo de regressão logística, a fim de identificar, de maneira geral, quais as *features* mais relevantes que definem a percepção dos usuários ao criarem playlists relaxantes.

Como comentado no Capítulo 4, cada usuário do conjunto de dados passou a ser representado por dois vetores de 26 dimensões, um relativo às suas preferências ao criar playlists relaxantes e o outro relativo às suas predileções ao montar playlists não relaxantes. Foi adicionada, a cada um desses vetores, uma nova variável chamada *relax*, que assumiu valor 1 para vetores de preferências relaxantes, e valor 0 em vetores que descrevem as preferências não relaxantes dos usuários. Sendo assim, com esta modelagem, passamos a ter dados compostos por 26 variáveis independentes (as 26 dimensões dos vetores de representação dos usuários) e 1 variável dependente binária, a variável *relax*. Por estas especificidades dos dados, foi desenvolvido um modelo de regressão do tipo logístico, visando entender como a variável *relax* é explicada por todas as outras variáveis independentes.

Após ajustar o modelo de regressão logística, foi possível identificar que das 26 *features*, 18 são estatisticamente significativas para definir a percepção dos usuários como relaxante ou não (estão destacadas em negrito na Tabela 5.1). Detalhes das estimativas e valores-p de cada uma das variáveis independentes do modelo podem ser identificados na Tabela 5.1. É importante ressaltar que o nível de significância adotado no desenvolvimento deste modelo foi de 5% ($\alpha = 0,05$).

É possível observar que das 18 variáveis independentes que se mostraram estatisticamente significativas, algumas possuem maior associação com a variável dependente, como, por exemplo, as variáveis *liveness_stddev*, *speechiness_stddev*, *instrumentalness_mean* e *instrumentalness_stddev* que possuem um valor-p bem próximo a zero.

Além disso, analisando os valores das estimativas das variáveis relevantes (estatisticamente significativas), percebe-se que, de uma forma geral, músicas com valores médios menores das *features* *Energy*, *Tempo*, *Loudness* e maiores das *features* *Liveness* e *Instrumentalness* tendem a definir a preferência dos usuários do 8tracks em relação ao relaxamento. Ou seja, músicas menos enérgicas, com menos batidas por minuto e mais instrumentais soam mais relaxante para tais usuários. Um outro ponto que destaca-se, dentre as variáveis inde-

pendentes relevantes, é o fato de que valores menores em seus desvios padrões aumentam a chance da música ser considerada relaxante pelos usuários desta plataforma, de modo geral. Isto é, músicas com menos variações são preferidas para relaxar. Quanto às variáveis independentes, relacionadas aos *clusters* identificados pelo GMM, verifica-se que músicas pop, rock, executadas por instrumentos de corda e contendo sons da natureza são mais propícias a estarem presentes em playlists relaxantes de tais usuários.

5.1.2 Agrupando os Usuários De Acordo com Suas Preferências Musicais

Com o intuito de expandir a análise dos dados das preferências musicais dos usuários do 8tracks em playlists relaxantes, após identificar as *features* mais relevantes que definem as preferências de um modo geral, foi investigada a possibilidade de existência de grupos distintos de usuários que possuem preferências similares.

Para conduzir esta investigação, foi utilizado um algoritmo de agrupamento não-hierárquico. A metodologia utilizada na escolha do algoritmo foi baseada na metodologia do trabalho realizado em [20].

O algoritmo escolhido para a identificação de grupos de usuários foi o k-means [25]. A idéia básica deste algoritmo é encontrar similaridades entre os dados e agrupá-los de acordo com um número K de grupos. Para calcular a similaridade, este algoritmo utiliza o critério de distância entre dois pontos. No caso do nosso agrupamento, foi utilizada a distância euclidiana [38].

Mais detalhadamente, podemos entender o funcionamento do k-means como segue:

1. Especifica-se o número K de grupos que se deseja identificar.
2. Seleciona-se, randomicamente, K objetos do conjunto de dados para serem os centros dos grupos (centroides).
3. Associa-se cada observação ao centroide mais próximo, utilizando algum critério de distância (no nosso caso a distância euclidiana).
4. Para cada um dos K grupos, recalcula-se seu centroide como sendo a média de todos os pontos associados àquele grupo.

Tabela 5.1: Resultados da regressão logística aplicada nos modelos de preferências relaxantes dos usuários do 8tracks

	Variável Dependente:	
	relax	
	Estimativa	Valor-p
energy_mean	-0.805122	5.31e-15
energy_stdev	-0.221778	3.38e-08
liveness_mean	0.310815	2.29e-10
liveness_stdev	-0.485928	<2e-16
tempo_mean	-0.089770	0.001794
tempo_stdev	-0.016175	0.574829
speechiness_mean	0.295083	3.74e-09
speechiness_stdev	-0.589930	<2e-16
acousticness_mean	-0.008762	0.900302
acousticness_stdev	0.017477	0.652185
instrumentalness_mean	0.593429	<2e-16
instrumentalness_stdev	-0.389140	<2e-16
danceability_mean	0.206830	0.000373
danceability_stdev	-0.125224	1.55e-05
loudness_mean	-0.334152	0.001147
loudness_stdev	-0.338335	3.48e-13
valence_mean	-0.091251	0.051307
valence_stdev	-0.184916	7.43e-10
cluster1	0.256253	0.009487
cluster2	-0.040244	0.506689
cluster3	0.086718	0.243932
cluster4	0.047984	0.622582
cluster5	0.328933	0.006575
cluster6	0.145816	0.091283
cluster7	0.193004	0.011567
cluster8	0.131744	0.005764

5. Iterativamente deve-se minimizar a soma dos erros quadrados internos de cada grupo. Para isso, repete-se os passos 3 e 4 até que os centroides não mudem de valor, ou que seja atingido um determinado limite máximo de iterações.

Os erros quadrados de cada grupo podem ser definidos pela seguinte equação:

$$W(C_k) = \sum_{x_i \in C_k} (x_i - \mu_k)^2 \quad (5.1)$$

Onde:

- x_i é um dado pertencente ao grupo C_k .
- μ_k é o valor médio dos dados associados ao grupo C_k (o centroide).

Por fim, o k-means finaliza seu processamento dividindo o conjunto inicial dos dados em K conjuntos distintos. Vale salientar que este algoritmo é uma técnica de agrupamento *hard*, portanto cada dado analisado estará presente em apenas um grupo dentre os K definidos.

Para fazer uso do algoritmo k-means, deve-se inicialmente especificar o número de grupos que se deseja identificar nos dados, o valor K . Uma abordagem que se pode utilizar para estimar um ótimo valor para K é por meio do método do cotovelo (ou joelho) [30], ao plotar um gráfico onde o eixo X é o número de grupos e o eixo Y algum critério de avaliação. Para o nosso agrupamento, o critério de avaliação foi a soma total dos erros quadrados de cada grupo. Essa soma pode ser entendida pela equação 5.2 que segue, onde $W(C_k)$ é definido na equação 5.1.

$$\sum_{k=1}^k W(C_k) \quad (5.2)$$

A Figura 5.1 mostra no eixo Y a soma total dos erros quadrados de cada configuração de quantidade de grupos. Seguindo o método do cotovelo, deve-se buscar por um valor de K (eixo X) onde não se tem uma diminuição significativa no valor do eixo Y caso aumentássemos o valor de K em uma unidade. Ou seja, se aumenta o número de grupos até o momento em que a adição de mais um novo grupo não representa uma diminuição significativa na soma total dos erros quadrados. Com esta abordagem, se evita que grupos distintos possuam dados semelhantes, que talvez fossem melhor agrupados unicamente.




Figura 5.1: Soma total dos erros quadrados em diferentes configurações de quantidade de grupos a serem identificados pelo algoritmo k-means nos modelos dos usuários do 8tracks.

Ao analisar a Figura 5.1, é possível identificar que as configurações com mais de 4 ou 5 grupos não diminuem de forma significativa a variância, e é justamente nessa região que possivelmente se encontra o número ótimo de grupos a serem identificados nos dados. Com o intuito de dirimir as dúvidas sobre a quantidade exata de grupos a serem identificados, foi realizada a checagem das diferenças nos gradientes das somas totais dos erros quadrados. Essa checagem se deu de forma análoga ao procedimento descrito no Capítulo 4, durante a construção do GMM. Observando a Figura 5.2 é possível reconhecer que após a configuração com 5 grupos, o gradiente pouco se altera, sugerindo que a utilização de um valor acima de 5 para a variável K não modifica significativamente a soma total dos erros quadrados. Sendo assim, foi definido que o número ideal de grupos a serem identificados nos dados da plataforma 8tracks é 5.

Após a definição do valor ótimo de K , foi aplicado o algoritmo k-means. Como resultado deste agrupamento, foram distinguidos 5 grupos com os seguintes tamanhos:

- Grupo 1: 1.510 usuários

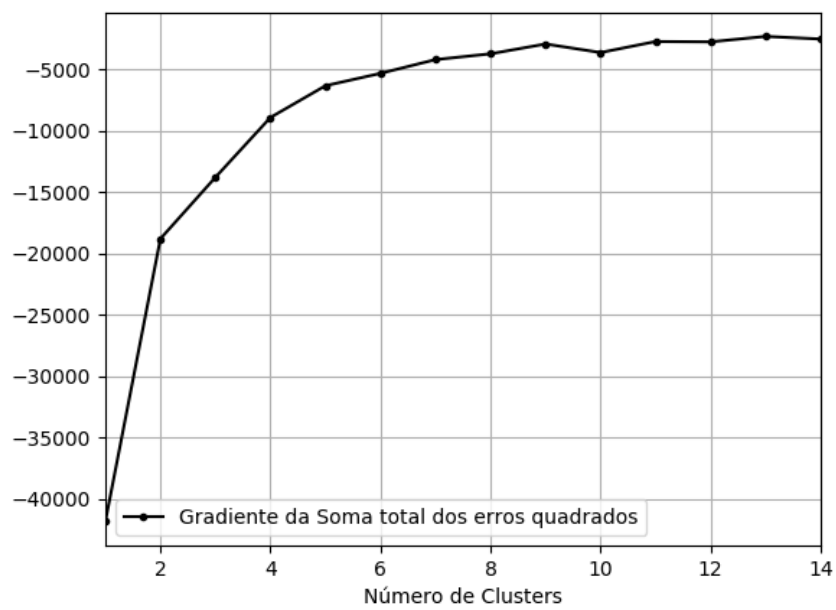


Figura 5.2: Gradientes das somas totais dos erros quadrados em diferentes configurações de quantidade de grupos a serem identificados pelo algoritmo k-means nos modelos dos usuários do 8tracks.

- Grupo 2: 1.407 usuários
- Grupo 3: 507 usuários
- Grupo 4: 288 usuários
- Grupo 5: 1.168 usuários

Para cada grupo identificado, foi feita uma análise descritiva buscando reconhecer características específicas em cada um deles, visando encontrar respostas para a **questão de pesquisa 1**. Estas análises podem ser lidas na subseção 5.1.3.

5.1.3 Identificando as *Features* Relevantes de Cada Grupo Encontrado

Fazendo uso da mesma metodologia adotada para identificar, de maneira geral, as *features* relevantes que definem a percepção dos usuários da plataforma 8tracks ao criarem playlists relaxantes, foram construídos modelos de regressão para cada um dos 5 grupos identificados pelo k-means.

Para o primeiro grupo, o maior deles, foram identificadas 11 variáveis independentes estatisticamente significativas para definir as preferências dos usuários deste grupo. Essas *features* relevantes estão destacadas em negrito na Tabela 5.2, são elas: *energy_mean*, *energy_stdev*, *liveness_stdev*, *speechiness_stdev*, *acousticness_mean*, *acousticness_stdev*, *instrumentalness_mean*, *instrumentalness_stdev*, *valence_mean*, *valence_stdev* e *cluster2*.

Ao analisar as estimativas (ou coeficientes) das variáveis independentes estatisticamente significativas, é possível verificar que dentre todas elas, a *energy_mean* e *speechiness_stdev* possuem maiores valores absolutos, o que sugere que mudanças em seus valores repercutem de forma mais efetiva na definição da percepção dos usuários. Mais especificamente, isto sugere que para os usuários do Grupo 1, músicas mais enérgicas tendem a ser menos relaxantes, assim como playlists compostas por músicas com maior variância na métrica *speechiness* tendem a ser menos relaxantes. Uma outra variável independente relevante que destaca-se é a *acousticness_mean*, que, por seu valor positivo, indica que a preferência relaxante dos usuários do Grupo 1, está diretamente relacionada com a presença de músicas acústicas, ou seja, quão maior o valor dessa variável, maiores as chances da percepção do

usuário ser relaxante. Por fim, mas não menos importante, deve-se registrar que os coeficientes dos desvios padrões de quase todas as *features* de alto nível relevantes, apontam uma predileção para relaxar ouvindo canções com menos variações.

No que diz respeito ao Grupo 2, o segundo maior grupo, ao observar a Tabela 5.3 identifica-se a presença de 14 variáveis independentes estatisticamente significativas, são elas: *liveness_mean*, *liveness_stdev*, *speechiness_mean*, *speechiness_stdev*, *acousticness_mean*, *acousticness_stdev*, *instrumentalness_mean*, *instrumentalness_stdev*, *danceability_mean*, *loudness_mean*, *loudness_stdev*, *valence_stdev*, *cluster1* e *cluster5*.

Dentre as *features* relevantes, a que possui um maior valor absoluto em seu coeficiente é a *cluster5*. Por possuir um valor positivo, conclui-se que para a população deste grupo, a sua percepção de música relaxante está diretamente ligada a valores desta variável independente. Músicas pertencentes ao *cluster5*, identificado durante a elaboração do GMM descrito no Capítulo 4, são, em regra geral, do gênero rock. Dentre algumas músicas deste cluster, podemos citar *Hysteria*, da banda Muse, e *Let The Music Do The Talking*, da banda Aerosmith. Assim como o *cluster5*, a variável independente *cluster1* também tem seu coeficiente diretamente relacionado com a percepção relaxante dos usuários do Grupo 2, ou seja, quanto maior o seu valor, maior a probabilidade da percepção ser de relaxamento. No *cluster1* estão presentes, em sua maioria, músicas pop, como por exemplo *Scars To Your Beautiful*, de Alessia Cara. Neste grupo, também percebe-se a preferência por músicas relaxantes sem variações em quase todas as suas *features* de alto nível. Nota-se também, que as preferências relaxantes destes usuários, quanto a amplitude das músicas, representada pela *feature loudness*, ratifica o padrão identificado em [58], onde músicas com menor amplitude são classificadas como relaxantes.

Quanto ao Grupo 3, o segundo menor grupo, observando a Tabela 5.4, verifica-se a existência de 10 variáveis independentes estatisticamente significativas, listadas a seguir: *energy_stdev*, *liveness_stdev*, *speechiness_stdev*, *instrumentalness_mean*, *instrumentalness_stdev*, *danceability_mean*, *loudness_mean*, *loudness_stdev*, *valence_mean* e *cluster5*.

Investigando os coeficientes das variáveis independentes relevantes para este grupo, percebe-se que a tendência de relaxamento com músicas com poucas variações nos valores da maioria de suas *features* de alto nível, se mantém. Porém, curiosamente, a variável

Tabela 5.2: Resultados da regressão logística aplicada no Grupo 1 nos modelos de preferências relaxantes dos usuários do 8tracks

	Variável Dependente:	
	relax	
	Estimativa	Valor-p
energy_mean	-0.82283	0.019543
energy_stdev	-0.49199	4.57e-05
liveness_mean	0.07725	0.651095
liveness_stdev	-0.69271	4.61e-06
tempo_mean	-0.14752	0.051226
tempo_stdev	-0.02243	0.785364
speechiness_mean	-0.08910	0.816306
speechiness_stdev	-0.86105	0.000184
acousticness_mean	0.61416	0.001160
acousticness_stdev	0.34588	0.001827
instrumentalness_mean	-0.26010	0.049504
instrumentalness_stdev	-0.34073	0.001615
danceability_mean	-0.04503	0.726464
danceability_stdev	-0.08528	0.292074
loudness_mean	-0.17036	0.495534
loudness_stdev	-0.15997	0.135540
valence_mean	-0.52233	0.000817
valence_stdev	-0.51612	5.05e-08
cluster1	0.31606	0.537149
cluster2	-0.25860	0.016079
cluster3	-0.18606	0.307545
cluster4	-0.54962	0.166071
cluster5	-0.45139	0.341711
cluster6	-0.34964	0.229794
cluster7	0.24026	0.537000
cluster8	-0.15963	0.257725

Tabela 5.3: Resultados da regressão logística aplicada no Grupo 2 nos modelos de preferências relaxantes dos usuários do 8tracks

	Variável Dependente:	
	relax	
	Estimativa	Valor-p
energy_mean	-0.21605	0.121751
energy_stdev	0.13786	0.069778
liveness_mean	0.22627	0.010500
liveness_stdev	-0.19275	0.022997
tempo_mean	0.02699	0.603591
tempo_stdev	-0.04000	0.449893
speechiness_mean	-0.58929	0.000643
speechiness_stdev	-0.59155	1.09e-06
acousticness_mean	-0.32008	0.001704
acousticness_stdev	0.15657	0.046445
instrumentalness_mean	0.34332	0.001218
instrumentalness_stdev	-0.48694	1.00e-07
danceability_mean	0.17197	0.048784
danceability_stdev	-0.09128	0.084745
loudness_mean	-0.35598	0.002446
loudness_stdev	-0.63109	1.57e-15
valence_mean	-0.01467	0.834577
valence_stdev	-0.11201	0.030096
cluster1	0.48727	0.045000
cluster2	-0.21474	0.092457
cluster3	0.03433	0.725583
cluster4	0.48908	0.082544
cluster5	1.00933	0.008401
cluster6	0.29978	0.160706
cluster7	0.30588	0.064295
cluster8	0.15198	0.073675

independente relevante que possui o maior valor absoluto em seu coeficiente, é justamente a que representa o desvio padrão da *feature* *speechiness*. Pelo seu valor positivo, pode-se inferir que playlists com músicas que variam quanto à presença ou ausência de palavras faladas (não cantadas), tendem a ser mais relaxantes para este público específico. Por fim, assim como no grupo 2, as preferências relaxantes relativas a *feature* *loudness*, neste grupo, corrobora com uma das características do padrão de músicas relaxantes descrito em [58].

Em relação ao Grupo 4, o menor dos grupos, composto por apenas 288 usuários, foi identificado apenas uma variável independente estatisticamente significativa. De acordo com a Tabela 5.5, esta variável é a *feature* *cluster4*.

O *cluster4*, identificado durante o desenvolvimento do GMM relatado neste trabalho, é composto por músicas majoritariamente eletrônicas. Um exemplo de música pertencente a este cluster é *Apollo*, de Hardwell e Amba Shepherd. Pelo valor positivo do seu coeficiente, é possível inferir que para este grupo, músicas eletrônicas tendem a ser relaxantes.

Por fim, com relação ao Grupo 5, o terceiro maior identificado, foi observada a presença de 15 variáveis independentes estatisticamente significativas. Averiguando a Tabela 5.6, pode-se listar todas estas variáveis: *energy_mean*, *liveness_mean*, *liveness_stddev*, *tempo_mean*, *speechiness_stddev*, *acousticness_stddev*, *instrumentalness_mean*, *instrumentalness_stddev*, *danceability_mean*, *danceability_stddev*, *valence_mean*, *cluster1*, *cluster6*, *cluster7* e *cluster8*.

Dentre as variáveis independentes relevantes, podemos constatar que os coeficientes de *energy_mean* e *cluster7* possuem os maiores valores absolutos. Analisando os sinais desses valores, é possível inferir que para este grupo, músicas mais enérgicas tendem a ser menos relaxantes. É também possível inferir que músicas instrumentais com a presença de instrumentos de corda, estão relacionadas positivamente com a preferência de relaxamento destes usuários, pois é o que sugere a *feature* *cluster7*, uma vez que neste cluster do GMM estão inseridas músicas deste estilo. Diferentemente dos outros 4 grupos identificados nos usuários do 8tracks, para este grupo a maioria das *features* de alto nível relevantes possui valor positivo nos coeficientes dos desvios padrões, o que sugere que músicas com maior variação nos valores dessas *features* tendem a ser mais relaxantes para tais usuários.

Tabela 5.4: Resultados da regressão logística aplicada no Grupo 3 nos modelos de preferências relaxantes dos usuários do 8tracks

	Variável Dependente:	
	relax	
	Estimativa	Valor-p
energy_mean	-0.327515	0.086823
energy_stdev	-0.397571	0.000923
liveness_mean	0.254692	0.080656
liveness_stdev	-0.418564	0.003397
tempo_mean	-0.131237	0.161490
tempo_stdev	-0.024603	0.793977
speechiness_mean	-0.195937	0.150647
speechiness_stdev	0.598439	2.08e-07
acousticness_mean	0.073026	0.671870
acousticness_stdev	-0.015464	0.910521
instrumentalness_mean	0.372727	0.032764
instrumentalness_stdev	-0.392923	0.003964
danceability_mean	0.339616	0.025295
danceability_stdev	-0.119242	0.181003
loudness_mean	-0.481578	0.008243
loudness_stdev	-0.551364	6.83e-06
valence_mean	0.287752	0.009462
valence_stdev	-0.131019	0.141441
cluster1	0.071385	0.680158
cluster2	-0.207491	0.104996
cluster3	0.059760	0.552138
cluster4	0.024326	0.926934
cluster5	-0.448107	0.045216
cluster6	-0.001282	0.995837
cluster7	-0.096982	0.507646
cluster8	0.088651	0.402657

Tabela 5.5: Resultados da regressão logística aplicada no Grupo 4 nos modelos de preferências relaxantes dos usuários do 8tracks

	Variável Dependente:	
	relax	
	Estimativa	Valor-p
energy_mean	-1.44074	0.2962
energy_stdev	0.25950	0.5952
liveness_mean	0.94299	0.1886
liveness_stdev	-0.67013	0.2426
tempo_mean	-0.11018	0.6901
tempo_stdev	0.24444	0.3129
speechiness_mean	-0.00655	0.9950
speechiness_stdev	-0.41889	0.5384
acousticness_mean	0.55752	0.3848
acousticness_stdev	0.15735	0.6352
instrumentalness_mean	1.11304	0.0806
instrumentalness_stdev	0.06502	0.8460
danceability_mean	0.76268	0.3702
danceability_stdev	0.43453	0.1343
loudness_mean	0.37617	0.6865
loudness_stdev	0.14402	0.6952
valence_mean	-2.00303	0.0517
valence_stdev	-0.18144	0.7068
cluster1	0.39007	0.5617
cluster2	0.89969	0.3364
cluster3	0.12183	0.9304
cluster4	1.87637	0.0349
cluster5	-0.38533	0.6410
cluster6	-0.08249	0.8861
cluster7	-0.14449	0.7795
cluster8	0.54058	0.4389

Tabela 5.6: Resultados da regressão logística aplicada no Grupo 5 nos modelos de preferências relaxantes dos usuários do 8tracks

	Variável Dependente:	
	relax	
	Estimativa	Valor-p
energy_mean	-0.71095	0.000353
energy_stdev	0.07700	0.411231
liveness_mean	0.27444	0.029534
liveness_stdev	-0.42143	0.000153
tempo_mean	-0.19135	0.004253
tempo_stdev	0.04111	0.551459
speechiness_mean	-0.19990	0.328617
speechiness_stdev	-0.55939	4.09e-05
acousticness_mean	0.15056	0.243799
acousticness_stdev	0.35629	7.73e-05
instrumentalness_mean	0.30691	0.004656
instrumentalness_stdev	0.44423	4.97e-08
danceability_mean	0.38762	0.001862
danceability_stdev	0.20661	0.002779
loudness_mean	0.08363	0.647113
loudness_stdev	0.03523	0.730132
valence_mean	-0.43198	3.20e-05
valence_stdev	0.13021	0.053326
cluster1	0.32827	0.032409
cluster2	-0.08506	0.277535
cluster3	0.22225	0.071233
cluster4	-0.05776	0.734105
cluster5	0.17918	0.389538
cluster6	0.39855	0.017062
cluster7	0.68405	7.89e-06
cluster8	0.39300	0.000209

5.1.4 Considerações Finais Sobre os Grupos Identificados no 8tracks

Na Tabela 5.7 é possível ter uma visão geral das variáveis independentes significativas em cada um dos modelos de regressão logística construídos para os 5 grupos identificados nos dados dos usuários da plataforma 8tracks. Cada um destes modelos possui um conjunto distinto de variáveis independentes significativas, sugerindo que, de fato, existem diferenças nas preferências dos usuários dessa plataforma em playlists relaxantes, levando em consideração o modelo de representação definido neste trabalho. Esta constatação responde positivamente, de forma parcial, a **questão de pesquisa 1**. Além dessas diferenças identificadas, também foi possível encontrar comportamentos semelhantes, como por exemplo entre os grupos 1, 2, 3 e 4, onde, em geral, músicas com menos variações nos valores de suas *features* de alto nível tendem a ser mais relaxantes.

5.2 Analisando os Usuários da Plataforma Spotify

Seguindo a mesma metodologia adotada durante as análises das preferências dos usuários da plataforma 8tracks, foram analisadas as preferências musicais de 2.854 usuários da plataforma Spotify.

Em um primeiro momento, foi proposto um modelo de regressão logística a fim de investigar, de maneira geral, as preferências de todos os usuários desta plataforma em relação a playlists relaxantes. Logo após, os usuários foram divididos em grupos similares de preferências musicais, determinados pelos seus vetores de representação de preferências. Em cada um destes grupos, foi projetado um modelo de regressão logística, visando identificar as *features* significativas em cada um deles, com o intuito de compará-las e observar a existência, ou não, de diferenças entre os conjuntos de *features*. Todo estes processos são descritos nas subseções 5.2.1, 5.2.2 e 5.2.3

5.2.1 Identificando as *Features* Relevantes de Maneira Geral

Antes de distribuir os usuários do Spotify em grupos com vetores de preferências similares, se buscou identificar, de maneira geral, as *features* relevantes que melhor caracterizam o tipo de percepção dos usuários desta plataforma. Para tal, foi desenvolvido um modelo de

Tabela 5.7: Resultados das regressões logísticas aplicadas nos 5 grupos identificados nos usuários do 8tracks

Variável Independente	Valor-p				
	Grupo 1	Grupo 2	Grupo 3	Grupo 4	Grupo 5
energy_mean	0.019543	0.121751	0.086823	0.2962	0.000353
energy_stdev	4.57e-05	0.069778	0.000923	0.5952	0.411231
liveness_mean	0.651095	0.010500	0.080656	0.1886	0.029534
liveness_stdev	4.61e-06	0.022997	0.003397	0.2426	0.000153
tempo_mean	0.051226	0.603591	0.161490	0.6901	0.004253
tempo_stdev	0.785364	0.449893	0.793977	0.3129	0.551459
speechiness_mean	0.816306	0.000643	0.150647	0.9950	0.328617
speechiness_stdev	0.000184	1.09e-06	2.08e-07	0.5384	4.09e-05
acousticness_mean	0.001160	0.001704	0.671870	0.3848	0.243799
acousticness_stdev	0.001827	0.046445	0.910521	0.6352	7.73e-05
instrumentalness_mean	0.049504	0.001218	0.032764	0.0806	0.004656
instrumentalness_stdev	0.001615	1.00e-07	0.003964	0.8460	4.97e-08
danceability_mean	0.726464	0.048784	0.025295	0.3702	0.001862
danceability_stdev	0.292074	0.084745	0.181003	0.1343	0.002779
loudness_mean	0.495534	0.002446	0.008243	0.6865	0.647113
loudness_stdev	0.135540	1.57e-15	6.83e-06	0.6952	0.730132
valence_mean	0.000817	0.834577	0.009462	0.0517	3.20e-05
valence_stdev	5.05e-08	0.030096	0.141441	0.7068	0.053326
cluster1	0.537149	0.045000	0.680158	0.5617	0.032409
cluster2	0.016079	0.092457	0.104996	0.3364	0.277535
cluster3	0.307545	0.725583	0.552138	0.9304	0.071233
cluster4	0.166071	0.082544	0.926934	0.0349	0.734105
cluster5	0.341711	0.008401	0.045216	0.6410	0.389538
cluster6	0.229794	0.160706	0.995837	0.8861	0.017062
cluster7	0.537000	0.064295	0.507646	0.7795	7.89e-06
cluster8	0.257725	0.073675	0.402657	0.4389	0.000209

regressão logística, ajustado com os dados de todos os usuários do Spotify.

Assim como os usuários do 8tracks, cada usuário do Spotify também teve suas preferências representadas por vetores de 26 dimensões, um relativo às suas preferências ao criar playlists relaxantes e o outro relativo às suas predileções ao montar outras playlists. Em cada vetor foi adicionada uma variável dependente chamada *relax*, possuindo valor 1 nos vetores das preferências relaxantes e valor 0 nos outros vetores. Dessa forma, foi construído um modelo com 26 variáveis independentes e 1 variável dependente binária.

Analisando a Tabela 5.8 pode-se detectar que das 26 variáveis independentes do modelo proposto, 19 se mostraram estatisticamente significativas. Para ser considerada estatisticamente significativa, uma variável independente deve possuir um valor-p menor que o nível de significância adotado no modelo, que foi de 5% ($\alpha = 0,05$). Portanto, todas as *features* que estão em negrito na Tabela 5.8 são significativas.

Das 19 variáveis independentes estatisticamente significativas, algumas possuem maior associação com a variável dependente, como por exemplo as variáveis *energy_stdev*, *speechiness_stdev* e *danceability_stdev* que possuem os menores valores-p. Um outro fato que caracteriza a população analisada é a influência da *feature energy_mean* para a definição do tipo de preferência dos usuários, como se pode observar pelo valor absoluto da sua estimativa (ou coeficiente), onde músicas menos enérgicas tendem a ser mais relaxantes para estes usuários. Percebe-se também, analisando os coeficientes dos desvios padrões das *features* de alto nível, uma predileção destes usuários para relaxar ouvindo músicas com menos variações nos valores dessas *features*. Por fim, nota-se, curiosamente, que, de modo geral, os usuários do Spotify analisados neste estudo, tendem a não escolher músicas executadas em piano, e nem músicas clássicas ao criarem playlists relaxantes, como pode-se verificar pelos valores dos coeficientes das variáveis independentes *cluster1* e *cluster2*, que remetem aos dois primeiros *clusters* identificados pelo GMM desenvolvido no Capítulo 4.

5.2.2 Agrupando os Usuários De Acordo com Suas Preferências Musicais

Objetivando responder a **questão de pesquisa 1**, foi utilizada a mesma abordagem de divisão dos usuários descrita na subseção 5.1.2, com os usuários do Spotify. Essa divisão se baseia

Tabela 5.8: Resultados da regressão logística aplicada nos modelos de preferências relaxantes dos usuários do Spotify

	Variável Dependente:	
	relax	
	Estimativa	Valor-p
energy_mean	-1.32683	2.20e-09
energy_stdev	-0.73133	5.39e-15
liveness_mean	0.21472	0.009185
liveness_stdev	-0.16686	0.026659
tempo_mean	-0.37059	2.45e-10
tempo_stdev	0.32503	9.52e-12
speechiness_mean	-0.16538	0.037833
speechiness_stdev	-0.60749	8.35e-15
acousticness_mean	-0.41908	0.009490
acousticness_stdev	0.40850	1.95e-06
instrumentalness_mean	0.35122	0.023621
instrumentalness_stdev	-0.30795	3.77e-07
danceability_mean	0.27777	0.147661
danceability_stdev	-0.48365	9.28e-16
loudness_mean	-0.28268	0.173628
loudness_stdev	-0.29501	0.002568
valence_mean	-0.50887	8.72e-07
valence_stdev	-0.41758	7.54e-10
cluster1	0.16837	0.273771
cluster2	-0.87937	1.80e-11
cluster3	-0.56965	0.000938
cluster4	-0.10873	0.508693
cluster5	0.17585	0.345247
cluster6	0.23985	0.106728
cluster7	0.06184	0.479282
cluster8	0.05004	0.604282

em identificar grupos de usuários que possuem vetores de preferências musicais relaxantes similares.

Para definir o número de grupos a serem identificados nos dados dos usuários do Spotify também foi utilizada a abordagem do método do cotovelo aplicado ao gráfico das somas totais dos erros quadrados em diferentes configurações de quantidade de grupos. Analisando a Figura 5.3, se tem a impressão que para uma configuração com mais de 4 grupos, não há uma diminuição significativa da variância. Com o intuito de confirmar a suspeita inicial de que o número ideal de grupos é 4, foi realizada uma verificação nos gradientes das somas totais dos erros quadrados. Observando a Figura 5.4 é possível identificar que após a configuração com 4 grupos, o gradiente pouco se altera, o que sugere que a suspeita inicial de que o número ideal de grupos a serem identificados nos dados dos usuários do Spotify é 4, estava correta.




Figura 5.3: Soma total dos erros quadrados em diferentes configurações de quantidade de grupos a serem identificados pelo algoritmo k-means nos modelos dos usuários do Spotify.

Após a definição do valor ótimo de K , foi aplicado o algoritmo k-means. Como resultado deste agrupamento, foram distinguidos 4 grupos com os seguintes tamanhos:

- Grupo 1: 404 usuários

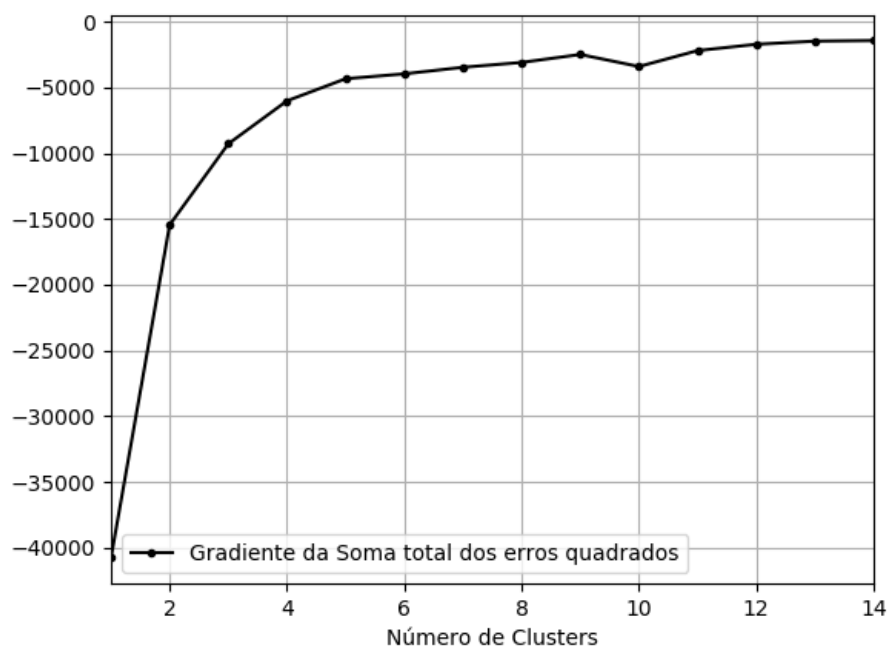


Figura 5.4: Gradientes das somas totais dos erros quadrados em diferentes configurações de quantidade de grupos a serem identificados pelo algoritmo k-means nos modelos dos usuários do Spotify.

- Grupo 2: 387 usuários
- Grupo 3: 1.153 usuários
- Grupo 4: 910 usuários

Para cada grupo identificado, foi feita uma análise descritiva buscando identificar características específicas em cada um deles, visando encontrar respostas para a **questão de pesquisa 1**. Estas análises estão descritas na subseção 5.2.3.

5.2.3 Identificando as *Features* Relevantes de Cada Grupo Encontrado

Utilizando a mesma abordagem adotada para identificar, de maneira geral, as *features* relevantes que definem a percepção dos usuários do Spotify ao criarem playlists relaxantes e demais playlists, foram construídos modelos de regressão para cada um dos 4 grupos identificados pelo k-means.

Para o primeiro grupo, o segundo menor deles, foram identificadas 7 variáveis independentes estatisticamente significativas para definir as preferências dos usuários deste grupo. Essas *features* relevantes estão destacadas em negrito na Tabela 5.9, são elas: *energy_mean*, *liveness_mean*, *liveness_stdev*, *speechiness_stdev*, *loudness_mean*, *valence_stdev* e *cluster4*.

Ao analisar as estimativas (ou coeficientes) das variáveis independentes estatisticamente significativas, é possível verificar que dentre todas elas, o *cluster4* possui maior valor absoluto, sugerindo que mudanças em seu valor repercutem de forma mais efetiva na definição da percepção dos usuários. O *cluster4*, identificado no GMM construído neste trabalho, é composto por músicas eletrônicas em sua grande maioria, sendo assim, para este grupo de usuários, músicas eletrônicas tendem a ser não relaxantes. Devemos destacar também que músicas com valores maiores das *features liveness* e *loudness*, tendem a ser relaxantes. Por fim, nota-se que, playlists contendo músicas menos enérgicas, são características da percepção relaxante deste grupo.

Quanto ao Grupo 2, o menor deles, observando a Tabela 5.10, é possível perceber a existência de 8 variáveis independentes estatisticamente significativas, listadas a seguir: *liveness_stdev*, *speechiness_stdev*, *instrumentalness_stdev*, *danceability_mean*, *valence_mean*, *cluster2*, *cluster4* e *cluster6*.

Tabela 5.9: Resultados da regressão logística aplicada no Grupo 1 nos modelos de preferências relaxantes dos usuários do Spotify

	Variável Dependente:	
	relax	
	Estimativa	Valor-p
energy_mean	-1.92598	0.03180
energy_stdev	0.20914	0.60901
liveness_mean	1.30188	0.01355
liveness_stdev	-0.77859	0.02057
tempo_mean	0.25194	0.36380
tempo_stdev	-0.22883	0.20302
speechiness_mean	0.70235	0.31799
speechiness_stdev	-0.95294	0.01056
acousticness_mean	-0.16648	0.83943
acousticness_stdev	-0.43591	0.30333
instrumentalness_mean	-0.42878	0.59773
instrumentalness_stdev	-0.54979	0.09056
danceability_mean	-1.36575	0.07161
danceability_stdev	0.41980	0.11363
loudness_mean	1.51652	0.00235
loudness_stdev	0.38682	0.10143
valence_mean	0.28131	0.73963
valence_stdev	-1.24197	0.00988
cluster1	0.01672	0.97373
cluster2	0.22962	0.80422
cluster3	-0.22188	0.82789
cluster4	-10.20208	0.00196
cluster5	-0.47719	0.68209
cluster6	-0.16714	0.77337
cluster7	0.26999	0.51085
cluster8	0.35161	0.42415

Investigando os coeficientes das variáveis independentes relevantes deste grupo, pode-se detectar que as *features cluster4*, *danceability_mean* e *valence_mean* possuem os maiores valores absolutos. Pelos sinais dos coeficientes, observa-se que neste grupo estão presentes usuários que em suas preferências, músicas eletrônicas e positivas tendem a ser não relaxantes, enquanto músicas dançantes tendem a ser relaxantes.

Em relação ao Grupo 3, o maior de todos, foi observada a presença de 8 *features* relevantes, ou seja, 8 variáveis independentes estatisticamente significativas. Olhando a Tabela 5.11, podemos listar todas estas variáveis: *energy_mean*, *energy_stdev*, *tempo_mean*, *tempo_stdev*, *speechiness_mean*, *acousticness_mean*, *acousticness_stdev* e *valence_stdev*.

Dentre as *features* relevantes para este grupo, as duas com maiores valores absolutos de coeficientes são *speechiness_mean* e *energy_mean*. Pelos sinais destes valores, é possível verificar que músicas com a presença de vozes tendem a ser não relaxantes, assim como músicas enérgicas.

Finalmente, no que diz respeito ao Grupo 4, o segundo maior, se pode verificar na Tabela 5.12 a existência de 11 variáveis independentes significativas, são elas: *energy_stdev*, *tempo_mean*, *tempo_stdev*, *speechiness_mean*, *instrumentalness_stdev*, *danceability_stdev*, *loudness_mean*, *loudness_stdev*, *valence_mean*, *valence_stdev* e *cluster3*.

Das 11 *features* relevantes, a que possui o maior valor absoluto do seu coeficiente é a *loudness_mean*. Por possuir um sinal negativo, indica que para os usuários pertencentes a este grupo, músicas com maiores intensidades sonoras tendem a ser não relaxantes. Percebe-se também, que as preferências relaxantes destes usuários, quanto a amplitude das músicas, representada pela *feature loudness*, reforça o padrão identificado em [58], onde músicas com menor amplitude são classificadas como relaxantes. Outra característica que sobressai, ao analisar os coeficientes das variáveis independentes relevantes, é a preferência destes usuários por músicas com pouca variação nos valores de suas *features* de alto nível.

5.2.4 Considerações Finais Sobre os Grupos Identificados no Spotify

Na Tabela 5.13 é possível ter uma visão completa de cada um dos modelos de regressão logística utilizados para identificar as variáveis independentes estatisticamente significativas em cada um dos grupos de usuários do Spotify. Percebe-se que tais modelos possuem diferentes conjuntos de *features* relevantes, indicando que, utilizando o modelo de representação das

Tabela 5.10: Resultados da regressão logística aplicada no Grupo 2 nos modelos de preferências relaxantes dos usuários do Spotify

	Variável Dependente:	
	relax	
	Estimativa	Valor-p
energy_mean	-0.367593	0.596302
energy_stdev	-0.243040	0.389628
liveness_mean	0.352674	0.197523
liveness_stdev	-0.896233	0.000912
tempo_mean	-0.296687	0.103006
tempo_stdev	0.250095	0.119716
speechiness_mean	0.439064	0.247924
speechiness_stdev	-0.687991	0.022786
acousticness_mean	-0.156940	0.718408
acousticness_stdev	0.166141	0.503417
instrumentalness_mean	-0.155610	0.683289
instrumentalness_stdev	0.566087	0.000924
danceability_mean	1.239500	0.019898
danceability_stdev	-0.315408	0.143484
loudness_mean	-0.340700	0.468727
loudness_stdev	-0.278156	0.260635
valence_mean	-1.011346	0.006578
valence_stdev	-0.228130	0.276402
cluster1	0.348562	0.283382
cluster2	-0.602411	0.006002
cluster3	-0.003946	0.992420
cluster4	-1.561047	0.000433
cluster5	-0.629984	0.145842
cluster6	-0.734955	0.044431
cluster7	0.495355	0.130265
cluster8	0.016736	0.945985

Tabela 5.11: Resultados da regressão logística aplicada no Grupo 3 nos modelos de preferências relaxantes dos usuários do Spotify

	Variável Dependente:	
	relax	
	Estimativa	Valor-p
energy_mean	-1.78346	0.000106
energy_stdev	-1.13446	6.70e-10
liveness_mean	-0.09553	0.564623
liveness_stdev	0.01331	0.935054
tempo_mean	-0.26061	0.003875
tempo_stdev	0.50705	4.23e-08
speechiness_mean	-1.98775	2.68e-07
speechiness_stdev	0.03337	0.892931
acousticness_mean	-1.00604	0.000327
acousticness_stdev	0.75222	6.71e-06
instrumentalness_mean	0.16738	0.403747
instrumentalness_stdev	-0.09773	0.541317
danceability_mean	0.05666	0.818571
danceability_stdev	-0.06611	0.549106
loudness_mean	0.25945	0.429309
loudness_stdev	-0.17713	0.387875
valence_mean	-0.19339	0.307357
valence_stdev	-0.32533	0.008621
cluster1	1.09611	0.160849
cluster2	-0.54307	0.111588
cluster3	-0.32890	0.195070
cluster4	0.32188	0.655677
cluster5	1.27178	0.134445
cluster6	0.55782	0.301132
cluster7	0.42780	0.238888
cluster8	-0.08084	0.554612

Tabela 5.12: Resultados da regressão logística aplicada no Grupo 4 nos modelos de preferências relaxantes dos usuários do Spotify

	Variável Dependente:	
	relax	
	Estimativa	Valor-p
energy_mean	-0.17269	0.460432
energy_stdev	-0.53164	4.93e-05
liveness_mean	-0.24533	0.137499
liveness_stdev	0.21474	0.145442
tempo_mean	-0.27561	0.000169
tempo_stdev	0.24473	0.005588
speechiness_mean	-0.65102	8.78e-05
speechiness_stdev	-0.18423	0.140768
acousticness_mean	-0.02064	0.894684
acousticness_stdev	-0.07000	0.635272
instrumentalness_mean	-0.19669	0.243443
instrumentalness_stdev	-0.25628	0.043790
danceability_mean	-0.29114	0.107130
danceability_stdev	-0.36304	0.000277
loudness_mean	-1.15218	2.86e-07
loudness_stdev	-0.38216	0.016202
valence_mean	-0.24868	0.037986
valence_stdev	-0.21829	0.005238
cluster1	0.36873	0.109770
cluster2	-0.81880	0.082155
cluster3	-0.45436	0.000147
cluster4	0.36841	0.191121
cluster5	-0.11071	0.710929
cluster6	0.58011	0.054214
cluster7	-0.03851	0.739656
cluster8	0.07922	0.315370

preferências dos usuários definido no Capítulo 4, há diferenças nas preferências dos usuários em playlists relaxantes e também em playlists gerais. A constatação deste fato responde, parcialmente, de forma positiva a **questão de pesquisa 1**. Assim como na plataforma 8tracks, além de evidenciar diferenças entre os grupos, foi possível identificar comportamentos afins entre os usuários do Spotify. Estes comportamentos similares podem ser observados analisando os valores dos desvios padrões das *features* de alto nível, onde, em sua maioria, quanto menores forem, maiores as chances de estarem definindo as preferências relaxantes destes usuários.

Tabela 5.13: Resultados das regressões logísticas aplicadas nos 4 grupos identificados nos usuários do Spotify

Variável Independente	Valor-p			
	Grupo 1	Grupo 2	Grupo 3	Grupo 4
energy_mean	0.03180	0.596302	0.000106	0.460432
energy_stdev	0.60901	0.389628	6.70e-10	4.93e-05
liveness_mean	0.01355	0.197523	0.564623	0.137499
liveness_stdev	0.02057	0.000912	0.935054	0.145442
tempo_mean	0.36380	0.103006	0.003875	0.000169
tempo_stdev	0.20302	0.119716	4.23e-08	0.005588
speechiness_mean	0.31799	0.247924	2.68e-07	8.78e-05
speechiness_stdev	0.01056	0.022786	0.892931	0.140768
acousticness_mean	0.83943	0.718408	0.000327	0.894684
acousticness_stdev	0.30333	0.503417	6.71e-06	0.635272
instrumentalness_mean	0.59773	0.683289	0.403747	0.243443
instrumentalness_stdev	0.09056	0.000924	0.541317	0.043790
danceability_mean	0.07161	0.019898	0.818571	0.107130
danceability_stdev	0.11363	0.143484	0.549106	0.000277
loudness_mean	0.00235	0.468727	0.429309	2.86e-07
loudness_stdev	0.10143	0.260635	0.387875	0.016202
valence_mean	0.73963	0.006578	0.307357	0.037986
valence_stdev	0.00988	0.276402	0.008621	0.005238
cluster1	0.97373	0.283382	0.160849	0.109770
cluster2	0.80422	0.006002	0.111588	0.082155
cluster3	0.82789	0.992420	0.195070	0.000147
cluster4	0.00196	0.000433	0.655677	0.191121
cluster5	0.68209	0.145842	0.134445	0.710929
cluster6	0.77337	0.044431	0.301132	0.054214
cluster7	0.51085	0.130265	0.238888	0.739656
cluster8	0.42415	0.945985	0.554612	0.315370

Capítulo 6

Explorando as Diferenças das Preferências Musicais dos Usuários entre as Playlists Relaxantes e as Playlists Gerais

Com o intuito de tentar responder a **questão de pesquisa 2**, foi realizado um estudo visando identificar a existência de diferenças nas preferências musicais dos usuários entre suas playlists relaxantes e outras playlists gerais. Além da identificação da existência de diferenças, também foi realizada uma análise descrevendo tais diferenças

Como comentado no Capítulo 4, neste trabalho foram criados modelos para representar as preferências dos usuários ao criarem playlists. Para cada usuário, foi desenvolvido um modelo que corresponde à preferência sobre músicas relaxantes e outro modelo correspondente às preferências acerca de músicas gerais.

Uma vez que o interesse nesta etapa da pesquisa era identificar a existência de desigualdades nas preferências de um mesmo usuário, foi calculada a diferença dos modelos de cada usuário, como podemos observar na Tabela 6.1. Interpretando esta tabela, percebe-se que um novo vetor de preferências foi obtido após a subtração de cada uma das *features* do vetor de representação do relaxamento pelos valores do vetor de representação de preferência geral do usuário. Dessa maneira, valores negativos resultantes dessas subtrações apontam para um aumento do valor da *feature* no vetor de representação geral das preferências do usuário

em relação ao vetor de representação das preferências de relaxamento, como por exemplo na *feature energy_mean* na Tabela 6.1. De forma análoga, resultados positivos provenientes dessas subtrações indicam uma diminuição do valor da *feature* no vetor de representação das preferências gerais, como por exemplo na *feature acousticness_mean* exposta na Tabela 6.1.

Com estes vetores de diferença nas preferências calculados, deu-se início a uma análise descritiva dos mesmos. Nesta análise, foi possível identificar a existência de diferenças nas preferências musicais dos usuários entre suas playlists relaxantes e outras playlists gerais. Todas as análises conduzidas neste escopo da pesquisa estão descritas ao longo de todo este capítulo.

6.1 Analisando os Usuários da Plataforma 8tracks

6.1.1 Agrupando os Usuários De Acordo com Suas Diferenças das Preferências Musicais

Assim como descrito no Capítulo 5, nesta etapa da análise também foi utilizada a abordagem de buscar identificar grupos distintos de usuários de acordo com seus vetores de representação. Neste caso, para este momento, este agrupamento visou identificar grupos de usuários que possuem diferenças similares entre seus vetores de representação de relaxamento e preferências gerais.

Para a identificação de tais grupos, foi utilizado o algoritmo k-means. Desse modo, como relatado no Capítulo 5, se fez necessário estimar um número ótimo de grupos a serem identificados nos dados. Seguindo a mesma metodologia adotada anteriormente, foi utilizado o método do cotovelo aplicado ao gráfico das somas totais dos erros quadrados em diferentes configurações de quantidade de grupos. Analisando a Figura 6.1, tem-se a impressão que para uma configuração com mais de 3 grupos, não há uma diminuição significativa da variância. Com o intuito de confirmar a suspeita inicial de que o número ideal de grupos é 3, foi realizada uma checagem nos gradientes das somas totais dos erros quadrados. Observando a Figura 6.2, é possível identificar que após a configuração com 3 grupos, o gradiente pouco se altera, o que sugere que a suspeita inicial de que o número ideal de grupos a serem identificados nos dados dos usuários do 8tracks é 3, estava correta.

Tabela 6.1: Exemplo de cálculo do vetor para representar as diferenças entre as preferências do usuário entre playlists relaxantes e playlists gerais.

<i>Features</i>	Representação Relaxante	Representação Geral	Representação da Diferença
energy_mean	0.3827833333333336	0.58786	-0.2050766666666668
energy_stdev	0.2558829452438491	0.24097825896565367	0.014904686278195384
liveness_mean	0.1714333333333333	0.17197714285714286	-0.0005438095238095297
liveness_stdev	0.09781692423434028	0.10721657325167566	-0.009399649017335393
tempo_mean	114.6825	116.98348571428572	-2.3009857142857157
tempo_stdev	30.41468625351904	28.916347977827176	1.4983382756918644
speechiness_mean	0.04336666666666664	0.05536571428571428	-0.011999047619047624
speechiness_stdev	0.01660766891127911	0.056940572441063195	-0.040332903529784095
acousticness_mean	0.6298333333333334	0.32060789714285715	0.3092254361904762
acousticness_stdev	0.37558776160395146	0.3316703413087348	0.04391742029521667
instrumentalness_mean	0.15241666666666667	0.061602408857142854	0.09081425780952382
instrumentalness_stdev	0.36676919399898716	0.20282560471368336	0.16394358928530386
danceability_mean	0.5578333333333333	0.5658571428571428	-0.008023809523809544
danceability_stdev	0.09000759227235591	0.14228950249757852	-0.052281910225222605
loudness_mean	-12.212833333333332	-8.029828571428572	-4.18300476190476
loudness_stdev	4.788544263830779	3.8494960287848397	0.9390482350459384
valence_mean	0.45816666666666667	0.5393371428571428	-0.08117047619047624
valence_stdev	0.27849266896395436	0.21033724053600808	0.06815542842794634
cluster1	0.26681873238008347	0.2710495115070267	-0.004230779126943196
cluster2	3.238265154999598e-09	1.0603059165542868e-08	-7.3647940105432695e-09
cluster3	1.382665855072808e-06	0.0009246497095941237	-0.0009232670437390509
cluster4	0.09842416784957939	0.24540929261716687	-0.14698512476758752
cluster5	0.16099727728255595	0.3258308784933038	-0.16483360121074783
cluster6	0.0037183143625002424	0.06611262030865937	-0.062394305946159134
cluster7	0.30334353222134003	0.09056891166237191	0.21277462055896812
cluster8	3.1571788016170735e-05	0.00010006219957922419	-6.849041156305346e-05

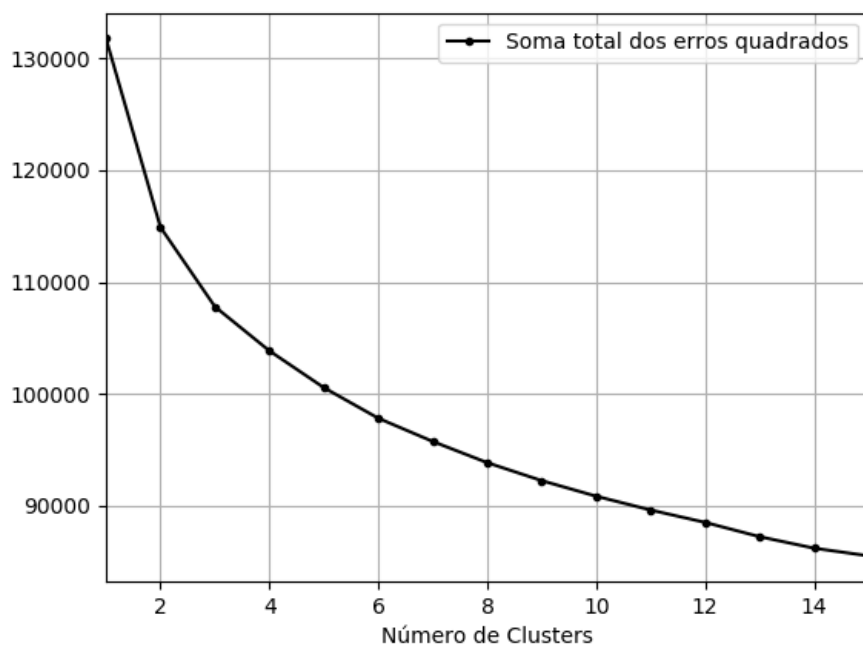


Figura 6.1: Soma total dos erros quadrados em diferentes configurações de quantidade de grupos a serem identificados pelo algoritmo k-means nos modelos das diferenças entre as preferências relaxantes e gerais dos usuários do 8tracks.




Figura 6.2: Gradientes das somas totais dos erros quadrados em diferentes configurações de quantidade de grupos a serem identificados pelo algoritmo k-means nos modelos das diferenças entre as preferências relaxantes e gerais dos usuários do 8tracks.

6.1.2 Analisando os Grupos Identificados

Após a utilização do k-means, foram identificados 3 grupos cujos centroides estão apresentados na Tabela 6.2. Vale salientar que os valores que aparecem na Tabela 6.2 estão normalizados. A seguir, são detalhados cada um desses grupos, evidenciando algumas das suas características:

- Grupo 1 [total de usuários: 2292]: Compreende os usuários que possuem playlists gerais mais enérgicas, menos acústicas e mais positivas que suas playlists relaxantes; Além dessas características, é possível identificar que em suas playlists relaxantes estão presentes mais músicas do *cluster1*, *cluster7* e *cluster8* do que em suas playlists gerais, o que significa uma maior presença de músicas pop, músicas tocadas com instrumentos de corda e músicas com sons da natureza, respectivamente.
- Grupo 2 [total de usuários: 2326]: A constatação mais direta que pode ser feita deste grupo é que ele possui um comportamento praticamente oposto aos usuários do Grupo 1, levando em conta as *features* de alto nível das músicas. É possível também verificar que estes usuários possuem em suas playlists relaxantes mais músicas eletrônicas, rock e *lounge music* do que em suas playlists gerais, uma vez que as *features cluster4*, *cluster5* e *cluster6* possuem valores positivos nesta representação.
- Grupo 3 [total de usuários: 262]: Formado pelos usuários que possuem diferenças mais extremas entre suas preferências de músicas relaxantes e músicas gerais. É neste grupo que se encontram os usuários que escutam em sua grande maioria músicas instrumentais tocadas por piano, músicas clássicas e sons da natureza para relaxar, como estabelece os valores encontrados para as *features cluster2*, *cluster3* e *cluster8*, respectivamente.

Tabela 6.2: Valores dos centroides calculados após a aplicação do algoritmo k-means para a identificação de 3 grupos nos dados das diferenças entre as preferências relaxantes e demais preferências dos usuários do 8tracks

Centroides dos Grupos			
Features	Grupo 1	Grupo 2	Grupo 3
energy_mean	-0.598784	0.735927	-1.295246
energy_stdev	0.248417	-0.191257	-0.475213
liveness_mean	-0.283286	0.304243	-0.22281
liveness_stdev	-0.225082	0.252079	-0.268889
tempo_mean	-0.092282	0.183432	-0.821191
tempo_stdev	0.065237	-0.093207	0.256776
speechiness_mean	-0.384682	0.387304	-0.073197
speechiness_stdev	-0.33742	0.35763	-0.223212
acousticness_mean	0.57046	-0.69654	1.193343
acousticness_stdev	0.373126	-0.312659	-0.488402
instrumentalness_mean	0.068202	-0.324289	2.282361
instrumentalness_stdev	0.218427	-0.231865	0.147641
danceability_mean	-0.263212	0.467343	-1.846405
danceability_stdev	0.076061	-0.08387	0.079202
loudness_mean	-0.410329	0.655466	-2.229543
loudness_stdev	0.319143	-0.420643	0.942519
valence_mean	-0.457015	0.607675	-1.396842
valence_stdev	-0.06017	0.170478	-0.987109
cluster1	0.447365	-0.356155	-0.751693
cluster2	-0.032889	-0.204635	2.10444
cluster3	-0.002901	-0.296884	2.661081
cluster4	-0.467343	0.51797	-0.510108
cluster5	-0.118021	0.201467	-0.756141
cluster6	-0.180278	0.229837	-0.463377
cluster7	0.335071	-0.269877	-0.5353
cluster8	0.046258	-0.165677	1.066191

6.2 Analisando os Usuários da Plataforma Spotify

6.2.1 Agrupando os Usuários De Acordo com Suas Diferenças das Preferências Musicais

Fazendo uso da mesma abordagem para estimar um valor ótimo de grupos a serem identificados nos dados analisados, foi utilizado novamente o método do cotovelo aplicado ao gráfico das somas totais dos erros quadrados em diferentes configurações de quantidade de grupos. Observando a Figura 6.3, percebe-se que provavelmente o valor ótimo para K é o valor 3. Para atestar a suspeita inicial de que o número ideal de grupos é 3, uma checagem nos gradientes das somas totais dos erros quadrados foi realizada. Analisando a Figura 6.4 é possível identificar que após a configuração com 3 grupos, o gradiente pouco se altera, sugerindo que a suspeita inicial estava correta.

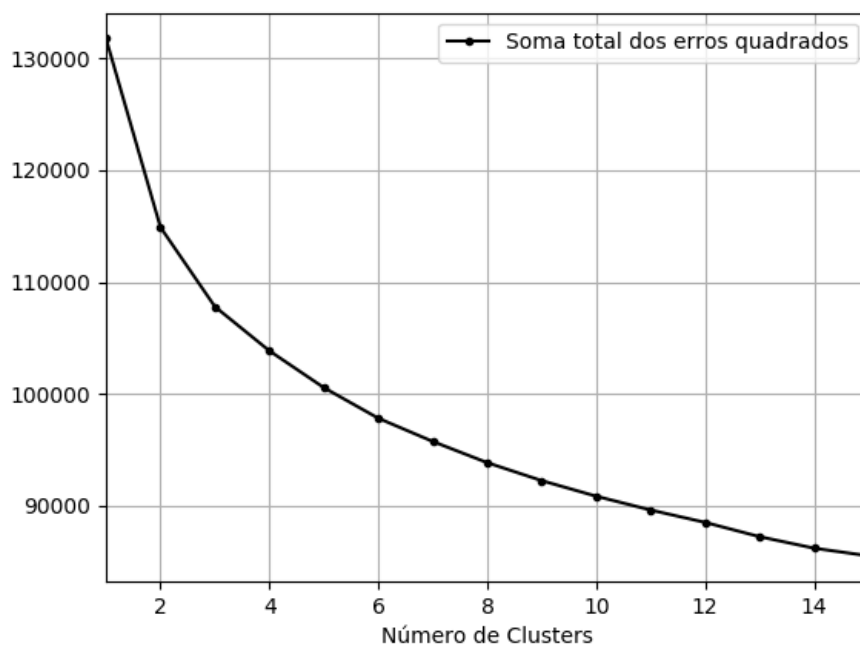


Figura 6.3: Soma total dos erros quadrados em diferentes configurações de quantidade de grupos a serem identificados pelo algoritmo k-means nos modelos das diferenças entre as preferências relaxantes e gerais dos usuários do Spotify.




Figura 6.4: Gradientes das somas totais dos erros quadrados em diferentes configurações de quantidade de grupos a serem identificados pelo algoritmo k-means nos modelos das diferenças entre as preferências relaxantes e gerais dos usuários do Spotify.

6.2.2 Analisando os Grupos Identificados

Após aplicar o algoritmo k-means nos vetores que representam as diferenças entre as preferências dos usuários do Spotify em relação às suas playlists relaxantes e às playlists gerais, 3 grupos foram identificados. Os centroides destes grupos são expostos na Tabela 6.3, normalizados. A seguir, são detalhados cada um desses grupos, evidenciando algumas das suas características:

- Grupo 1 [total de usuários: 1317]: Compreende os usuários que possuem playlists relaxantes mais enérgicas, mais dançantes e mais positivas que suas playlists gerais. Como era de se esperar, é possível identificar que em suas playlists relaxantes estão presentes mais músicas do *cluster4* e *cluster6* do que em suas playlists gerais, o que significa uma maior presença de músicas eletrônicas e *lounge music*.
- Grupo 2 [total de usuários: 1175]: Neste grupo temos a presença de usuários que possuem em suas playlists relaxantes músicas mais acústicas, com uma maior presença de pop e de rock, do que em suas playlists gerais.
- Grupo 3 [total de usuários: 362]: Assim como na plataforma 8tracks, este grupo é formado pelos usuários que possuem diferenças mais extremas entre suas preferências entre músicas relaxantes e músicas gerais. É neste grupo que se encontram os usuários que escutam em sua grande maioria músicas pouco enérgicas, instrumentais tocadas por piano, músicas clássicas e sons da natureza para relaxar, como define os valores encontrados para as *features energy_mean*, *instrumentalness_mean*, *cluster2*, *cluster3* e *cluster8*, respectivamente.

6.3 Considerações Finais

Com o intuito de buscar respostas para a **segunda questão de pesquisa**, foram desenvolvidas análises levando em consideração as diferenças entre as preferências dos usuários em relação às playlists relaxantes e às playlists gerais. Inicialmente, foi definido um novo modelo de representação dos usuários. Este novo modelo nada mais é que a subtração de cada um dos valores das *features* do vetor de representação das preferências relaxantes de cada usuário, pelos valores das *features* do vetor de representação das preferências gerais.

Tabela 6.3: Valores dos centroides calculados após a aplicação do algoritmo k-means para a identificação de 3 grupos nos dados das diferenças entre as preferências relaxantes e demais preferências dos usuários do Spotify

Centroides dos Grupos			
Features	Grupo 1	Grupo 2	Grupo 3
energy_mean	0.629919	-0.235489	-1.527358
energy_stdev	-0.129199	0.488694	-1.116189
liveness_mean	0.093308	-0.097874	-0.021783
liveness_stdev	0.101565	0.017842	-0.42742
tempo_mean	0.333155	0.048791	-1.37043
tempo_stdev	-0.251009	0.162344	0.386254
speechiness_mean	0.41951	-0.449018	-0.068782
speechiness_stdev	0.350315	-0.2598	-0.431218
acousticness_mean	-0.619922	0.232937	1.499271
acousticness_stdev	-0.171542	0.586302	-1.278963
instrumentalness_mean	-0.388213	-0.189437	2.027254
instrumentalness_stdev	-0.27232	0.323611	-0.059661
danceability_mean	0.664691	-0.23595	-1.652365
danceability_stdev	-0.22073	0.385008	-0.446637
loudness_mean	0.541758	0.02403	-2.048985
loudness_stdev	-0.438623	0.383885	0.349728
valence_mean	0.629072	-0.242975	-1.499976
valence_stdev	0.253892	0.17526	-1.492561
cluster1	-0.249789	0.670012	-1.266001
cluster2	-0.292387	-0.147128	1.5413
cluster3	-0.37316	-0.136739	1.801442
cluster4	0.618651	-0.47681	-0.703071
cluster5	-0.016108	0.350781	-1.07998
cluster6	0.491823	-0.332382	-0.710444
cluster7	-0.051911	0.11206	-0.174871
cluster8	-0.284058	-0.116612	1.411946

Com esta nova representação em mãos, foram identificados grupos distintos de usuários que possuem preferências similares. Este agrupamento ocorreu de forma análoga aos outros agrupamentos já realizados em análises anteriores desenvolvidas neste trabalho. Foram identificados 3 grupos distintos de usuários em cada uma das plataformas em estudo: 8tracks e Spotify. Em cada um desses grupos, foram elencadas suas principais características, evidenciando a existência de diferenças entre as preferências de um mesmo usuário em relação ao relaxamento e a outros contextos. Um outro fator interessante identificado nesta análise foi o pequeno tamanho dos grupos dos usuários que escutam mais músicas clássicas, sons da natureza e músicas em piano para relaxar. Essas diferenças permitem responder positivamente, de forma parcial, a **segunda questão de pesquisa**.

Capítulo 7

Conclusões e Trabalhos Futuros

Neste trabalho de pesquisa, foi proposto como objetivo geral a investigação da tese de que há diferenças nas preferências de usuários ao criarem playlists para contextos específicos, tornando a personalização um fator importante neste escopo. Mais especificamente, três perguntas de pesquisa serviram de guia para toda a metodologia adotada neste trabalho, são elas: **(i) Há, e se há, quais são as diferenças nas preferências dos usuários ao criarem playlists para uma mesma atividade?;** **(ii) Existem e quais são as diferenças nas preferências de diferentes grupos de usuários entre suas playlists criadas para uma atividade ou segundo outros critérios?;** **(iii) Qual o impacto de modelar as preferências dos usuários ao criarem playlists relaxantes utilizando *features* musicais de alto e baixo nível?**

Para averiguar esta tese e conseqüentemente responder às perguntas de pesquisa, inicialmente foram buscados dados em plataformas de compartilhamento de playlists (Seção 3.1). Após o processo de obtenção de dados, se fez necessário o enriquecimento destes dados (Seção 3.3), para assim possibilitar a criação de modelos representativos das preferências dos usuários ao criarem playlists. Este enriquecimento se deu adicionando informações acústicas de alto e baixo nível de cada uma das músicas presentes nas playlists dos usuários estudados.

Após a obtenção e o enriquecimento dos dados, foram desenvolvidos modelos estatísticos para representar as preferências de cada usuário ao criar playlists relaxantes e playlists gerais (Capítulo 4). O modelo desenvolvido foi baseado em [62]. Neste modelo, foi possível incorporar características médias e de dispersão de *features* acústicas de alto nível, bem como de *features* acústicas de baixo nível, como o timbre.

Cada usuário passou a ser representado por dois vetores, um contendo suas preferên-

cias sobre músicas relaxantes e outro abrangendo as preferências sobre músicas em geral. Fazendo uso dessas representações, foi desenvolvido e ajustado um modelo de regressão logística para cada uma das plataformas utilizadas neste trabalho (8tracks e Spotify). Os resultados obtidos demonstraram a existência de diferentes conjuntos de variáveis independentes estatisticamente significativas em cada um dos modelos. Em cada fonte de dados utilizadas neste trabalho, seus usuários foram agrupados visando identificar diferentes grupos de usuários que possuem diferentes preferências. Para tal, em cada grupo identificado pelo algoritmo k-means, foi projetado um modelo de regressão logística com o intuito de verificar se tais modelos possuíam diferentes conjuntos de variáveis independentes significativas, ou não. Os resultados alcançados demonstraram que, de fato, ao menos para a atividade de relaxamento, existem diferenças nas preferências dos usuários, o que responde positivamente de forma parcial a **primeira questão de pesquisa** (Capítulo 5). Essas diferenças observadas corroboram com nossa hipótese e com estudos da área de musicoterapia [14; 12; 58; 8], que indicam que dentre outros fatores, como familiaridade com música, a preferência musical dos ouvintes desempenha papel fundamental para o resultado efetivo de relaxamento.

Apesar das diferenças identificadas nos coeficientes dos valores médios das *features* de alto nível, um comportamento comum observado nos grupos criados com os usuários das duas plataformas, é que suas preferências relaxantes tendem a ser modeladas por músicas com poucas variações nos valores de suas *features* de alto nível. Este comportamento sugere que, quebras de padrões, variações, chamam a atenção dos ouvintes, possivelmente os tirando de um comportamento de relaxamento.

Buscando respostas para a **segunda questão de pesquisa**, foi definido um novo modelo de representação das preferências dos usuários. Este novo modelo seria composto pela subtração dos valores do vetor de representação das preferências sobre relaxamento em relação às preferências gerais. Ao agrupar estes usuários de acordo com este novo modelo, foi possível verificar a existência de contrastes nas preferências de diferentes grupos de usuários entre suas playlists criadas para uma atividade específica, no caso o relaxamento, ou segundo outros critérios, respondendo positivamente a **segunda questão de pesquisa**. Este resultado solidificou a nossa impressão inicial de que uma mesma pessoa pode ter preferências musicais diferentes para contextos distintos, evidenciando o papel essencial da personalização

para, por exemplo, recomendadores musicais baseados em contexto.

Por fim, quanto à **terceira questão de pesquisa**, o sucesso ao utilizar o modelo de representação das preferências dos usuários ao criarem playlists relaxantes, para identificar diferenças nas preferências dos usuários, demonstra que o uso de *features* musicais de alto e baixo nível consegue captar uma grande quantidade de informações, sendo possível diferenciar as preferências dos usuários sob várias perspectivas, desde a análise de diferenças entre, por exemplo, os tempos das músicas, até mesmo a presença de gêneros musicais específicos. Além de explicitar diferenças nas preferências, ao fazer uso das *features* de alto nível neste modelo, foi possível também verificar a importância da ausência de variações nesses valores para definir as preferências relaxantes dos usuários analisados. Característica comum, compartilhada por praticamente todos os grupos estudados.

7.1 Limitações e Trabalhos Futuros

Considerando a metodologia aplicada na condução da pesquisa realizada nesta tese, algumas limitações devem ser elencadas. A primeira delas reside no modo em que as playlists foram extraídas das fontes de dados. Foi realizada uma filtragem por playlists que possuíam a tag "relax" ou "chill", porém podem existir casos em que playlists criadas com o intuito de serem relaxantes não possuam tais tags. Ainda sobre a coleta de dados, uma vez que o interesse desta pesquisa era analisar playlists criadas manualmente por usuários, utilizar plataformas que disponibilizam a possibilidade de criação automática de playlists, pode se tornar um risco. Para mitigar este risco, foi realizada uma filtragem, limitando a presença de usuários que tinham no máximo 100 playlists publicadas e playlists com no máximo 200 músicas.

Um outro ponto a ser discutido para uma possível melhoria do trabalho consiste na evolução do modelo de representação das preferências dos usuários. O atual modelo possui apenas o timbre como *feature* acústica de baixo nível. Trabalhos futuros devem propor novos modelos e comparar os resultados com os obtidos neste trabalho.

Uma outra limitação que ameaça a validade externa, é o fato da utilização de apenas duas fontes de dados para testar os modelos criados. Se faz necessário o uso de novas fontes de dados a fim de confirmar os achados deste trabalho.

Além do objetivo de mitigar possíveis limitações do trabalho atual, outras tarefas estão

planejadas para serem executadas com o intuito de aprimorar a pesquisa como um todo. A primeira delas é a adição de novas atividades/contextos específicos a serem analisados de acordo com a metodologia aplicada neste trabalho, vislumbrando alguma possível nova constatação.

Por fim, propor, utilizar e avaliar as preferências de usuários em recomendadores musicais baseados em contexto, avaliando sua performance. Nesta tarefa, a ideia principal é que, após analisar os comportamentos de cada usuário ao criar playlists para atividades específicas, se terá um conhecimento prévio das preferências de cada um deles para determinados contextos (relaxar, estudar, etc.). Com essa informação em mãos, deve-se propor a utilização em recomendadores musicais baseados em contexto. Além disso, pretende-se comparar os resultados obtidos com outros trabalhos dessa área, tais como [59].

Bibliografia

- [1] Gediminas Adomavicius and Alexander Tuzhilin. Context-aware recommender systems. In *Recommender systems handbook*, pages 217–253. Springer, 2011.
- [2] Marko Balabanović and Yoav Shoham. Fab: content-based, collaborative recommendation. *Communications of the ACM*, 40(3):66–72, 1997.
- [3] Linas Baltrunas, Marius Kaminskas, Bernd Ludwig, Omar Moling, Francesco Ricci, Aykan Aydin, Karl-Heinz Lüke, and Roland Schwaiger. Incarmusic: Context-aware music recommendations in a car. In *International Conference on Electronic Commerce and Web Technologies*, pages 89–100. Springer, 2011.
- [4] Christine Bauer and Alexander Novotny. A consolidated view of context for intelligent systems. *Journal of Ambient Intelligence and Smart Environments*, 9(4):377–393, 2017.
- [5] Dmitry Bogdanov, Martín Haro, Ferdinand Fuhrmann, Emilia Gómez, and Perfecto Herrera. Content-based music recommendation based on user preference examples. In *ACM conf. on recommender systems. Workshop on music recommendation and discovery (Womrad 2010)*, 2010.
- [6] Dmitry Bogdanov, Martín Haro, Ferdinand Fuhrmann, Emilia Gómez, and Perfecto Herrera. Content-based music recommendation based on user preference examples. In *ACM conf. on recommender systems. Workshop on music recommendation and discovery (Womrad 2010)*, 2010.
- [7] Tung Bui, editor. *51st Hawaii International Conference on System Sciences, HICSS 2018, Hilton Waikoloa Village, Hawaii, USA, January 3-6, 2018*. ScholarSpace / AIS Electronic Library (AISeL), 2018.

-
- [8] Debra S Burns, Renata B Sledge, Leigh Ann Fuller, Joanne K Daggy, and Patrick O Monahan. Cancer patients' interest and preferences for music therapy. *Journal of Music Therapy*, 42(3):185–199, 2005.
- [9] Zehra Çataltepe and Berna Altinel. Music recommendation based on adaptive feature and user grouping. In *2007 22nd international symposium on computer and information sciences*, pages 1–6. IEEE, 2007.
- [10] Toni Cebrián, Marc Planagumà, Paulo Villegas, and Xavier Amatriain. Music recommendations with temporal context awareness. In *Proceedings of the fourth ACM conference on Recommender systems*, pages 349–352. ACM, 2010.
- [11] Zhiyong Cheng and Jialie Shen. Just-for-me: An adaptive personalization system for location-aware social music recommendation. In *Proceedings of international conference on multimedia retrieval*, pages 185–192, 2014.
- [12] Michael Clark, Gloria Isaacks-Downton, Nancy Wells, Sheryl Redlin-Frazier, Carol Eck, Joseph T Hepworth, and Bapsi Chakravarthy. Use of preferred music to reduce emotional distress and symptom activity during radiation therapy. *Journal of music therapy*, 43(3):247–265, 2006.
- [13] Sally Jo Cunningham and David M Nichols. Exploring social music behaviour: An investigation of music selection at parties. In Bui [7].
- [14] William B Davis and Michael H Thaut. The influence of preferred relaxing music on measures of state anxiety, relaxation, and physiological responses. *Journal of music therapy*, 26(4):168–187, 1989.
- [15] Franz De Leon and Kirk Martinez. Enhancing timbre model using mfcc and its time derivatives for music similarity estimation. In *2012 Proceedings of the 20th European Signal Processing Conference (EUSIPCO)*, pages 2005–2009. IEEE, 2012.
- [16] Andrew Demetriou, Martha Larson, and Cynthia C. S. Liem. Go with the flow: When listeners use music as technology. In Michael I. Mandel, Johanna Devaney, Douglas

- Turnbull, and George Tzanetakis, editors, *Proceedings of the 17th International Society for Music Information Retrieval Conference, ISMIR 2016, New York City, United States, August 7-11, 2016*, pages 292–298, 2016.
- [17] Tia DeNora. Music as a technology of the self. *Poetics*, 27(1):31–56, 1999.
- [18] Anind K Dey. Understanding and using context. *Personal and ubiquitous computing*, 5(1):4–7, 2001.
- [19] Ricardo Dias, Manuel J Fonseca, and Ricardo Cunha. A user-centered music recommendation approach for daily activities. In *CBRecSys@ RecSys*, pages 26–33, 2014.
- [20] Adabriand Andrade Furtado. Perfis de contribuidores em sites de perguntas e respostas. Mestrado, Universidade Federal de Campina Grande, 2013.
- [21] Arijit Ghosal, Rudrasis Chakraborty, Bibhas Chandra Dhara, and Sanjoy Kumar Saha. Music classification based on mfcc variants and amplitude variation pattern: a hierarchical approach. *International Journal of Signal Processing, Image Processing and Pattern Recognition*, 5(1):131–150, 2012.
- [22] Michael Gillhofer and Markus Schedl. Iron maiden while jogging, debussy for dinner? In *International Conference on Multimedia Modeling*, pages 380–391. Springer, 2015.
- [23] David J Hargreaves and Adrian C North. The functions of music in everyday life: Redefining the social in music psychology. *Psychology of music*, 27(1):71–83, 1999.
- [24] Negar Hariri, Bamshad Mobasher, and Robin Burke. Context-aware music recommendation based on latent topic sequential patterns. In *Proceedings of the sixth ACM conference on Recommender systems*, pages 131–138, 2012.
- [25] J. A. Hartigan and M. A. Wong. Algorithm as 136: A k-means clustering algorithm. *Journal of the Royal Statistical Society. Series C (Applied Statistics)*, 28(1):100–108, 1979.
- [26] Eugenia Hernandez-Ruiz, Bianca James, Jordan Noll, and Evangelia G Chrysikou. What makes music relaxing? an investigation into musical elements. *Psychology of Music*, 48(3):327–343, 2020.

- [27] Jesper Højvang Jensen, Mads Græsbøll Christensen, Manohar N Murthi, and Søren Holdt Jensen. Evaluation of mfcc estimation techniques for music similarity. In *2006 14th European Signal Processing Conference*, pages 1–5. IEEE, 2006.
- [28] Marius Kaminskis, Francesco Ricci, and Markus Schedl. Location-aware music recommendation using auto-tagging and hybrid matching. In *Proceedings of the 7th ACM conference on Recommender systems*, pages 17–24, 2013.
- [29] Kunsu Kim, Donghoon Lee, Tae-Bok Yoon, and Jee-Hyong Lee. A music recommendation system based on personal preference analysis. In *2008 First International Conference on the Applications of Digital Information and Web Technologies (ICADIWT)*, pages 102–106. IEEE, 2008.
- [30] Trupti M Kodinariya and Prashant R Makwana. Review on determining number of cluster in k-means clustering. *International Journal*, 1(6):90–95, 2013.
- [31] Chang-Hsing Lee, Jau-Ling Shih, Kun-Ming Yu, and Jung-Mau Su. Automatic music genre classification using modulation spectral contrast feature. In *2007 IEEE International Conference on Multimedia and Expo*, pages 204–207. IEEE, 2007.
- [32] Jae Sik Lee and Jin Chun Lee. Context awareness by case-based reasoning in a music recommendation system. In *International symposium on ubiquitous computing systems*, pages 45–58. Springer, 2007.
- [33] Mark Levy and Mark Sandler. Lightweight measures for timbral similarity of musical audio. In *Proceedings of the 1st ACM workshop on Audio and music computing multimedia*, pages 27–36, 2006.
- [34] Tao Li and Mitsunori Ogihara. Content-based music similarity search and emotion detection. In *2004 IEEE International Conference on Acoustics, Speech, and Signal Processing*, volume 5, pages V–705. IEEE, 2004.
- [35] Beth Logan. Music recommendation from song sets. In *ISMIR*, pages 425–428, 2004.
- [36] Beth Logan and Ariel Salomon. A music similarity function based on signal analysis. In *ICME*, pages 22–25, 2001.

- [37] Martin McKinney and Jeroen Breebaart. Features for audio and music classification. In *ISMIR 2003, 4th International Conference on Music Information Retrieval, Baltimore, Maryland, USA, October 27-30, 2003, Proceedings*. Johns Hopkins University, 2003.
- [38] JM Moita Neto and Graziella Ciaramella Moita. Uma introdução à análise exploratória de dados multivariados. *Química nova*, 21(4):467–469, 1998.
- [39] Bin NIU, Ling-zhi KONG, Sen-lin LUO, Li-min PAN, and Liang GUO. Individuality music recommendation model based on mfcc and gmm [j]. *Transactions of Beijing Institute of Technology*, 4, 2009.
- [40] Adrian C North and David J Hargreaves. Situational influences on reported musical preference. *Psychomusicology: A Journal of Research in Music Cognition*, 15(1-2):30, 1996.
- [41] Adrian C North, David J Hargreaves, and Jon J Hargreaves. Uses of music in everyday life. *Music Perception: An Interdisciplinary Journal*, 22(1):41–77, 2004.
- [42] Kenton O’Hara and Barry Brown. *Consuming music together: social and collaborative aspects of music consumption technologies*, volume 35. Springer Science & Business Media, 2006.
- [43] Han-Saem Park, Ji-Oh Yoo, and Sung-Bae Cho. A context-aware music recommendation system using fuzzy bayesian networks with utility theory. In *International conference on Fuzzy systems and knowledge discovery*, pages 970–979. Springer, 2006.
- [44] Terry F Pettijohn, Greg M Williams, and Tiffany C Carter. Music for the seasons: seasonal music preferences in college students. *Current Psychology*, 29(4):328–345, 2010.
- [45] Martin Pichl, Eva Zangerle, and Günther Specht. Towards a context-aware music recommendation approach: What is hidden in the playlist name? In *2015 IEEE International Conference on Data Mining Workshop (ICDMW)*, pages 1360–1365. IEEE, 2015.

- [46] Peter J Rentfrow and Samuel D Gosling. The do re mi's of everyday life: the structure and personality correlates of music preferences. *Journal of personality and social psychology*, 84(6):1236, 2003.
- [47] Paul Resnick and Hal R. Varian. Recommender systems. *Commun. ACM*, 40(3):56–58, March 1997.
- [48] Douglas A Reynolds. Gaussian mixture models. *Encyclopedia of biometrics*, 741, 2009.
- [49] Markus Schedl and Arthur Flexer. Putting the user in the center of music information retrieval. In *ISMIR*, pages 385–390. Citeseer, 2012.
- [50] Markus Schedl, Arthur Flexer, and Julián Urbano. The neglected user in music information retrieval research. *Journal of Intelligent Information Systems*, 41(3):523–539, 2013.
- [51] Markus Schedl, Peter Knees, and Fabien Gouyon. New paths in music recommender systems research. In *Proceedings of the Eleventh ACM Conference on Recommender Systems*, pages 392–393. ACM, 2017.
- [52] Markus Schedl, Peter Knees, Brian McFee, Dmitry Bogdanov, and Marius Kaminskas. Music recommender systems. In *Recommender systems handbook*, pages 453–492. Springer, 2015.
- [53] Markus Schedl, Hamed Zamani, Ching-Wei Chen, Yashar Deldjoo, and Mehdi Elahi. Current challenges and visions in music recommender systems research. *International Journal of Multimedia Information Retrieval*, 7(2):95–116, 2018.
- [54] Alexander Schindler and Andreas Rauber. Capturing the temporal domain in echo-nest features for improved classification effectiveness. In *International Workshop on Adaptive Multimedia Retrieval*, pages 214–227. Springer, 2012.
- [55] Upendra Shardanand and Pattie Maes. Social information filtering: algorithms for automating “word of mouth”. In *Proceedings of the SIGCHI conference on Human factors in computing systems*, pages 210–217. ACM Press/Addison-Wesley Publishing Co., 1995.

- [56] Daniel Skog, Henrik Wimelius, and Johan Sandberg. Digital service platform evolution: How spotify leveraged boundary resources to become a global leader in music streaming. In Bui [7].
- [57] John A Sloboda, Susan A O'Neill, and Antonia Ivaldi. Functions of music in everyday life: An exploratory study using the experience sampling method. *Musicae scientiae*, 5(1):9–32, 2001.
- [58] Xueli Tan, Charles J Yowler, Dennis M Super, and Richard B Fratianne. The interplay of preference, familiarity and psychophysical properties in defining relaxation music. *Journal of Music Therapy*, 49(2):150–179, 2012.
- [59] Xinxin Wang, David Rosenblum, and Ye Wang. Context-aware mobile music recommendation for daily activities. In *Proceedings of the 20th ACM international conference on Multimedia*, pages 99–108, 2012.
- [60] Karthik Yadati, Cynthia C. S. Liem, Martha Larson, and Alan Hanjalic. On the automatic identification of music for common activities. In *Proceedings of the 2017 ACM on International Conference on Multimedia Retrieval, ICMR 2017, Bucharest, Romania, June 6-9, 2017*, pages 192–200, 2017.
- [61] Kazuyoshi Yoshii, Masataka Goto, Kazunori Komatani, Tetsuya Ogata, and Hiroshi G Okuno. Hybrid collaborative and content-based music recommendation using probabilistic model with latent user preferences. In *ISMIR*, volume 6, page 7th, 2006.
- [62] Eva Zangerle and Martin Pichl. The many faces of users: Modeling musical preference. In Emilia Gómez, Xiao Hu, Eric Humphrey, and Emmanouil Benetos, editors, *Proceedings of the 19th International Society for Music Information Retrieval Conference, ISMIR 2018, Paris, France, September 23-27, 2018*, pages 709–716, 2018.