

UNIVERSIDADE FEDERAL DE SÃO CARLOS– UFSCAR  
CENTRO DE CIÊNCIAS EXATAS E DE TECNOLOGIA– CCET  
DEPARTAMENTO DE COMPUTAÇÃO– DC  
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO– PPGCC

**Willian Garcias de Assunção**

**Uma Arquitetura para Sistemas de  
Recomendação de Música Baseado em  
Contexto da Interação e Experiência do  
Usuário**

**Willian Garcias de Assunção**

**Uma Arquitetura para Sistemas de  
Recomendação de Música Baseado em  
Contexto da Interação e Experiência do  
Usuário**

Tese apresentada ao Programa de Pós-Graduação em Ciência da Computação do Centro de Ciências Exatas e de Tecnologia da Universidade Federal de São Carlos, como parte dos requisitos para a obtenção do título de Doutor em Ciência da Computação.

Área de concentração: Metodologias e Técnicas de Computação

Orientador: Luciana Aparecida Martinez Zaina

São Carlos

2023

*Este trabalho é dedicado aos meus pais, aos meus avós, às minhas irmãs, à minha esposa e ao meu filho.*

---

# Agradecimentos

---

Primeiramente, gostaria de expressar minha imensa gratidão à minha família: meu pai e minha mãe, que foram pilares inabaláveis de apoio e crença em mim desde a graduação até esta etapa importante do doutorado. Vocês sempre estiveram ao meu lado, não apenas acreditando em meus sonhos, mas também me fornecendo o suporte necessário para torná-los realidade. Minha irmã, sempre presente e incentivadora, desempenhou um papel importante também.

Agradeço também à família que construí durante este doutorado, minha esposa Letícia e nosso filho Yuri. A chegada de vocês na minha vida trouxe uma nova dimensão de amor e motivação. Letícia, sua presença tem sido uma fonte constante de força e inspiração e nosso filho é a luz que ilumina cada passo que dou.

Um agradecimento muito especial ao meu pai, um verdadeiro modelo de dedicação e bondade. Pai, sua incansável dedicação e fé foram inspiradoras, especialmente durante os desafios da construção de minha casa. Trabalhar ao seu lado foi uma experiência que me aproximou ainda mais de você. Aprecio cada momento que passamos juntos, esses momentos me ensinaram sobre a perseverança, amor e o valor do trabalho árduo. Eu me espelho em você e aspiro ser um pai tão incrível quanto você tem sido para mim.

Minha gratidão se estende aos meus avós, cujas orações e apoio espiritual foram fundamentais e constantes em minha jornada. Eles sempre estiveram ao meu lado, oferecendo não apenas apoio espiritual, mas também amor e sabedoria que guiaram meu caminho. Aos meus tios Edson e Fábio, que infelizmente perdi durante este período, deixo uma homenagem especial. Meu tio Fábio, sempre interessado na minha vida acadêmica, frequentemente perguntava sobre a faculdade e se mostrava ansioso pela conclusão. Seu incentivo, baseado na crença de que o estudo é o caminho para o sucesso, especialmente em uma família onde poucos concluíram o ensino superior, foi uma inspiração constante. Carrego as memórias de ambos como lembretes do valor da vida e da importância de perseguir nossos sonhos com determinação e coragem.

Agradeço profundamente aos professores da Universidade Federal de Goiás e da Uni-

versidade Federal de São Carlos, cuja orientação e ensinamentos foram fundamentais para o meu desenvolvimento acadêmico e pessoal. Um agradecimento especial ao meu amigo Renan Vinícius Aranha, cujo apoio, incentivo e companheirismo desde os tempos de graduação foram essenciais para minha trajetória.

À equipe do PPGCC da UFSCar, sou grato pela oportunidade de desenvolver este trabalho e pela formação valiosa que me proporcionaram. A Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) – Código Financeiro 001, pelos apoios financeiro que viabilizaram esta pesquisa, permitindo-me dedicar tempo e energia significativos à minha pesquisa.

Um agradecimento especial ao grupo de pesquisa UX Leris, onde a colaboração, os comentários e as sugestões enriqueceram imensamente meu trabalho. A Universidade de Rio Verde merece reconhecimento por seu apoio constante, permitindo-me focar no doutorado e compartilhar meus trabalhos em diversas plataformas e conferências.

Devo um agradecimento especial aos membros da banca de qualificação, Prof. Dr. Marcelo Soares Pimenta, Prof. Dr. Marco Antônio Alba Winckler e Profa. Dra. Joice Lee Otsuka, cujos comentários críticos foram fundamentais para o amadurecimento do meu trabalho. As avaliações e orientações contribuíram significativamente para a evolução da minha pesquisa.

Por fim, de todos os agradecimentos, este eu considero de grande e profunda importância e gratidão que vai para minha orientadora Profa. Dra. Luciana Aparecida Martinez Zaina. Luciana, sua chegada em um dos momentos mais desafiadores da minha vida, logo quando descobri que seria pai e estava preocupado com a possibilidade de perder a bolsa e até mesmo desistir do doutorado, isso foi um divisor de águas. Sua resposta imediata e abrangente, trazendo parcerias com professores renomados da UFAM (Prof. Dr. Bruno Gadelha e Profa. Dra. Tayana Conte), da CODE University of Applied Sciences (Profa. Dra. Lara Schibelsky Godoy Piccolo) e da UFMG (Profa. Dra. Raquel Oliveira Prates) foi essencial. Suas revisões e sugestões foram cruciais para o meu desenvolvimento como pesquisador. Sua bondade, alto astral e preocupação constante com minha experiência e progresso na pesquisa fazem de você uma pessoa excepcional. Fiquei muitas vezes receoso de decepcioná-la, mas sua orientação e apoio incondicional me impulsionaram a seguir em frente. Você não só merece crédito nesta seção de agradecimentos, mas também um lugar especial em minha trajetória e memória como uma verdadeira mãe na pesquisa.

*“O segredo do sucesso é a constância do propósito”  
(Benjamin Disraeli)*

---

# Resumo

---

Esta tese de doutorado aborda diretamente o problema de pesquisa: "Como os sistemas de recomendação musical podem ser aprimorados para integrar o contexto da interação e a experiência do usuário?". Em resposta a essa questão, a pesquisa desenvolve e avalia a UConteXt Arch, uma arquitetura para sistemas de recomendação de música. Esta arquitetura é concebida para aprimorar a experiência do usuário, considerando especificamente o contexto de interação e as preferências musicais. A abordagem metodológica adotada é o Design Science Research (DSR), que possibilita uma análise iterativa e cíclica no desenvolvimento da UConteXt Arch. A arquitetura é fundamentada em teorias e pesquisas sobre sistemas de recomendação, experiência do usuário e personalização contextual. O desenvolvimento da UConteXt Arch envolveu uma revisão sistemática da literatura e estudos exploratórios sobre as práticas atuais em plataformas como Spotify e Deezer. A avaliação da UConteXt Arch incluiu métodos variados, como o Método de Avaliação da Comunicabilidade (MAC), o Modelo de Aceitação de Tecnologia (TAM), o UX Curves e o Método de Inspeção Semiótica Intermediado (MISI). Estes métodos confirmaram a eficácia da arquitetura em entregar recomendações musicais precisas e adaptáveis, alinhadas com as mudanças nas preferências e contextos dos usuários. A arquitetura também aborda o desafio do "cold-start", implementando mecanismos de feedback imediato e aprendizado contínuo para aprimorar as recomendações. A tese conclui que a UConteXt Arch representa uma solução para o problema identificado, demonstrando que é possível aprimorar significativamente os sistemas de recomendação musical ao integrar de maneira eficaz o contexto da interação e a experiência do usuário. Este estudo ajuda a melhorar a qualidade das recomendações musicais, mas também enriquece a experiência do usuário, contribuindo de forma substancial para o campo dos sistemas de recomendação de música.

**Palavras-chave:** Sistemas de recomendação, contexto, experiência do usuário, cold-start.

---

# Abstract

---

This doctoral thesis addresses the research problem: "How can music recommendation systems be improved to more effectively integrate interaction context and user experience?". In response to this question, the research develops and evaluates UConteXt Arch, an architecture for music recommendation systems. This architecture is designed to enhance the user experience, explicitly considering the interaction context and musical preferences. The methodological approach adopted is Design Science Research (DSR), which enables iterative and cyclical analysis in the development of UConteXt Arch. The architecture is based on theories and research into recommendation systems, user experience, and contextual personalization. The development of UConteXt Arch involved a systematic literature review and exploratory studies of current practices on platforms such as Spotify and Deezer. The evaluation of UConteXt Arch included a variety of methods, such as the Communicability Assessment Method (MAC), the Technology Acceptance Model (TAM), UX Curves, and the Method of Intermediate Semiotic Inspection (MISI). These methods confirmed the effectiveness of the architecture in delivering accurate and adaptable music recommendations in line with changing user preferences and contexts. The architecture also addresses the "cold-start" challenge by implementing immediate feedback mechanisms and continuous learning to improve recommendations. The thesis concludes that UConteXt Arch represents a solution to the identified problem, demonstrating that it can significantly improve music recommendation systems by more effectively integrating interaction context and user experience. This study helps improve the quality of music recommendations and enriches the user experience, making a substantial contribution to the field of music recommendation systems.

**Keywords:** Recommendation systems, context, user experience, cold-start.



---

# Lista de ilustrações

---

Figura 1 – Linha do tempo de atividades realizadas pelo autor desta Tese. . . . .	26
Figura 2 – Visão geral do processo de revisão sistemática. . . . .	45
Figura 3 – Publicações por ano versus tópicos. . . . .	54
Figura 4 – Correlação entre as abordagens de recomendação musical. . . . .	58
Figura 5 – Codificação (aberta e fechada) x Aspectos Desejáveis. . . . .	87
Figura 6 – Resultados do questionário SAM aplicados às Tarefas 2, 4 e 5 - Verme- lho para Spotify e Azul para o Deezer. . . . .	93
Figura 7 – Visão geral da Arquitetura . . . . .	98
Figura 8 – Visão Geral - Etapas do processo de definição de valores para cada recurso de áudio. . . . .	113
Figura 9 – Interfaces do aplicativo MixFy. . . . .	131
Figura 10 – Interface de avaliação UX Curves (MixFy). . . . .	132
Figura 11 – Visão geral do Método de Inspeção Semiótica Intermediado (MISI) . .	140
Figura 12 – Modelo de Regressão do TAM: Relações entre Questões e Construtores.	162
Figura 13 – Método Elbow Curve. . . . .	164
Figura 14 – Média dos Clusters ao Longo dos Dias. . . . .	165
Figura 15 – Variação e Tendência Central das Avaliações Diárias. . . . .	166
Figura 16 – Frequência das Avaliações Diárias por Intervalo. . . . .	168

---

## Lista de tabelas

---

Tabela 1 – Comparação entre as plataformas comerciais de música . . . . .	42
Tabela 2 – Publicações relacionadas. . . . .	46
Tabela 3 – Frequência de palavras-chave por termo único . . . . .	48
Tabela 4 – Frequência de palavras-chave por termo composto . . . . .	48
Tabela 5 – Lista de string de busca testadas em todos os repositórios. . . . .	49
Tabela 6 – Critérios de inclusão. . . . .	50
Tabela 7 – Critérios de Exclusão. . . . .	50
Tabela 8 – Publicações aceitas e rejeitadas em cada repositório científico. . . . .	51
Tabela 9 – Questões de qualidade . . . . .	52
Tabela 10 – Lista de publicações avaliadas. . . . .	52
Tabela 11 – Conjunto de perguntas do formulário de extração de dados. . . . .	53
Tabela 12 – Lista de abordagens. . . . .	55
Tabela 13 – Publicações selecionadas. . . . .	55
Tabela 14 – Aspectos desejáveis da recomendação musical. . . . .	69
Tabela 15 – Relação entre aspectos desejáveis e tarefas - Os participantes responderam a perguntas do SAM após as tarefas atribuídas por (*) . . . . .	82
Tabela 16 – Distribuição dos participantes em cada grupo de experimento. . . . .	84
Tabela 17 – Codificação aberta e fechada (MAC) para cada tarefa. . . . .	88
Tabela 18 – Codificação aberta e fechada (MAC) para cada plataforma. . . . .	89
Tabela 19 – Perfil dos participantes: Plataforma, Grupo (contexto e emoção) e Resultados do SAM: PI - Pleasure Index, AI - Arousal Index, DI - Dominance Index. . . . .	92
Tabela 20 – Média, desvio padrão e coeficiente alfa de Cronbach por questão e construto (utilidade percebida, facilidade de uso percebida, intenção de uso). . . . .	147
Tabela 21 – Coeficientes de Correlação de Pearson. . . . .	148

Tabela 22 – Média, desvio padrão e coeficiente alfa de Cronbach por questão e construto (utilidade percebida, facilidade de uso percebida, intenção de uso). . . . .	157
Tabela 23 – Coeficientes de Correlação de Pearson. . . . .	158
Tabela 24 – Parâmetros da Análise de Regressão para Construtores do TAM. . . .	160
Tabela 25 – Análise Estatística Descritiva dos Dados do UX Curves . . . . .	163

---

# Lista de abreviaturas e siglas

---

CCC	Características Comuns de Contexto
CCI	Informações de contexto comum (Common Context Information)
CF	Filtragem colaborativa (Collaborative filtering)
DCU	Design Centrado no Usuário
DIM	Modelo dimensional de emoção (Dimensional Emotion Model)
DISC	Modelo de emoção discreta (Discrete Emotion Model)
ECG	Eletrocardiograma
EEG	Eletroencefalograma
EPMRS	Sistema de Recomendação Musical Personalizado e Sensível à Emoção
ESTM	Modelo de Transição de Estados Emocionais
FC	Filtragem Colaborativa
FE	Expressão facial (Facial Expression)
FEED	Feedback
FM	Factoring Machine
FUP	Facilidade de Uso Percebida
HRV	Heart Rate Variability
IHC	Interação Humano-Computador
IU	Intenção de Uso

MAC	Método de Avaliação da Comunicabilidade
MC	Contexto musical (Music Context)
MD	Dados musicais (Musical Data)
MDI	Informações sobre dispositivos móveis (Mobile Device Information)
MF	Máquina de Fatoração
MIS	Método de Inspeção Semiótica
MISI	Método de Inspeção Semiótica Intermediado
ML	Aprendizado de máquina (Machine Learning)
MP	Preferências musicais (Musical Preferences)
MVC	Model-View-Controller
ON	Ontologias (Ontology)
RBC	Raciocínio Baseado em Casos
REM	Reconhecimento de Emoções Musicais
RSL	Revisão Sistemática da Literatura
SAM	Self-Assessment Manikin
SEN	Sensores(Sensors)
SI	Informações subjetivas (Subjective Information)
SIM	Similaridade (Similarity)
SN	Redes sociais (Social Networks)
SQL	Structured Query Language
SUS	System Usability Scale
TAM	Modelo de Aceitação de Tecnologia
UA	Atividade do usuário (User Activity)
UB	Comportamento do usuário (User Behavior)
UH	Histórico do usuário (User History)
UP	Utilidade Percebida
UX	User Experience

---

# Sumário

---

<b>1</b>	<b>INTRODUÇÃO . . . . .</b>	<b>17</b>
1.1	Contexto e motivação . . . . .	17
1.2	Problema de pesquisa . . . . .	19
1.3	Objetivos . . . . .	20
1.4	Metodologia do desenvolvimento do trabalho . . . . .	20
1.5	Contribuições da pesquisa . . . . .	22
1.6	Percurso do pesquisador . . . . .	24
1.7	Estrutura da Tese . . . . .	25
<b>2</b>	<b>FUNDAMENTAÇÃO TEÓRICA . . . . .</b>	<b>27</b>
2.1	Contexto . . . . .	27
2.1.1	Categorização do contexto . . . . .	29
2.1.2	Consciência do Contexto - <i>Context Awareness</i> . . . . .	30
2.1.3	Categorização de consciência de contexto . . . . .	31
2.2	Experiência do usuário ( <i>UX - User Experience</i> ) . . . . .	32
2.2.1	Dimensões da UX . . . . .	33
2.3	Sistemas de recomendação de música . . . . .	35
2.3.1	Recuperação de informações sobre metadados . . . . .	36
2.3.2	Filtragem colaborativa . . . . .	36
2.3.3	Recuperação de informações baseadas no conteúdo . . . . .	36
2.3.4	Recomendação de música considerando informações contextuais . . . . .	37
2.4	UX em sistemas de recomendação . . . . .	38
2.5	Plataformas de <i>streaming</i> de música . . . . .	38
2.5.1	Spotify . . . . .	39
2.5.2	Deezer . . . . .	40
2.5.3	Apple Music . . . . .	40
2.5.4	Youtube Music . . . . .	41

2.5.5	Comparação de serviços de <i>streaming</i> . . . . .	41
2.6	Considerações finais . . . . .	42
3	<b>REVISÃO SISTEMÁTICA DA LITERATURA . . . . .</b>	<b>44</b>
3.1	Identificação da necessidade de uma revisão . . . . .	44
3.2	Questões de pesquisa . . . . .	47
3.3	Definição da string de busca . . . . .	48
3.4	Estratégia de busca . . . . .	49
3.5	Seleção dos estudos . . . . .	50
3.6	Lista de verificação de avaliação de qualidade . . . . .	51
3.7	Extração de dados . . . . .	51
3.8	Resultados . . . . .	53
3.8.1	RQ-1: Que abordagens são usadas para a recomendação musical? . . . .	54
3.8.2	RQ-2: Quais aspectos são desejáveis a serem tratados nos sistemas de recomendação musical? . . . . .	68
3.9	Desafios . . . . .	72
3.9.1	Perspectiva do contexto . . . . .	73
3.9.2	Perspectiva da emoção . . . . .	75
3.10	Considerações finais . . . . .	78
3.10.1	Considerações finais . . . . .	79
4	<b>AVALIANDO A EXPERIÊNCIA DO USUÁRIO NA DESCO- BERTA DE MÚSICA EM DEEZER E SPOTIFY . . . . .</b>	<b>80</b>
4.1	Planejamento . . . . .	81
4.2	Condução . . . . .	84
4.3	Análise . . . . .	85
4.4	Resultados e discussões . . . . .	86
4.4.1	Avaliação da experiência do usuário . . . . .	91
4.5	Considerações finais . . . . .	94
5	<b>UCONTEXT ARCH: UMA ARQUITETURA PARA RECO- MENDAÇÃO MUSICAL BASEADA EM CONTEXTO E EX- PERIÊNCIA DO USUÁRIO . . . . .</b>	<b>96</b>
5.1	Visão geral da arquitetura . . . . .	97
5.2	Camada de Interface . . . . .	100
5.3	Camada de Middleware . . . . .	100
5.3.1	Módulo de Feedback . . . . .	101
5.3.2	Módulo de Gêneros Musicais . . . . .	102
5.3.3	Módulo de Popularidade . . . . .	104
5.3.4	Módulo de Contexto Atual do Usuário . . . . .	106

<b>5.4</b>	<b>Camada de Serviços</b>	<b>108</b>
5.4.1	Módulo de Integração com Plataformas de Música	109
5.4.2	Módulo do Cold-start	112
5.4.3	Módulo de Recálculo de Recursos de Áudio	116
5.4.4	Módulo de Artistas Preferidos	117
5.4.5	Módulo de Predição Adaptativa	120
5.4.6	Módulo de Filtragem de Músicas	123
5.4.7	Módulo Gerenciador de Recomendações	125
<b>5.5</b>	<b>Implementação da arquitetura UConteXt Arch</b>	<b>128</b>
5.5.1	Ambiente de implementação	129
5.5.2	Implementação da Camada de Interface	130
5.5.3	Considerações técnicas sobre a implementação da Camada de Serviços, Middleware e Dados	133
<b>5.6</b>	<b>Mapeamento dos aspectos desejáveis na arquitetura</b>	<b>135</b>
<b>6</b>	<b>DO CONTEXTO DO USUÁRIO ÀS LISTAS DE REPRODUÇÃO PERSONALIZADAS</b>	<b>138</b>
<b>6.1</b>	<b>Método de Inspeção Semiótica Intermediado</b>	<b>139</b>
6.1.1	Aplicação do MISI	140
<b>6.2</b>	<b>O Modelo de Aceitação de Tecnologia (TAM)</b>	<b>142</b>
6.2.1	Aplicando o TAM	143
<b>6.3</b>	<b>Resultados</b>	<b>143</b>
6.3.1	MISI: Falhas semióticas e experiência do usuário	144
6.3.2	TAM - Percepções e intenções do usuário	146
<b>6.4</b>	<b>Discussão</b>	<b>149</b>
<b>6.5</b>	<b>Considerações finais</b>	<b>150</b>
<b>7</b>	<b>AVALIANDO A ARQUITETURA UCONTEXT ARCH A PARTIR DA EXPERIÊNCIA DO USUÁRIO</b>	<b>152</b>
<b>7.1</b>	<b>Avaliações de UX ao longo do tempo</b>	<b>153</b>
<b>7.2</b>	<b>Método UX Curves e TAM</b>	<b>154</b>
<b>7.3</b>	<b>Planejamento da avaliação</b>	<b>154</b>
<b>7.4</b>	<b>Condução da avaliação</b>	<b>155</b>
<b>7.5</b>	<b>Resultados</b>	<b>156</b>
7.5.1	TAM: Perspectivas e motivações dos usuários	156
7.5.2	UX Curves: Análise da jornada do usuário	162
7.5.3	Considerações finais	169
<b>8</b>	<b>CONSIDERAÇÕES FINAIS E TRABALHOS FUTUROS</b>	<b>171</b>
<b>8.1</b>	<b>Considerações finais</b>	<b>171</b>



8.2	Limitações . . . . .	173
8.3	Trabalhos futuros . . . . .	173
	REFERÊNCIAS . . . . .	175

**APÊNDICES** 195

APÊNDICE A	– AVALIAÇÃO DA EXPERIÊNCIA DO USUÁRIO EM PLATAFORMAS COMERCIAIS DE MÚSICA: QUESTIONÁRIO DE PERFIL DOS PARTICIPANTES E QUESTIONÁRIO SAM .	196
APÊNDICE B	– AVALIAÇÃO DA COMUNICABILIDADE DA UCONTEXT ARCH NO MIXFY: QUESTIONÁRIO DE PERFIL DEMOGRÁFICO, QUESTIONÁRIO TAM E ROTEIRO DE INSPEÇÃO	205
APÊNDICE C	– AVALIAÇÃO DA ARQUITETURA UCONTEXT ARCH A PARTIR DA EXPERIÊNCIA DO USUÁRIO: QUESTIONÁRIO DE PERFIL DEMOGRÁFICO E QUESTIONÁRIO TAM . . . . .	222

**ANEXOS** 232

ANEXO A	– PARECER DE APROVAÇÃO 1 (COMITÊ DE ÉTICA): ESTUDO SOBRE A AVALIAÇÃO DA EXPERIÊNCIA DO USUÁRIO EM PLATAFORMAS COMERCIAIS DE MÚSICA. . . . .	233
ANEXO B	– PARECER DE APROVAÇÃO 2 (COMITÊ DE ÉTICA): ESTUDO SOBRE AVALIAÇÃO DA EXPERIÊNCIA DE USUÁRIOS NO MIXFY: ABORDAGEM SEMIÓTICA INTERMEDIADA E USO O PROLONGADO DIANTE DO CONTEXTO ATUAL. .	241

---

# Capítulo 1

## Introdução

---

### 1.1 Contexto e motivação

Na era digital, os sistemas de recomendação tornaram-se essenciais nas plataformas de streaming de música. Elas se destacam pela habilidade de filtrar e personalizar grandes conjuntos de dados, facilitando a descoberta de novas músicas pelos usuários (SCHEDL et al., 2018). Com a evolução desses sistemas, houve um aprimoramento notável na precisão e adaptabilidade, melhorando significativamente a experiência de usuário (FERNANDO; BAIZAL; DHARAYANI, 2021). Estudos como o de Sun (2022c) ressaltam que a análise de grandes volumes de dados proporcionou um entendimento mais profundo das preferências dos usuários.

Plataformas como Spotify<sup>1</sup> e Apple Music<sup>2</sup> exemplificam o sucesso dos sistemas de recomendação modernos, que integram algoritmos avançados para proporcionar experiências musicais personalizadas. Estes sistemas expandem-se para além do simples registro de músicas ouvidas, empregando técnicas avançadas de aprendizado de máquina para compreender as preferências e comportamentos dos usuários (ANDERSON et al., 2020). Sun (2021) sugerem que essa personalização eleva a satisfação do usuário. No entanto, Murciego et al. (2021) identificaram desafios na compreensão dos contextos dos usuários, uma lacuna também observada por (SCHEDL et al., 2018), que destacam a necessidade de incorporar efetivamente o contexto da interação na experiência do usuário.

O conceito de “contexto”, conforme definido por Abowd et al. (1999), refere-se a qualquer informação que descreva a situação de uma entidade, com ênfase na dimensão da atividade do usuário. Entre as dimensões propostas, a atividade é notável por oferecer

---

<sup>1</sup> <https://www.spotify.com/>

<sup>2</sup> <https://www.apple.com/apple-music/>

compreensões importantes sobre as ações atuais do usuário. Paralelamente, a “experiência do usuário” (UX), conforme descrita por Law et al. (2009), é um conceito dinâmico moldado pelo contexto. Esta abordagem inclui uma gama de benefícios percebidos durante a interação com produtos. Law et al. (2009) expandem esta visão nas “Dimensões do Contexto de Uso”, enfatizando a importância de fatores situacionais, culturais e sociais na UX, integrando assim o contexto como uma dimensão fundamental da UX.

Portanto, a importância de pesquisar sistemas de recomendação de música que integram o contexto e a experiência do usuário é evidenciada pelas limitações observadas em plataformas atuais. Knijnenburg et al. (2012) revelam que muitos sistemas negligenciam a experiência subjetiva dos usuários em suas recomendações. Himeur et al. (2021) argumentam que a ausência de tratamento do contexto pode resultar em recomendações menos pertinentes. Além disso, Liu et al. (2022) apontam a limitada participação dos usuários no feedback, prejudicando a eficácia dos algoritmos de recomendação. Xie et al. (2021) corroboram essa visão, indicando que um entendimento aprofundado da experiência do usuário poderia melhorar substancialmente a qualidade das recomendações.

A pesquisa sobre sistemas de recomendação de música que consideram o contexto da interação e a experiência do usuário é, portanto, de grande importância e são evidenciados nos estudos de Adomavicius e Tuzhilin (2011), Yu, Lin e Wang (2016), Assuncao, Piccolo e Zaina (2022), Bu, Luo e Zeng (2023). Yu, Lin e Wang (2016) sugerem que a inclusão do contexto e experiência do usuário eleva a satisfação e o engajamento. Além disso, foi demonstrado que a integração de informações valiosas provenientes de avaliações de usuários promovem a experiência em sistemas de recomendação, enfatizando a importância de aproveitar o conteúdo gerado pelo usuário para melhorar o desempenho da recomendação (CAO et al., 2018).

O estado atual dos sistemas de recomendação de música baseados em contexto e experiência do usuário mostra uma crescente, mas com limitações que ainda afetam sua eficácia, como por exemplo o problema do *Cold-start* que acontece porque pouca informação é conhecida sobre este usuário ou porque o sistema tem um novo usuário (CHEN; CHEN; WANG, 2015). Além disso, estudos como os de Zhang et al. (2021) revelam que muitos desses sistemas ainda priorizam dados objetivos, como históricos de escuta e popularidade das faixas, sem incorporar adequadamente o contexto atual do usuário. Esta ênfase em dados objetivos pode levar a recomendações que não se alinham efetivamente com as necessidades situacionais dos usuários, como seu ambiente atual ou atividades específicas.

Embora existam iniciativas para integrar aspectos contextuais e experiências do usuário em sistemas de recomendação musical, como observado por Assuncao, Piccolo e Zaina (2022), elas ainda são exceções. O panorama atual dos sistemas de recomendação de música, apresentam várias questões de pesquisa que precisam ser abordadas (ASSUNCAO; PICCOLO; ZAINA, 2022; VELANKAR; KULKARNI, 2023). Assuncao, Piccolo e Zaina

(2022) destacam a complexidade de abordagens de recomendações híbridas (contexto e emoção), apontando desafios técnicos e teóricos. Velankar e Kulkarni (2023) enfatizam a necessidade de uma abordagem multidisciplinar para superar esses desafios.

Os sistemas de recomendação de música enfrentam desafios específicos, incluindo a necessidade de atualização constante do catálogo musical para manter as recomendações pertinentes, especialmente em certos gêneros. Estudos recentes, como os de Assuncao, Piccolo e Zaina (2022) e Velankar e Kulkarni (2023), ressaltam a importância de adaptar-se às mudanças nas preferências dos usuários ao longo do tempo para um aprendizado eficaz e contínuo. Velankar e Kulkarni (2023) destacam também a necessidade de feedback imediato dos usuários sobre as recomendações fornecidas, que influencia diretamente a experiência do usuário em diversos gêneros musicais. Além disso, enfatizam a relevância de integrar fatores contextuais, que variam no tempo, para melhorar a percepção e aceitação das recomendações. Ambos os estudos, Assuncao, Piccolo e Zaina (2022) e Velankar e Kulkarni (2023) trazem à tona a possibilidade de que sistemas de recomendação de música poderiam se beneficiar significativamente de uma abordagem mais integrada com as diversas dimensões contextuais e interativas da experiência do usuário, considerando tanto os padrões de escuta quanto as situações específicas de uso.

## 1.2 Problema de pesquisa

O problema de pesquisa desta tese centra-se nas limitações fundamentais dos sistemas de recomendação musical contemporâneos, particularmente em sua capacidade de incorporar o contexto da interação e a experiência do usuário nas recomendações. Apesar dos avanços tecnológicos substanciais em algoritmos de aprendizado de máquina e análise de grandes volumes de dados, como evidenciado por Anderson et al. (2020) e Sun (2022c), as recomendações muitas vezes carecem de personalização efetiva e contextualização.

Um aspecto crítico é a predominância de sistemas de recomendação que dependem excessivamente de dados objetivos, como históricos de escuta e popularidade das faixas. Esta abordagem, embora eficaz em certos aspectos, falha em capturar plenamente as nuances do contexto do usuário e suas preferências dinâmicas, conforme destacado por Zhang et al. (2021). Essa ênfase nos dados objetivos pode resultar em recomendações que não correspondem às necessidades do contexto atual dos usuários, como ressaltado por Schedl et al. (2018).

Além disso, os sistemas atuais enfrentam o desafio do *cold-start*, uma problemática em que pouca informação é conhecida sobre novos usuários ou em situações em que o sistema encontra um novo usuário, conforme descrito por Chen, Chen e Wang (2015). Esse problema é acentuado pela falta de feedback direto do usuário, limitando a eficácia dos algoritmos de recomendação, um ponto enfatizado por Liu et al. (2022) e Xie et al. (2021).

Dessa forma, esta pesquisa visou abordar a seguinte questão: *Como os sistemas de recomendação musical podem ser aprimorados para integrar o contexto da interação e a experiência do usuário?* Este problema é fundamentado pela necessidade de superar as limitações dos métodos atuais de recomendação, visando aprimorar a qualidade e a relevância das recomendações musicais para os usuários finais.

### 1.3 Objetivos

Neste sentido, o objetivo geral desta Tese foi investigar como os recomendadores das plataformas de música atuais podem ser aprimorados para integrar de maneira efetiva o contexto da interação e a experiência do usuário. A UConteXt Arch, uma arquitetura para sistemas de recomendação de música, foi desenvolvida como uma solução materializada deste objetivo, demonstrando na prática a integração destes aspectos críticos.

A partir do objetivo geral desta proposta, os seguintes objetivos específicos foram definidos:

- ❑ Identificar e compreender quais abordagens de recomendação são utilizadas nos sistemas de recomendação de música, bem como quais aspectos são considerados importantes para serem tratados nos sistemas de recomendação.
- ❑ Investigar como plataformas comerciais de música abordam e integram o conjunto de aspectos identificados.
- ❑ Desenvolver e propor uma arquitetura, denominada UConteXt Arch, que serve como um modelo prático para sistemas de recomendação de música que integram o contexto da interação e a experiência do usuário, visando superar as limitações das plataformas atuais;
- ❑ Validar a aplicabilidade do conceito de considerar o contexto e a experiência do usuário em sistemas de recomendação de música, por meio do desenvolvimento e implementação de uma instância prática da arquitetura UConteXt Arch, integrada a uma plataforma comercial de música.
- ❑ Avaliar a eficácia da arquitetura UConteXt Arch em relação a experiência do usuário.

### 1.4 Metodologia do desenvolvimento do trabalho

Para alcançar os objetivos apresentados nesta tese de doutorado, emprega-se o método Design Science Research (DSR). Conforme delineado por Hevner et al. (2010), é uma metodologia de pesquisa que busca criar e avaliar artefatos destinados a resolver problemas identificados, ou seja, algo criado com um propósito prático (WIERINGA, 2014). O DSR

se destaca por sua natureza iterativa e cíclica, englobando três ciclos principais: relevância, rigor e design (HEVNER et al., 2010; PEFFERS et al., 2012). Esses ciclos interagem continuamente, garantindo que o artefato desenvolvido seja não apenas teoricamente robusto, mas também prático e útil para as partes interessadas. No contexto desta pesquisa, o artefato central é a arquitetura UConteXt Arch para sistemas de recomendação musical, considerando o contexto e a experiência do usuário. A seguir será apresentado os conceito por trás de cada ciclo e uma visão geral das etapas realizadas durante cada ciclo do DSR.

O **ciclo de relevância** do DSR envolve a identificação de oportunidades e problemas em um ambiente específico de aplicação (HEVNER, 2007). No caso desta pesquisa, o ambiente refere-se ao domínio dos sistemas de recomendação musical, onde se observa a necessidade de integrar o contexto e a experiência do usuário de forma eficiente.

O ciclo de relevância foi iniciado com uma busca ad-hoc de Revisões Sistemáticas da Literatura (RSL) que apresentassem uma discussão sobre abordagens de recomendação musical. Esta análise preliminar apontou que há poucas investigações sobre abordagens de recomendação musical que lidam com o contexto e as emoções em conjunto. Dado isso, surgiu-se o objetivo de realizar uma revisão sistemática da literatura (Capítulo 3) para identificar lacunas significativas no campo dos sistemas de recomendação de música, a partir de abordagens de recomendação. A revisão apresentou desafios técnicos e centrados no usuário, além de um conjunto de aspectos considerados importantes de serem tratados pelos sistemas de recomendação de música.

No estudo subsequente (ASSUNÇÃO; ZAINA, 2022) (Capítulo 4), foram apresentadas evidências de que sistemas comerciais amplamente utilizados (Spotify e Deezer) não consideram suficientemente os aspectos desejáveis. Foi observado, particularmente, que há falhas significativas na comunicabilidade. De forma complementar, a pesquisa realizada por Velankar e Kulkarni (2023) também identificou uma série de problemas associados à experiência do usuário em sistemas de recomendação, ressaltando a necessidade de otimizações nestas plataformas.

Após estas investigações, surgiu a hipótese de que uma abordagem que pudesse incorporar o contexto e a experiência do usuário de maneira efetiva poderia melhorar a recomendação. A partir deste ponto, verificou-se a relevância da proposta da arquitetura UConteXt Arch (Capítulo 5) e o potencial de sua contribuição para a melhoria dos sistemas de recomendação existentes.

O **ciclo de rigor** no DSR exige a identificação do estado da arte para desenvolver o artefato com uma sólida base teórica (HEVNER et al., 2010). Este ciclo compreende à base de conhecimento, métodos, a análise de artefatos e processos existentes, bem como as experiências e competências que definem o estado da arte no domínio da aplicação (HEVNER, 2007).

Neste projeto, a base teórica para o desenvolvimento da UConteXt Arch foi estabelecida por meio de uma união de teorias relevantes e pesquisas anteriores (Capítulo 2

e 3). Esta fundamentação incluiu estudos sobre sistemas de recomendação, experiência do usuário e técnicas de personalização baseadas em contexto. A literatura existente proporcionou compreensões importantes para o design da arquitetura, garantindo que a proposta estivesse alinhada com as práticas atuais e as tendências emergentes da área de sistemas de recomendação de música.

De acordo com Hevner et al. (2010), o artefato precisa ser desenvolvido e avaliado iterativamente. Neste estudo, o **ciclo de design** é onde a UConteXt Arch (o artefato) é concebido, desenvolvido e iterativamente aprimorado. O desenvolvimento começou com a definição de uma arquitetura preliminar, fundamentada nos resultados da revisão da literatura e do estudo exploratório de plataformas.

Cada componente da UConteXt Arch foi projetado para atender aos desafios identificados. A arquitetura foi estruturada em camadas e módulos, cada uma desempenhando um papel específico na entrega de recomendações musicais personalizadas e contextualizadas.

A iteração contínua é uma parte importante do ciclo de design. Após cada estudo (Capítulos 6 e 7), a arquitetura foi ajustada com base no feedback e nos resultados obtidos. Esta abordagem garantiu que o artefato não só atendesse às necessidades teóricas, mas também se mostrasse prático e funcional na aplicação real.

Além disso, a implementação prática da UConteXt Arch foi um passo importante, pois tornou-se possível avaliar a arquitetura em um ambiente real e para isso criou-se o aplicativo MixFy e um servidor associado. Isso permitiu não apenas validar a teoria por trás da arquitetura, mas também testar sua eficácia em um cenário de uso real.

## 1.5 Contribuições da pesquisa

As principais contribuições desta Tese incluem:

- a) Um conjunto de 7 aspectos considerados fundamentais para serem implementados pelos sistemas de recomendação de música, que foram obtidos a partir da revisão sistemática da literatura (ASSUNCAO; PICCOLO; ZAINA, 2022).
- b) Lacunas específicas existentes em plataformas comerciais de música (Spotify e Deezer), a partir uma análise detalhada de falhas de comunicabilidade utilizando os sete aspectos identificados na revisão sistemática (ASSUNÇÃO; ZAINA, 2022).
- c) Uma metodologia para segmentar e analisar datasets de playlists de usuários com base em contexto e preferências de gênero musical. Esta metodologia inclui a filtragem e análise de recursos de áudio, resultando em um conjunto de dados consolidado (parâmetros) que informa sobre preferências contextuais e musicais dos usuários (ASSUNÇÃO; PRATES; ZAINA, 2023).

- d) A UConteXt Arch, uma arquitetura para sistemas de recomendação de música baseado em contexto de interação e experiência do usuário.
- e) A ferramenta UX Curve Tracker, que monitora a experiência do usuário em aplicações de software, contribuindo tecnicamente para o campo da experiência do usuário (UX). Número do registro: BR512023003658-7. A é uma implementação digital avançada do método UX Curve, que permite aos usuários registrar de forma interativa o nível de sua experiência ao longo do tempo. Utilizando um gráfico dividido em cinco colunas, correspondendo a um período de avaliação de cinco dias, os usuários podem marcar diariamente o nível de sua experiência, indicando se foi positiva ou negativa, e adicionar comentários explicativos. Este design permite que, para cada dia, apenas a coluna correspondente esteja ativa para marcações, enquanto as colunas dos dias anteriores ficam bloqueadas, evitando revisões retrospectivas e mantendo o foco na experiência atual. Com essa abordagem, o UX Curve Tracker fornece uma visão precisa e temporalmente rica da experiência do usuário, facilitando a coleta de dados valiosos para avaliação contínua e ajuste das recomendações musicais.
- f) A ferramenta MixFy, uma abordagem de recomendação de músicas adaptada ao contexto e preferências de gêneros musicais do usuário. Um modelo aplicado e prático. Número do registro: BR512023003656-0. A ferramenta utiliza algoritmos de aprendizado de máquina para analisar dados de contexto em tempo real, como a atividade atual do usuário, além de incorporar preferências de gênero musicais explicitamente informadas pelo usuário. MixFy representa um modelo aplicado de recomendação musical que reflete uma abordagem centrada no usuário, fornecendo uma interface intuitiva e personalizada para a descoberta musical.
- g) O AudioContextMapper, uma ferramenta que identifica padrões em playlists de música considerando contextos do usuário e preferências de gênero musical, aprimorando as técnicas de análise de dados em sistemas de recomendação musical. Número do registro: BR512023003657-9. A ferramenta é a concretização prática do módulo de Recálculo de Recursos de Áudio e identificação de parâmetros padrões iniciais para a filtragem das recomendações. Esta ferramenta analisa detalhadamente datasets de playlists, primeiramente filtrando-as pelo título para identificar contextos definidos, e posteriormente segmentando-as por gêneros musicais. A cada combinação de contexto e gênero, o AudioContextMapper aplica métodos estatísticos para calcular intervalos de percentis, estabelecendo valores mínimos e máximos para as características de áudio que definem o padrão para aquela configuração específica. Quando um novo usuário informa um contexto e gênero musical, os valores calculados são utilizados para buscar músicas correspondentes na plataforma comercial integrada. Esta funcionalidade torna o AudioContextMapper uma ferramenta



essencial para fornecer recomendações precisas e contextualmente relevantes para usuários novos.

- h) Desenvolvimento de um guia detalhado para uso da API de transcrição audio-to-text, facilitando o processo de transcrição de gravações em vídeo para texto, utilizando ferramentas como ffmpeg e Whisper da OpenAI. Este tutorial representa uma contribuição significativa para pesquisas que requerem transcrição precisa de dados audiovisuais.

Além disso, foram publicados os seguintes artigos completos:

- a) ASSUNCAO, W. G.; PICCOLO, L. S.; ZAINA, L. A. Considering emotions and contextual factors in music recommendation: a systematic literature review. *Multimedia Tools and Applications*, Springer, p. 1–41, 2022.
- b) ASSUNÇÃO, W. G.; ZAINA, L. A. M. Evaluating user experience in music discovery on deezer and spotify. In: *Proceedings of the 21st Brazilian Symposium on Human Factors in Computing Systems*. 2022. p. 1-11.
- c) ASSUNÇÃO, W. G.; PRATES, R. O.; ZAINA, L. A. M. Managing cold-start issues in music recommendation systems: An approach based on user experience. In: *Companion Proceedings of the 2023 ACM SIGCHI Symposium on Engineering Interactive Computing Systems*, 2023. p. 31–37.
- d) ASSUNÇÃO, W. G.; PRATES, R. O.; ZAINA, L. A. M. From User Context to Tailored Playlists: A User Centered Approach to Improve Music Recommendation System. In: *Proceedings of the 22st Brazilian Symposium on Human Factors in Computing Systems*, 2023.

## 1.6 Percurso do pesquisador

Durante o desenvolvimento do doutorado, o doutorando em questão engajou-se em múltiplas atividades acadêmicas e profissionais que contribuíram significativamente para sua formação como pesquisador, conforme demonstrado na Figura 1. O início do programa foi marcado pela conclusão dos créditos exigidos pelo PPGCC e pelo primeiro ciclo de pesquisa em 2019. Este período também incluiu a publicação de um artigo no Simpósio Brasileiro sobre Fatores Humanos em Sistemas Computacionais (IHC) e a finalização de dois estágios de docência.

No ano subsequente, a troca de supervisão e o realinhamento do projeto de doutorado precederam o ingresso no segundo ciclo de pesquisa e a publicação de mais um artigo em IHC. A condução de uma revisão sistemática da literatura foi realizada em 2021, um

ano também marcado pela realização do exame de proficiência em inglês e pela defesa de qualificação.

Em 2022, o doutorando publicou dois artigos, o primeiro no periódico *Multimedia Tools and Applications - (MTAP)* e o segundo no IHC. O pesquisador também assumiu uma posição docente na Universidade de Rio Verde e iniciou o processo de construção da arquitetura UConteXt Arch. No ano de 2023, atividades como a realização de avaliações com usuários, publicação de artigos em conferências como EICS e IHC e o registro de software foram desenvolvidas paralelamente à escrita da tese.

Adicionalmente, o doutorando realizou revisões de trabalhos para o Simpósio Brasileiro de Engenharia de Software (SBES) 2023, para a Trilha de Ideias Inovadoras do IHC 2023 e para a Conferência Latino-Americana de Interação Humano-Computador (CLIHC) 2021. A interação com pesquisadores de instituições como UFAM, UFMG e Open University culminou em publicações colaborativas. Contribuições para a formação acadêmica incluíram a participação em bancas de conclusão de curso na UniRV.

## 1.7 Estrutura da Tese

Esta Tese está organizada em oito capítulos.

O **Capítulo 2** apresenta os fundamentos teóricos que embasam o desenvolvimento da tese. Aqui, são abordados conceitos essenciais sobre contexto, Experiência do Usuário (UX), sistemas de recomendação de música e UX em sistemas de recomendação de música.

No **Capítulo 3**, apresenta a Revisão Sistemática da Literatura (RSL). O foco desta revisão foi identificar abordagens de recomendação musical que consideram emoção e contexto do usuário, além de destacar um conjunto de aspectos desejáveis em sistemas de recomendação. Esta revisão serviu para contextualizar o trabalho e identificar lacunas que o projeto buscou preencher.

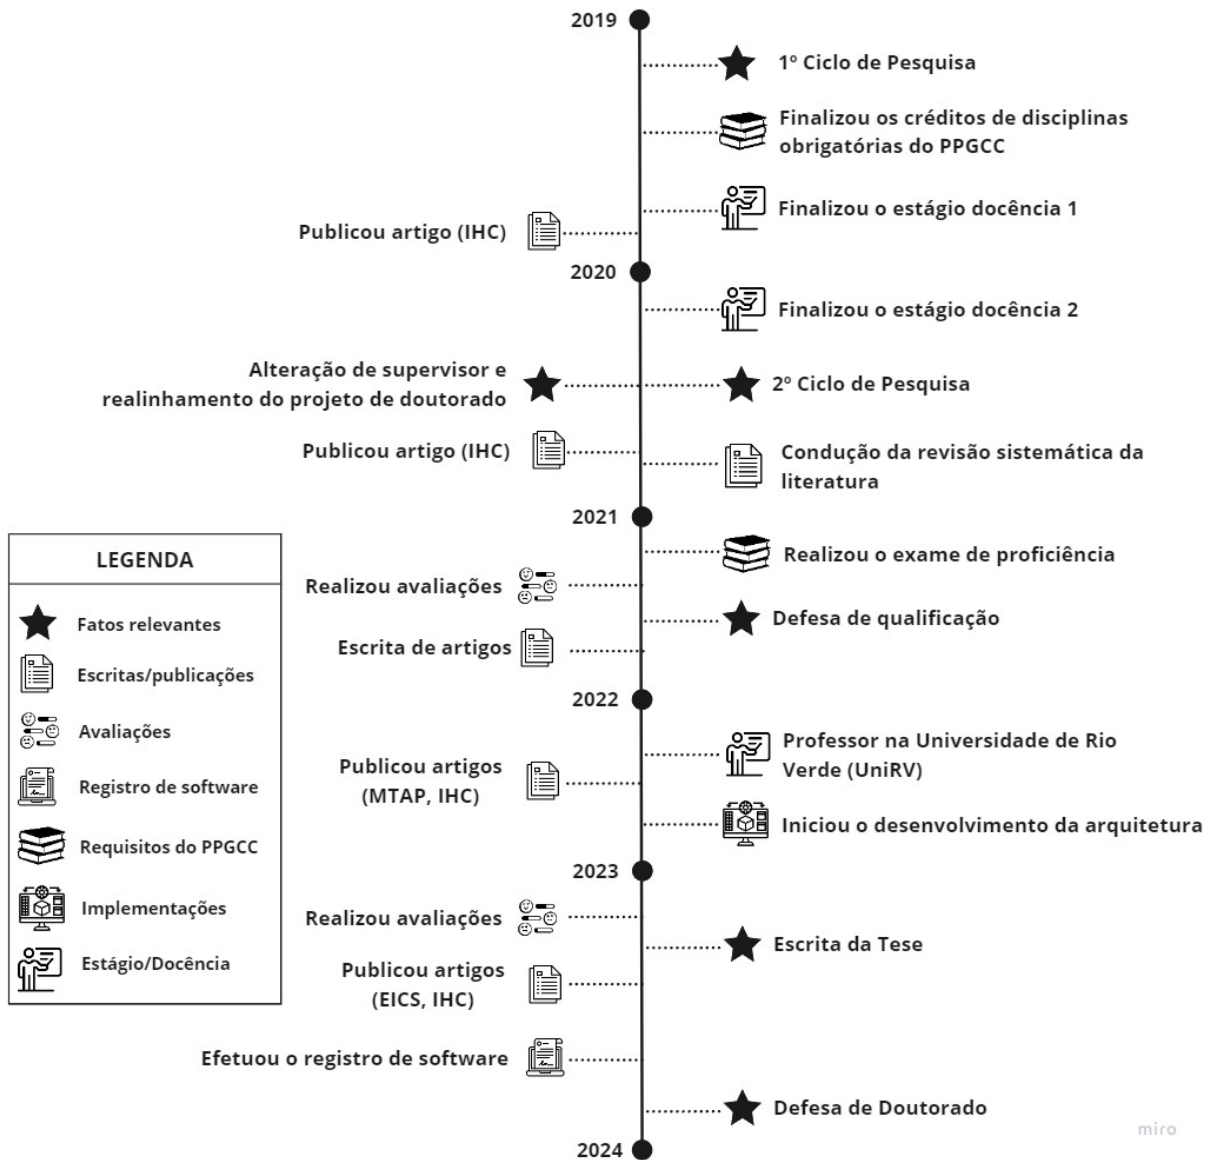
O **Capítulo 4** contém o estudo de avaliação da experiência do usuário na descoberta de música nas plataformas Deezer e Spotify. O estudo utilizou o Método de Avaliação da Comunicabilidade (MAC), fornecendo insights importantes sobre a eficácia e os desafios de comunicação nestas plataformas comerciais.

O **Capítulo 5** introduz a 'UConteXt Arch', uma Arquitetura para Recomendação Musical Baseada em Contexto e Experiência do Usuário. Neste Capítulo as camadas e módulos são detalhados, levando em conta os objetivos e especificidades de cada um.

No **Capítulo 6** o foco é a avaliação da abordagem de recomendação proposta relacionadas a solução do problema do *cold-start*. A avaliação visa determinar a eficácia e a comunicabilidade do sistema, além de medir a aceitação dos usuários em relação à tecnologia proposta.

O **Capítulo 7** aborda a avaliação e validação da arquitetura UConteXt Arch em um contexto real. Este capítulo detalha o planejamento e a execução da avaliação, demons-

Figura 1 – Linha do tempo de atividades realizadas pelo autor desta Tese.



Fonte: Elaborado pelo autor

trando a viabilidade e eficácia da arquitetura em um ambiente prático.

Por fim, o tem se a **Conclusão** desta Tese e sugestões para trabalhos futuros

---

## Capítulo 2

# Fundamentação Teórica

---

*Este capítulo aborda o ciclo de rigor do Design Science Research. Estabelecem-se os fundamentos teóricos para a pesquisa, discutindo-se conceitos fundamentais de sistemas de recomendação, experiência do usuário e contextos de interação. Esta fundamentação fornece a base necessária para o desenvolvimento subsequente da arquitetura UConteXt Arch. Explora-se também a relevância dos trabalhos relacionados para o reconhecimento das lacunas que a arquitetura proposta visa preencher.*

O capítulo foi dividido da seguinte forma: a Seção 2.1, denominada "Contexto", aborda a categorização do contexto e a consciência do contexto. A Seção 2.2, "Experiência do Usuário", destaca avaliações de UX ao longo do tempo e as dimensões da UX. A Seção 2.3 concentra-se nos sistemas de recomendação de música. A Seção 2.4 analisa a UX em sistemas de recomendação. Por último, a Seção 2.5 apresenta plataformas de streaming de música e uma comparação entre elas é realizada.

### 2.1 Contexto

O conceito de **Contexto** é multifacetado e tem sido amplamente explorado em diversas áreas de pesquisa. Esta seção busca sintetizar as diferentes definições e perspectivas de contexto, com o objetivo de estabelecer uma compreensão abrangente e aplicável aos sistemas de recomendação musical e outros sistemas sensíveis ao contexto.

O termo Contexto tem sido estudado por muitos pesquisadores. Muitos pesquisadores definiram o contexto de acordo com seu entendimento, num esforço para considerar um conceito mais geral de contexto. Schilit, Adams e Want (1994) utilizaram o termo

contexto em 1994 e descrito como identidades, localização, objetos e pessoas próximas (SCHILIT; ADAMS; WANT, 1994). Em 1999, Brown definiu contexto como os elementos que envolvem um usuário que um computador pode identificar (ABOWD et al., 1999). Por outro lado, Schmidt, Beigl e Gellersen (1999) definiram usando três dimensões: ambiente físico, fatores humanos e tempo. O contexto físico é um conjunto de características do ambiente, enquanto que o contexto cultural inclui informações do usuário, o ambiente social e as crenças.

Uma definição frequentemente citada na literatura pertence aos trabalhos de Abowd et al. (1999) e Dey (2001): "*Contexto é qualquer informação que pode ser usada para caracterizar a situação de uma entidade*". Uma entidade é uma pessoa, lugar ou objeto que é considerado relevante para a interação entre um usuário e uma aplicação, incluindo o usuário e as próprias aplicações". O contexto é útil e as pessoas trabalharam nele, concentrando-se principalmente na localização, embora a situação de uma entidade possa consistir em tempo, localização, atividade e os fatores ao redor que possam afetar a atividade de uma entidade.

Abowd et al. (1999) ainda discutem a relevância de certos tipos de contexto em aplicações práticas. Os autores identificam quatro elementos importantes: localização, identidade, **atividade** e tempo. Dentre esses, a atividade se destaca por fornecer compreensões essenciais sobre as ações atuais do usuário. Esta dimensão de contexto é fundamental para entender o que está acontecendo na situação específica do usuário.

Dourish (2004) argumenta que o contexto não deve ser visto como um conjunto estático de informações representacionais, mas como uma propriedade relacional emergente das interações humanas. Ele enfatiza que o contexto é algo que é continuamente produzido e redefinido através das atividades cotidianas, desafiando a noção de que contexto e conteúdo são entidades separáveis. Esta perspectiva destaca a importância de considerar o contexto como um elemento dinâmico e mutável, intrinsecamente ligado às interações e experiências dos usuários, o que é fundamental para o design de sistemas de recomendação musical eficazes e adaptáveis.

Bradley e Dunlop (2005) propuseram um modelo multidisciplinar de contexto de uso integrando IHC e perspectivas de computação consciente do contexto. Os autores definem o contexto de uso como "qualquer coisa que influencie o processo no qual ações focais do usuário estão sendo tomadas" e sugerem as seguintes dimensões:

- ❑ **Contexto da tarefa:** pessoas e objetos que cercam a tarefa, com vantagens ("recursos") e desvantagens ("restrições") para sua realização.
- ❑ **Contexto físico:** inclui a localização ambiental, elementos físicos próximos e seus atributos, mas também as condições climáticas e de luz.
- ❑ **Contexto social:** influências das pessoas ao redor (relacionamento, diálogo, presença e comportamento).

- ❑ **Contexto temporal:** influências de experiências passadas em termos de expectativas, e explicações do presente. Também inclui o contexto temporal de nível superior (por exemplo, hora atual, data ou estação do ano).
- ❑ **Contexto da aplicação:** o fluxo de informação entre o usuário e o dispositivo (por exemplo, a representação do estado e funcionamento da aplicação).
- ❑ **Contexto cognitivo:** as habilidades cognitivas, hábitos e atitudes do usuário.

O termo contexto foi classificado em duas categorias (física e lógica). O **contexto físico** pode ser determinado por sensores de hardware e o **contexto lógico** é dado ou pela entrada do usuário ou pela captura de suas interações com os serviços disponíveis (ALEGRE; AUGUSTO; CLARK, 2016; SUBBU; VASILAKOS, 2017). Por exemplo, através da observação ou análise do perfil do usuário, atividades, rotinas de trabalho, atividade de digitação, etc. A maioria das pesquisas nesta área faz uso de sensores físicos de luz, movimento, som, temperatura, toque e, é claro, localização. Os sensores lógicos, entretanto, fornecem informações relacionadas através da leitura das informações do usuário a partir de páginas da web abertas e outros documentos e também analisam os dados do usuário (interações) e, com base nessas interações, visam a publicidade.

### 2.1.1 Categorização do contexto

Barrett e Power (2003) apresentam a categorização do contexto nas seguintes perspectivas: **contexto interno** ou externo, contexto material ou contexto social, contexto físico ou virtual, contexto em tempo real ou contexto irreal, contexto natural, contexto tecnológico ou contexto social. A categorização do contexto pode descobrir o contexto possível facilmente simplificar a manipulação do contexto e pode ser útil no fornecimento de informações de contexto de qualidade.

Dois possíveis pontos de vista gerais de categorização apresentados por Razzaque, Dobson e Nixon (2006) são:

- ❑ **Ponto de vista conceitual** - descreve o espaço contextual em termos dos atores, das ações e das relações entre eles.
- ❑ **Ponto de vista de medição** - contém contexto contínuo, contexto enumerativo, contexto de estado, e contexto descritivo, contexto físico e virtual.

Além disso, os contextos podem ser classificados como contextos estáticos ou dinâmicos. Outro significado semelhante é contexto contínuo e discreto. O **Contexto estático** muda frequentemente durante a operação do sistema, como lista de contatos, calendário, perfil do usuário, lista de afazeres, lista de endereços e outros. **Contexto dinâmico** é

uma informação altamente variável, como temperatura, tempo, localização do usuário, humor do usuário e outros (YEUNG; YANG, 2010).

No trabalho realizado por Asabere (2013), o contexto é dividido em três categorias: Contexto do usuário, Contexto físico, Contexto computacional .

- ❑ Contexto do usuário consiste na situação social, pessoas próximas, perfil e localização do usuário.
- ❑ O contexto físico é composto pelo clima, temperatura, condições de trânsito, iluminação e nível de ruído.
- ❑ O Contexto computacional consiste no seguinte: recursos próximos, como estações de trabalho, impressoras e monitores, largura de banda de comunicação e também conectividade de rede (ASABERE, 2013).

Já no estudo realizado por Gallego et al. (2013), os autores caracterizaram o contexto em três tipos: Contexto social, Contexto de localização, Contexto de usuário. O contexto social inclui, perfis relacionados, interesse comum, etc. Contexto de localização Consiste em informações geográficas, nacionalidade, etc. O Contexto de usuário consiste na atividade atual do usuário.

### 2.1.2 Consciência do Contexto - *Context Awareness*

O termo **Consciência do Contexto** (Context Awareness) foi introduzido por Schilit e Theimer como sensível (SCHILIT; THEIMER, 1994). "Um sistema é sensível ao contexto se ele usa o contexto para fornecer informações e/ou serviços relevantes ao usuário, onde a relevância depende da tarefa do usuário". Os sistemas sensíveis ao contexto são capazes de adaptar suas atividades com base no contexto atual. Isto também aumenta a eficácia, levando em conta o contexto ambiental. Sistemas conscientes do contexto observam o meio ambiente o tempo todo e propõem sugestões adequadas aos usuários para que eles possam tomar as ações necessárias. Por exemplo, publicar a localização de um usuário para membros apropriados de uma rede social, e permitir que os varejistas publiquem ofertas especiais para clientes potenciais que estejam próximos aos varejistas.

Os sistemas que conhecem o contexto utilizaram uma variedade de contextos como localização, ambiente e dispositivo. A localização atual de um usuário para um dispositivo foi considerada como contexto. O contexto ambiental ambiente inclui o perfil de um ambiente. O contexto do dispositivo de modelagem de sistemas inclui o ajuste do brilho da tela com base na energia disponível da bateria . O contexto do usuário inclui sua atividade física, seu modo de transporte e registros de atividade do usuário, estilos de uso para referências de deslocamento, compras, entre outros (WANT et al., 1995; BIBRI, 2015).

Um sistema consciente do contexto compreende de três componentes principais. Para começar, o sistema reúne informações de contexto disponíveis na interface do usuário, dados pré-especificados ou sensor e as adiciona a um repositório. Além disso, o sistema converte a informação bruta de contexto coletada em um contexto significativo que pode ser utilizado. Finalmente, o sistema usa o contexto e dá uma reação, e revela o contexto apropriado para o usuário (LIU; LI; HUANG, 2011). Para auxiliar os usuários na tomada de decisões a partir das inferências de contexto, as técnicas de análise de dados coletados são de grande ajuda (HU et al., 2014).

Em sistemas conscientes do contexto, o contexto pode ser, dados brutos e também informações significativas utilizadas para tomar decisões. Os dados podem vir de várias fontes. Para definir os dados de contexto, os dados precisam ser pré-processados. Quando os dados são diversos, eles têm que ser normalizados e agregados (BIBRI; KROGSTIE, 2017).

### 2.1.3 Categorização de consciência de contexto

De acordo com a influência do comportamento do sistema, a consciência de contexto pode ser dividida em consciência de contexto ativa e passiva (CHEN; KOTZ, 2000).

- ❑ **Consciência de contexto ativo:** um aplicativo se adapta automaticamente para descobrir o contexto por meio da alteração do comportamento do aplicativo.
- ❑ **Consciência de contexto passivo:** um aplicativo apresenta o contexto novo ou atualizado para um usuário interessado ou torna o contexto persistente para o usuário recuperar mais tarde.

A consciência do contexto também pode ser amplamente classificada nas seguintes áreas: consciência de contexto independente e baseada em infraestrutura. Se considerarmos as ferramentas de aquisição de informação, ela também consiste na consciência de contexto *hard* que pode ser obtida por sensores de hardware que medem a consciência de contexto, e a consciência de contexto *soft* que inferência de conhecimento baseada no repositório de informação da consciência de contexto (TUULARI, 2000).

#### 2.1.3.1 Aquisição e detecção de contexto

A aquisição do contexto é o nível mais básico de consciência do contexto. Em geral, há três maneiras de adquirir contexto: (MOSTEFAOUI; PASQUIER-ROCHA; BREZIL-LON, 2004).

- ❑ **Contexto detectado:** as informações do ambiente e as informações físicas do usuário podem ser adquiridas por sensores físicos ou de software. E o hábito de



interação do usuário e o registro histórico interativo são obtidos principalmente pelo sensor lógico do host.

- ❑ **Contexto derivado:** este tipo de informação contextual pode ser calculado em tempo real.
- ❑ **Contexto explicitamente fornecido:** por exemplo, as preferências do usuário podem ser obtidas quando são explicitamente comunicadas ao aplicativo solicitante.

Embora muitas informações de contexto estejam no sistema, as informações relacionadas à identidade, localização, atividade e tempo têm recebido mais atenção do que outras (LIU; LI; HUANG, 2011). Há duas abordagens diferentes para detectar informações de localização. A primeira abordagem é baseada no usuário, usando GPS, WiFi e Bluetooth. Algumas informações de identidade podem ser fornecidas diretamente ao sistema consciente do contexto, como por exemplo, o sexo do usuário. As informações de tempo são geralmente obtidas do relógio do sistema. Além disso, informações de contexto de alto nível, tais como a atividade atual do usuário, é um grande desafio. Uma abordagem para adquirir é a visão mecânica, que se baseia na tecnologia de câmera e processamento de imagem. Outra abordagem possível é consultar a agenda do usuário diretamente para descobrir o que o usuário deve fazer em um determinado momento. Uma terceira abordagem é usar técnicas de inteligência artificial para reconhecer contextos complexos, combinando vários sensores simples de baixo nível (LIU; LI; HUANG, 2011).

## 2.2 Experiência do usuário (*UX - User Experience*)

A literatura apresenta várias definições para UX e há várias razões pelas quais é difícil conseguir uma definição de UX. De acordo com Law et al. (2009), a UX está associado a uma ampla gama de conceitos difusos e dinâmicos, inclusive emocionais, afetiva, experiencial, hedônica e estética. Inclusão e exclusão de particulares variáveis parecem arbitrarias, dependendo do autor histórico e interesse. Em segundo lugar, a unidade de análise para UX é muito maleável, variando de um único aspecto de uma interação individual do usuário final com um usuário autônomo aplicação a todos os aspectos das interações de múltiplos usuários finais com a empresa e sua fusão de serviços de múltiplas disciplinas. Terceiro, a paisagem da pesquisa UX é fragmentada e complicada por diversos modelos teóricos com diferentes focos como o pragmatismo, a emoção, o afeto, experiência, valor, prazer, beleza, qualidade hedonística, entre outros (LAW et al., 2009).

De acordo com ISO-9241-210 (2010), UX é definida como sendo as percepções e respostas do usuário (emoções, crenças, preferências, percepções, conforto, entre outras), resultantes do uso de um sistema, produto ou serviço, de modo que, essas percepções e respostas possam ocorrer antes, durante ou após o uso. O estado interno e físico do

usuário também interfere na experiência de uso, tais como o contexto de uso, experiências anteriores, atitudes, habilidades e personalidade (ISO-9241-210, 2010).

Segundo Law et al. (2009), o UX resulta da ampla gama de benefícios potenciais que os usuários podem obter de um produto; e pode ser classificado como algo novo, que deve ser parte integrante do domínio da Interação Humano-Computador (IHC), apoiado pelas práticas de design centrado no usuário (LAW et al., 2009).

Conforme Garrett (2010), UX é a experiência criada a partir do uso de um produto. Quando um produto está sendo gerado, é preciso prestar muita atenção ao que ele faz. No entanto, a experiência do usuário é muitas vezes o lado negligenciado da equação de como algo funciona, o que pode ser a diferença entre um produto de sucesso e fracasso (GARRETT, 2010).

Para Norman e Nielsen (2021), a UX cobre todos os aspectos da interação do usuário final com a empresa, seus serviços e seus produtos. Os autores também citam, que para obter uma boa UX é necessário atender às necessidades do cliente sem causar confusão ou inconveniência, e também, ser simples para causar alegria nos usuários que possuem ou utilizam o produto ou serviço (NORMAN; NIELSEN, 2021). Em resumo, Norman e Nielsen (2021) apontam que a busca de um UX de alta qualidade, requer esforços multidisciplinares, tais como engenharia, marketing, design gráfico e industrial, e design de interface.

Enquanto que para o entendimento de Hassenzahl (2018), a UX é dividida em dois atributos: os pragmáticos que dizem respeito à usabilidade e funcionalidade do software; e os hedônicos, que dizem respeito à comunicação de identidade, provocando memórias e fornecendo estimulação. O autor também aponta que ao projetar e avaliar a UX, os profissionais devem prestar atenção aos diferentes episódios da experiência.

Law et al. (2009) realizaram uma pesquisa que reuniu as opiniões sobre UX de 275 pesquisadores e profissionais da academia e da indústria. A maioria dos entrevistados tendem a concordar com um conceito de UX como dinâmico, contexto-dependente e subjetivo, que deriva de um ampla gama de benefícios potenciais que os usuários podem derivar de um produto. UX é visto como algo novo, que deve ser um parte do domínio IHC e estar fundamentado nas práticas de Design Centrado no Usuário (DCU).

### 2.2.1 Dimensões da UX

Vários pesquisadores no domínio UX propuseram esquemas que ilustram a interação das dimensões que formam o UX. Entre eles estão Forlizzi e Ford (2000), Crilly, Moultrie e Clarkson (2004), Krippendorff (2005), Hekkert e Schifferstein (2008), Locher, Overbeeke e Wensveen (2009) e Hassenzahl (2018). Cada modelo olha para o UX de seu ponto de vista particular. Juntos, eles dão uma visão geral sobre a multiplicidade de dimensões que constituem o UX e que devem desempenhar um papel na concepção inicial do produto e na

avaliação do projeto do produto. Uma consolidação das várias dimensões foi apresentada no estudo de Bouchard e Bongard-Blanchy (2015).

As dimensões são organizadas e apresentadas sob as quatro categorias:

1. **Dimensões da Percepção Humana / o usuário:** Um usuário é uma pessoa que é alvo de utilização de um produto. Ele se aproxima do produto com um objetivo específico extrínseco - o que eu espero conscientemente deste produto? - e expectativas intrínsecas que foram formadas por experiências anteriores além de suas condições pessoais de vida (ROBERT; LESAGE, 2017). As dimensões que definem o perfil do usuário são a idade e o sexo da pessoa (CRILLY; MOULTRIE; CLARKSON, 2004), o contexto cultural, o ambiente de vida (LOCHER; OVERBEEKE; WENSVEEN, 2009), a educação, a ocupação e os interesses da pessoa.
2. **Dimensões dos produtos:** Um produto é um tipo específico de objeto ou interface ou serviço que serve a um determinado propósito e que pode ser classificado em um determinado setor, como automóvel, alimentos, cosméticos, entre outros (KRIPPENDORFF, 2005). Hassenzahl (2018) atribui quatro funções principais aos produtos: 1. Permitir que as pessoas manipulem seu ambiente, 2. Estimular o desenvolvimento pessoal, 3. Expressar identidade, e 4. Evocar memórias. Para isso, os produtos devem possuir certas propriedades que facilitem estas funções. As dimensões clássicas do Design de Produto são funcionalidades, semântica, forma, cor, material, textura, entre outros.
3. **Dimensões do contexto de uso:** Qualquer UX está embutido em uma situação de interação específica. O contexto de uso também influencia as propriedades que os sensores humanos ou de produto irão capturar. Além disso, ele pode influenciar o tratamento das informações de estímulo. As externalidades do contexto de uso que influenciam o UX são dimensões situacionais, culturais e sociais (CRILLY; MOULTRIE; CLARKSON, 2004; KRIPPENDORFF, 2005; LOCHER; OVERBEEKE; WENSVEEN, 2009).
4. **A dimensão temporal do UX:** O tempo é outra importante dimensão UX. Algumas experiências, como uma surpresa, só podem ser vividas uma vez, enquanto outras experiências crescem com vários episódios de uso. Hassenzahl (2010) exige uma "abordagem longitudinal" ao projetar para o UX. Ele distingue entre uma perspectiva micro (uma hora de uso), meso (algumas semanas de uso), e macro (anos de uso) sobre o UX com um produto. Roto et al. (2011) identificaram quatro tipos de UX ao longo do tempo: o UX antecipado (antes do uso), o UX momentâneo (durante o uso), o UX episódico (após o uso) e o UX cumulativo (situações de uso múltiplo ao longo do tempo) (ROTO et al., 2011). Do ponto de vista do Projeto do Produto, há

dois tipos diferentes de temporalidade que podem ser efetivamente moldados pelo projetista: A sequência de interação e certos aspectos do UX cumulativo.

Sequências de interações: Um produto que muda dinamicamente é concebido como um ciclo contínuo de sensoriamento e resposta no lado humano e no lado do produto. Tanto o humano quanto o artefato são capazes de detectar a entrada, processar estes dados e responder com comportamento distinto (ações de saída). Os dados circulam entre o usuário e o produto e são transformados (KRIPPENDORFF, 2005). As emoções sentidas pelo usuário mudam ao longo das diferentes sequências de interação (LIN; CHENG, 2011).

UX a longo prazo: Um produto interativo pode mostrar padrões de resposta recorrentes às ações do usuário, mas o usuário pode responder de forma diferente depois de um tempo. A surpresa só pode ser desencadeada uma vez. A excitação se transforma em conforto quando o usuário se familiariza com o produto. Mesmo quando o produto desaparece de sua visão, a memória dele ainda pode desencadear emoções (NORMAN, 2004). Karapanos et al. (2009) estudaram a experiência dos usuários de iPhone desde a intenção de compra, até depois de alguns meses de uso. Eles provaram uma mudança no UX ao longo do tempo. Durante a fase inicial de orientação, a experiência é formada principalmente por estímulo e capacidade de aprendizagem. Isto leva a uma certa familiaridade com o produto. Na fase de incorporação seguinte, a utilidade e a usabilidade a longo prazo são importantes. Aparece uma dependência funcional do usuário em relação ao produto. Finalmente, o usuário pode entrar na fase de identificação onde ele demonstra uma ligação emocional com o produto.

## 2.3 Sistemas de recomendação de música

Um sistema ideal de recomendação deve ajudar o usuário a filtrar e descobrir a música de acordo com seu gosto e objetivo (LAMERE, 2008). Ao contrário de outros sistemas que recomendam livros ou filmes, a música ocupa menos espaço e pode ser ouvida várias vezes em qualquer lugar e em várias ocasiões (SONG; DIXON; PEARCE, 2012). Muitas plataformas de reprodução de música (por exemplo, Spotify<sup>1</sup>, Last.fm<sup>2</sup>, Apple Music<sup>3</sup>, Deezer<sup>4</sup>) têm aumentado substancialmente a quantidade de usuários ativos nos últimos anos (LIFSON et al., 2023). O aumento dos usuários que utilizam plataformas de reprodução de música tem proporcionado cada vez mais novos estudos que levam em conta fatores que podem influenciar as escolhas ou preferências dos usuários. As abordagens

---

<sup>1</sup> <https://www.spotify.com/>

<sup>2</sup> <https://www.last.fm>

<sup>3</sup> <https://www.apple.com/apple-music/>

<sup>4</sup> <https://www.deezer.com/en/>

mais comuns utilizadas nestes estudos são: recuperação de informações sobre metadados, filtragem colaborativa e recuperação de informações baseadas em conteúdo.

### 2.3.1 Recuperação de informações sobre metadados

A recomendação musical baseada em metadados é o método mais simples e que proporciona o mecanismo mais fácil de busca de música, pois a recuperação de informações utiliza métodos textuais, ou seja, as informações fornecidas pelos criadores, tais como o título da música, nome do artista e letra da música (CASEY et al., 2008). Embora este método seja rápido, ele tem algumas limitações, por exemplo, os usuários precisam inserir muitos detalhes sobre uma música para que o mecanismo de busca possa sugerir músicas semelhantes. (SONG; DIXON; PEARCE, 2012).

### 2.3.2 Filtragem colaborativa

Sistemas de filtragem colaborativos sugerem a música mais apropriada com base no comportamento do usuário de um grupo de usuários (HILL et al., 1995). A ideia desta abordagem é que, quer um usuário  $X$  e  $Y$  classifiquem  $n$  itens de forma semelhante ou tenham comportamento semelhante, eles classificarão ou agirão sobre outros itens de forma semelhante (RESNICK; VARIAN, 1997). Neste método, em vez de calcular a semelhança a partir dos dados das músicas, são utilizadas informações de usuários com gostos semelhantes. O mecanismo de filtragem colaborativa apresenta um bom desempenho, porém, tem o problema do *cold-start*. O problema do *cold-start* é dividido em duas categorias: *cold-start* de itens e *cold-start* de usuários (CHEN; CHEN; WANG, 2015). O problema do *cold-start* acontece porque pouca informação é conhecida sobre este usuário ou porque o sistema tem um novo usuário. Na filtragem colaborativa, o problema do *cold-start* é causado quando há um novo usuário apresentado com poucas opiniões.

### 2.3.3 Recuperação de informações baseadas no conteúdo

Diferentemente da técnica de filtragem colaborativa, a abordagem baseada no conteúdo se concentra na análise do conteúdo dos itens musicais para fazer as sugestões aos usuários (LI et al., 2004). O objetivo do método é procurar músicas semelhantes àquelas que o usuário gostava. Para isso, o algoritmo analisa as características acústicas da música. Assim, com base nas características extraídas, o grau de semelhança entre cada música é calculado e recomenda as músicas com menor grau ou distância. Embora o modelo baseado no conteúdo possa resolver o problema do *cold-start*, o método baseado na similaridade não foi completamente investigado em termos da preferência dos ouvintes. No entanto, nenhuma pesquisa demonstrou que um comportamento semelhante leva à escolha da mesma música. (SONG; DIXON; PEARCE, 2012).

### 2.3.4 Recomendação de música considerando informações contextuais

Muitos dos métodos apresentados as seções anteriores fazem recomendações satisfatórias após um longo período de escuta. Entretanto, as preferências de escuta dos usuários são geralmente imediatas e podem ser fortemente influenciadas por uma série de diferentes fatores e características, por exemplo, fatores de contexto e emoções.

A recomendação musical baseada no contexto pode usar várias informações para melhorar uma sugestão musical, por exemplo, opiniões públicas, redes sociais, similaridade, mineração de dados, localização, tempo e até mesmo emoções (SONG; DIXON; PEARCE, 2012). Os sistemas de recomendação de música com reconhecimento de contexto dão aos amantes da música a liberdade de ouvir suas músicas favoritas em qualquer lugar, a qualquer momento, sem a necessidade de criar uma lista de reprodução ou categorizar músicas com base em algum critério (MAGARA et al., 2016).

Nos últimos anos, muitos estudos têm considerado informações contextuais ao fazer recomendações musicais (ABDUL et al., 2018; DIAS; FONSECA; CUNHA, 2014; WANG; WANG; CHOU, 2018; YOON; LEE; KIM, 2012; GILDA et al., 2017; JIN et al., 2019). Na revisão realizada por Juslin et al. (2008), os autores concluem que o contexto social da música é negligenciado na pesquisa, incluindo tudo, desde a situação em que a atividade musical ocorre até o contexto sócio-cultural mais amplo.

Diferentes classificações para informações contextuais foram propostas na literatura (ADOMAVICIUS; TUZHILIN, 2011; ABOWD et al., 1999). Para Adomavicius e Tuzhilin (2011), há três tipos de contextos em sistemas de recomendação: contexto completamente observável, contexto parcialmente observável, e contexto não observado. No contexto completamente observável, os fatores contextuais relevantes (ou informações) para a aplicação são explicitamente conhecidos quando a recomendação é feita. No contexto parcialmente observável, apenas algumas das informações sobre os fatores contextuais são conhecidas explicitamente. No contexto não observado, nenhuma informação sobre os fatores contextuais está explicitamente disponível para o sistema de recomendação. Para este tipo de contexto, as recomendações são geralmente feitas utilizando apenas o conhecimento implícito latente do contexto.

Diferentemente, Abowd et al. (1999) sugerem uma classificação que distingue entre os contextos primário e secundário. O contexto primário é definido pela localização, identidade, atividade e tempo do usuário, os quatro fatores mais importantes ao caracterizar a situação de um usuário. O contexto secundário é definido como informação adicional que deriva dos fatores do contexto primário. Por exemplo, o tempo atual deriva da localização e do tempo do usuário.

## 2.4 UX em sistemas de recomendação

Desde o surgimento dos sistemas de recomendação, muitos artigos foram publicados (BEEL et al., 2013; BEEL et al., 2016) que, em sua maioria, têm como objetivo criar algoritmos mais precisos. Para Garcia-Gathright et al. (2018), a boa experiência do usuário nos sistemas de recomendação exige considerações além da relevância dos itens e da precisão dos algoritmos.

Assim, pesquisas em sistemas de recomendação começaram a olhar além da precisão das recomendações e descobriram que outros fatores além da precisão têm influência na experiência do usuário (KNIJNENBURG et al., 2012). Estes fatores incluem outros aspectos do sistema, como diversidade de recomendações (BOLLEN et al., 2010; FERWERDA et al., 2016), mas também aspectos pessoais (por exemplo, conhecimento do produto e preferências prévias (BOLLEN et al., 2010; WILLEMSEN et al., 2011)) ou situacionais (por exemplo, humor e emoção (FERWERDA; SCHEDL; TKALCIC, 2015)), que começaram a receber atenção na criação de sistemas de recomendação.

De acordo com Ferwerda (2016), um problema que persiste é como capturar esses fatores em fluência ou como reunir dados comportamentais suficientes a fim de inferir as preferências dos usuários para uma experiência personalizada. Para os autores, a maneira simples de conhecer o usuário é deixá-lo preencher os questionários. No entanto, isto é muitas vezes indesejável, uma vez que é difícil, requer muito esforço e tempo do usuário, e assim interfere sua interação com o sistema.

A UX é dinâmica e muda nas diferentes circunstâncias pelos contextos e estados emocionais dos usuários, antes e depois de uma interação com um produto (VERMEEREN et al., 2010). Em pesquisas de recomendação de música um aspecto da experiência do usuário que têm atraído a atenção de muitos pesquisadores e se tornou a principal tendência para a descoberta e recomendação da música é a emoção (KIM et al., 2010). Identificar a emoção expressa pela música ou a emoção do usuário tem sido uma informação valiosa para os sistemas de recomendação musical, pois obter esse tipo de informação pode ajudar o usuário a recuperar uma música que melhor se adapte ao seu estado emocional atual (ASSUNÇÃO; NERIS, 2019).

## 2.5 Plataformas de *streaming* de música

Os serviços de *streaming* de música são aplicativos baseados na web que utilizam uma tecnologia de distribuição que permite que grandes quantidades de material digital sejam armazenadas na nuvem, ou seja, grandes centros de dados compostos de computadores em rede conectados à Internet (HAGEN, 2015).

Segundo Thomes (2013) os serviços de *streaming* de música representam a maior fonte de receita em potencial para a indústria da música e estão bem estabelecidos entre os

consumidores. O conceito subjacente aos serviços de *streaming* baseia-se em induzir os consumidores de música a ouvir música sobre demanda (THOMES, 2013). Segundo Panda et al. (2021), os primeiros serviços musicais atingiram o ponto mais baixo de receita musical no ano de 2014. Desde então, a receita da música subiu consecutivamente, liderada por serviços de *streaming* como Spotify, Deezer ou Pandora.

Atualmente, estes serviços oferecem acesso fácil a milhões de músicas com uma conveniência sem precedentes (por exemplo, Spotify com mais de 70 milhões de músicas em 3 de Agosto de 2021<sup>5</sup>). No entanto, uma quantidade tão grande de dados requer melhores mecanismos de busca e descoberta do que uma simples busca por artista, título ou gênero.

As plataformas de *streaming* tipicamente estabelecem sofisticados sistemas de recomendação, que oferecem recomendações personalizadas aos usuários. As recomendações personalizadas podem ser, por exemplo, baseadas no comportamento passado dos usuários (ou seja, compras ou consumo anteriores), bem como nas informações obtidas através de pesquisas ou *feedback* (gostos versus desgostos, ou classificações) (BOURREAU; GAUDIN, 2018).

Muitas plataforma de *streaming* de música possuem um modelo de negócios que oferece dois tipos de serviços. O primeiro é o serviço gratuito que é coberto de publicidades. O segundo serviço cobra dos usuários uma taxa fixa mensal e oferece benefícios adicionais, tais como acesso irrestrito ao catálogo, audição offline e aplicações para dispositivos móveis. A seguir, serão apresentadas 4 plataformas de transmissão de música, juntamente com as características específicas de cada uma.

### 2.5.1 Spotify

A Spotify foi fundada na Suécia em 2006 por Daniel Ek e Martin Lorentzon. É um serviço de música que foi lançado em 2008 e fornece serviços de streaming e podcast. O Spotify está disponível em 178 países. Usando o método de marketing freemium, Spotify oferece audição de música anunciada e paga (premium) e serviço de audição de música sem anúncios. Spotify pode ser facilmente utilizado em computadores, dispositivos móveis e outros dispositivos inteligentes graças a seu navegador e sua própria aplicação (SPOTIFY, 2021).

A página inicial (*Home*) do Spotify é o local onde oferece as principais recomendações da plataforma. A *Home* apresenta recomendações personalizadas, sensíveis ao contexto e explícitas através do algoritmo contextual bandith (MCINERNEY et al., 2018). A personalização é baseada em características contextuais que descrevem o que o sistema sabe sobre o usuário, seu contexto e o conteúdo de áudio. O desenvolvimento e iteração do modelo é orientado por uma avaliação em larga escala através de uma avaliação contrafactual offline usando dados de registro aleatórios e testes on-line A/B (MCINERNEY et al., 2018; GRUSON et al., 2019).

<sup>5</sup> <https://newsroom.spotify.com/company-info/>



## 2.5.2 Deezer

É um serviço francês de streaming de música online. O Deezer permite aos usuários ouvir música, bem como podcasts em vários dispositivos. Os usuários podem ouvir as músicas em modo online e offline. O Deezer tem atualmente 73 milhões de faixas licenciadas em sua biblioteca<sup>6</sup>, com mais de 30.000 canais de rádio, 16 milhões de usuários ativos mensais. Os usuários podem acessar ao Deezer nas plataformas Web, iOS, Android. O Deezer oferece opções de pacotes gratuitos e pagos. O Deezer segue seguindo o modelo de negócios freemium com 2 pacotes diferentes (DEEZER, 2021).

Assim como no Spotify, a página inicial do Deezer é o local onde apresenta as principais recomendações da plataforma. O Deezer oferece diversas recomendações de playlists separadas por categorias, por exemplo: artistas, gêneros musicais, playlists populares, mais tocadas, entre outras. O algoritmo de recomendação do Deezer tende a adaptar as recomendações ao gosto musical do usuário quando recebe avaliações nas faixas musicais, álbuns e artistas que o usuário gosta (SIMONE, 2021).

## 2.5.3 Apple Music

É um serviço de escuta de música desenvolvido pela Apple. Os usuários podem baixar as músicas que desejam escutar seus dispositivos e ouvir primeiro as listas de reprodução criadas. O serviço também inclui as estações de rádio da Internet Apple Music, Apple Music Hits, e Apple Music Country, que transmitem ao vivo para mais de 200 países 24 horas por dia. Novos assinantes podem testar a aplicação com um período experimental de 3 meses com 70 milhões de músicas. Em 2020, a Apple Music estava com mais de 72 milhões de assinantes<sup>7</sup>. Não há uso gratuito para música da Apple. Os usuários se beneficiam do serviço em troca da taxa de pacote que escolherem (APPLE, 2021).

A Apple Music possui um recurso chamado "Ouvir Agora" que, na primeira vez que é tocado, pede ao usuário que indique suas preferências. A Apple Music usa estas preferências ao recomendar músicas. Para que as sugestões da plataforma possam ser melhoradas, ela pede ao usuário que indique o que gosta ou não gosta, marcando-o como "Gostar" ou "Sugerir Menos Similares" (APPLE, 2021).

Ao criar uma conta na Apple Music, os usuários são solicitados a selecionar alguns de seus artistas favoritos para que o serviço possa ter uma noção de seus gostos. A interface apresenta vários círculos, com cada círculo representando um artista. Os usuários simplesmente selecionam em determinados círculos para indicar artistas que gostam.

Uma vez que o processo esteja concluído, a Apple Music recomenda *playlists* para atender as preferências dos usuários. As *playlists* podem ser baseadas no gênero, artista,

<sup>6</sup> <https://www.deezer.com/br/company/about>

<sup>7</sup> <https://www.businessofapps.com/data/apple-music-statistics/>

ou mesmo em uma atividade particular como dirigir. A Apple afirma que as listas de reprodução são criadas por uma "equipe de especialistas"(BIZZACO; LACOMA, 2021).

#### 2.5.4 Youtube Music

É um serviço de transmissão de música desenvolvido pelo YouTube. O aplicativo YouTube Music<sup>8</sup> foi revelado em outubro de 2015 e lançado no mês seguinte. Seu lançamento veio junto com a revelação do YouTube Red (YouTube Premium), um serviço de assinatura maior que cobre toda a plataforma do YouTube, incluindo o aplicativo Music. O serviço é executado em uma interface separada do YouTube. Este serviço, que oferece recursos como reprodução sem anúncios e reprodução de fundo para usuários assinantes, tem recursos limitados para usuários não assinantes e oferece reprodução suportada por anúncios. Além disso, o YouTube Music também segue o modelo de negócio *freemium* (YOUTUBE, 2021).

#### 2.5.5 Comparação de serviços de *streaming*

As plataformas apresentadas fornecem um grande catálogo, com centenas de músicas que podem ser acessadas a qualquer momento por dispositivo móvel ou computador. Em geral, as plataformas são muito semelhantes em termos do conteúdo fornecido aos seus ouvintes, mas ainda possuem algumas características próprias. A Tabela 1 apresenta uma comparação entre as plataformas.

Ao analisar a Tabela, pode-se observar que há pouca diferença entre as plataformas e que a maioria das características estão presentes em todas elas. A característica que mais varia dentre as plataformas é a taxa mensal, o período de teste, tamanho da biblioteca e as principais recomendações.

As 4 plataformas apresentadas possuem basicamente 2 recursos incomuns de interface, sendo: a biblioteca e a funcionalidade de exploração. A funcionalidade da biblioteca permite aos usuários criar suas *playlists*, assim como ver suas músicas por artistas, álbuns e gêneros musicais. O recurso de exploração, muitas das vezes é página inicial das plataformas. Ao acessar este recurso, o usuário pode navegar pela plataforma em busca de músicas por várias categorias, seja por gênero musical, eventuais contextos pré-definidos (na academia, no trabalho, dirigindo, e outros) e até mesmo por humor. Quando o recurso de exploração é a própria tela inicial da plataforma, todas as principais recomendações das plataformas são contidas nesta seção e geralmente é parte central das plataformas.

Em geral, as recomendações nesta seção são compostas de conjuntos de músicas e apresentadas na forma de álbuns e *playlists* prontas. Estes álbuns e *playlists* prontas são criados pelos algoritmos de recomendação de cada plataforma e normalmente os títulos variam de cada plataforma. Os títulos mais comuns são: "Tocadas recentemente", "O

<sup>8</sup> <https://www.youtube.com/musicpremium>

Tabela 1 – Comparação entre as plataformas comerciais de música

Funcionalidade	Spotify	Deezer	Apple Music	Youtube Music
Taxa mensal	R\$ 19,90	16,90	16,90	16,90
Opção gratuita	Sim, com anúncios	Sim, com anúncios	Não	Sim, com anúncios
Período de teste	60 dias	Não	3 meses	30 dias
Tamanho da biblioteca	+70 milhões	+73 milhões	+75 milhões	+50 milhões
Plano familiar	Sim (R\$ 34,90)	Sim (R\$ 26,90)	Sim (R\$ 24,90)	Sim (R\$ 31,90)
Desconto estudantil	Sim (R\$ 9,90)	Sim (R\$ 8,45)	Sim (R\$ 8,50)	Sim (R\$ 8,50)
Escuta offline	Celular e Desktop	Celular e Desktop	Apenas celular	Apenas premium
Serviços	Estações de rádio, podcasts, vídeos musicais, biblioteca, explorar	Estações de rádio, podcasts, biblioteca, explorar	Estações de rádio, podcasts, vídeos musicais, biblioteca, explorar	Estações de rádio, podcasts, vídeos musicais, biblioteca, explorar
Plataformas	Android, iOS, web e desktop	Android, iOS, web e desktop	Android, iOS, web e desktop	Android, iOS e web
Principais recomendações	Artistas, gêneros, álbuns, semelhantes, popularidade, personalizadas	Artistas, gêneros, álbuns, semelhantes, popularidade, destaques, playlists populares, lançamentos, categorias, personalizadas.	Lançamentos, gênero, popularidade, playlists populares, personalizadas	Lançamentos, gênero, artistas, álbuns, playlists prontas, álbuns, personalizadas

melhor de cada artista", "Álbuns populares", "Baseado no que você ouviu recentemente", entre outros.

## 2.6 Considerações finais

Após uma análise detalhada das diversas definições e dimensões de contexto e experiência do usuário, esta tese adota uma posição que considera o contexto como um conjunto de condições dinâmicas e variáveis que afetam a interação do usuário com sistemas de recomendação musical. Em particular, a definição de contexto utilizada aqui se alinha com a perspectiva de Abowd et al. (1999) e Dey (2001), na qual o contexto é compreendido como qualquer informação que possa ser usada para caracterizar a situação de uma entidade. A entidade, neste caso, é o usuário envolvido na interação com o sistema de recomendação musical, e a informação relevante inclui, mas não se limita a, localização, tempo, atividade e os elementos circundantes que podem influenciar essa interação. Além disso, adota-se a visão de Dourish (2004), que vê o contexto não como um conjunto estático de informações, mas como algo produzido e redefinido continuamente pelas atividades do usuário.

Na dimensão da experiência do usuário, esta pesquisa se baseia na definição proposta pela ISO 9241-210, considerando a UX como as respostas subjetivas, emoções e percepções resultantes do uso ou da antecipação do uso de um sistema, produto ou serviço. Além disso, a tese reconhece a importância da temporalidade na UX, conforme descrito por Roto et al. (2011), com foco nos aspectos antecipados, momentâneos, episódicos e cumulativos

da experiência. Essa abordagem multidimensional permite uma análise mais profunda e holística da interação do usuário com os sistemas de recomendação musical, enfatizando o papel da experiência evolutiva e contínua ao longo do tempo.

Portanto, ao construir a arquitetura UConteXt Arch e ao projetar as interações do usuário com o sistema MixFy, tanto as definições de contexto quanto de UX adotadas direcionam o desenvolvimento e a avaliação dos módulos da arquitetura. Este posicionamento teórico fundamenta a tese na criação de uma experiência de usuário personalizada e sensível ao contexto, que é essencial para os sistemas de recomendação musical.

---

## Capítulo 3

# Revisão Sistemática da Literatura

---

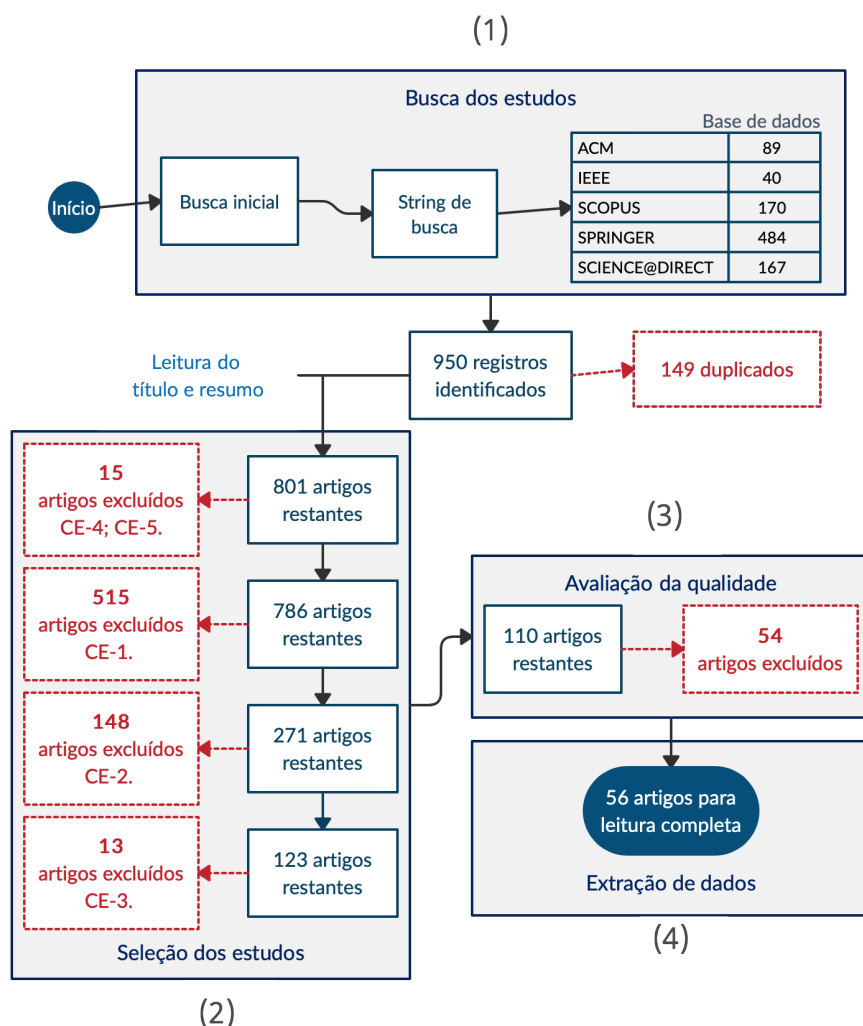
*O ciclo de relevância do Design Science Research é desenvolvido neste capítulo. Realiza-se uma revisão sistemática da literatura para responder às questões de pesquisa definidas, identificando lacunas significativas no campo dos sistemas de recomendação musical. A realização da revisão sistemática envolveu interações que analisou e sintetizou os dados para identificar os aspectos desejáveis para sistemas de recomendação musical que colaboraram para o desenvolvimento dos módulos da arquitetura UConteXt Arch.*

A Revisão Sistemática da Literatura (RSL) realizada neste projeto segue as diretrizes de Kitchenham et al. (2009). O objetivo da revisão foi descobrir as abordagens de recomendação musical que levam em conta a emoção e o contexto do usuário. O processo de revisão sistemática está claramente ilustrado na Figura 2. Quatro etapas, ou seja, busca de estudos, seleção de estudos, avaliação de qualidade e extração de dados. Na primeira etapa (1), Figura 2, uma busca inicial foi realizada para identificar a necessidade de RSL (Seção 3.1). Na sequência, as questões de pesquisa foram definidas (Seção 3.2), a string de busca (Seção 3.3) e a estratégia de busca (Seção 3.4). Na segunda etapa (2), Figura 2, os estudos foram selecionados utilizando os critérios de inclusão e exclusão (Seção 3.5). No terceiro passo (3), Figura 2, procedeu-se com a avaliação da qualidade (Seção 3.6). Finalmente, a extração de dados (Seção 3.7) ocorreu no passo quatro (4).

### 3.1 Identificação da necessidade de uma revisão

De acordo com Kitchenham et al. (2009), antes de conduzir um RSL, os autores devem investigar a demanda real pela RSL. Normalmente, a necessidade de uma revisão

Figura 2 – Visão geral do processo de revisão sistemática.



Fonte: Elaborado pelo autor

tem origem na necessidade de compreender o estado da arte na área ou de profissionais que queiram utilizar evidências empíricas em suas atividades estratégicas de tomada de decisão ou melhoria. Considerando esta diretriz, primeiro foi realizada uma busca ad-hoc de RSLs de acordo com o objetivo da revisão, ou seja, abordagens de recomendação musical que cobrem as emoções do usuário e o contexto de uso. A busca foi realizada na plataforma Google Scholar<sup>1</sup> com os seguintes termos de busca: “music recommendation systems: a systematic (“review” OR “mapping”)”. A busca foi filtrada para ordenar por relevância. Entretanto, a busca trouxe à tona outros estudos que diferem da revisão e do mapeamento, mas com objetivo de pesquisa associado a recomendações musicais que consideram emoções e informações contextuais. Como resultado, 15 publicações foram selecionadas e ajudou a compreender as principais características da literatura nesta

<sup>1</sup> <https://scholar.google.com>

área. Na Tabela 2, é apresentado uma visão geral dessas publicações, ou seja, autores e referência, objetivo e palavras-chave.

Tabela 2 – Publicações relacionadas.

Autor	Objetivo	Palavras-chave
Abdul et al. (2018)	Um sistema de recomendação musical personalizado e sensível à emoção (EPMRS) que extrai a correlação entre os dados do usuário e a música.	convolutional neural networks; latent features; machine learning; music; user preference; weighted feature extraction.
Chiu e Ko (2017)	Um sistema inteligente de seleção musical que ajuda as pessoas a identificar e selecionar música apropriada para melhorar seu desempenho de aprendizagem.	music recommendation; personalized music system; machine learning; heart rate variability (HRV); wearable device.
Deng e Leung (2012)	Uma recomendação musical personalizada baseada em emoções usando Campos Aleatórios Condicionais.	music emotion; music recommendation; conditional random fields, graph embedding, rank.
Dias, Fonseca e Cunha (2014)	Uma solução de recomendação musical personalizada para atividades diárias, cuja abordagem associa conteúdo musical (características acústicas) com atividades (contexto).	user-centered; music recommendation; content; context; retrieval.
Gilda et al. (2017)	Um tocador de música afetivo de plataforma cruzada, EMP, que recomenda música com base no humor em tempo real do usuário.	recommender systems; emotion recognition; music information retrieval.
Guo, Wu e Peteiro-Barral (2012)	Um novo sistema musical que utiliza o sinal de eletroencefalograma (EEG) como uma forma de melhorar a experiência musical do usuário em tempo real.	music therapy; music listening; music recommendation; recommendation engine; sequential floating forward selection.
Han et al. (2010)	Um novo modelo de transição de estados emocionais (ESTM) para modelar os estados emocionais humanos e suas transições pela música.	emotion state transition model; music information retrieval; mood; emotion; classification; recommendation.
Han et al. (2018)	Um sistema de recomendação de som de alarme inteligente e uma aplicação que estuda como os sons de alarme podem impactar as emoções humanas.	context-aware; smart alarm sound recommendation; emotion.
Hsu et al. (2018)	Um modelo baseado em evidências e personalizado para o reconhecimento das emoções musicais.	music emotion recognition; EEG; personalization; emotion trail; affective analysis.
Jin et al. (2019)	ContextPlay, a context-aware music recommender that enables user control for both contextual characteristics and music preferences.	context-aware recommendation; user control; music recommendation.
Mariappan, Suk e Prabhakaran (2012)	FaceFetch, um novo sistema de recomendação de conteúdo multimídia baseado em contexto que compreende o estado emocional atual de um usuário através do reconhecimento da expressão facial e recomenda conteúdo multimídia ao usuário.	emotion recognition; facial expression recognition; context-based content recommendation; computer vision.
Schedl (2013)	Um reproduzidor de música móvel inteligente que adapta automaticamente a lista de reprodução atual ao contexto do usuário.	user-centric music retrieval; mobile music player; adaptive playlist generation; hybrid music recommendation.
Yang e Teng (2015)	Um estudo quantitativo dos fatores pessoais, situacionais e musicais de preferência musical em um contexto de smartphone.	music information retrieval; music emotion recognition; context-aware music recommendation; smartphone.
Wang, Wang e Chou (2018)	Uma abordagem integrada para melhorar a previsão da preferência de um usuário que incorpora fatores de contexto e emoção.	music recommendation; context; emotion; service-oriented architecture.
Yoon, Lee e Kim (2012)	Um sistema personalizado de recomendação musical que utiliza recursos selecionados, informações de contexto e histórico de audição.	using emotion triggering low-level features; low-level feature selection; emotion triggering low-level feature; personalized music recommendation system.

Fonte: Elaborado pelo autor.

Esta análise preliminar apontou que há poucas investigações sobre abordagens de recomendação musical que lidam com a emoção do usuário e o contexto de uso em conjunto. Normalmente, as propostas consideram apenas as emoções ou apenas o contexto do usuário para executar a recomendação, e a emoção é muitas vezes tomada como um

fator de contexto. Além disso, esta análise indicou que o objetivo do RSL era viável e poderia apresentar contribuições importantes para o estado da arte. Além da busca das abordagens, também foram identificadas limitações na pesquisa das abordagens de recomendações musicais considerando as emoções ou os fatores de contexto.

## 3.2 Questões de pesquisa

O primeiro passo no planejamento do RSL é a definição das questões de pesquisa, já que todo o processo de revisão se baseia nos objetivos das questões. O método de definição das questões de pesquisa ocorreu diante das lacunas descobertas pela pesquisa inicial apresentada na subseção 3.1. Com base na primeira exploração da literatura, as seguintes questões de pesquisa foram definidas:

**RQ-1:** Que abordagens são usadas para a recomendação musical?

**RQ-1.1:** Que abordagens são usadas para recomendar música considerando o contexto?

**RQ-1.2:** Que abordagens são usadas para recomendar música considerando as emoções?

**RQ-1.3:** Que abordagens são usadas para recomendar música considerando as emoções e o contexto ao mesmo tempo?

**RQ-2:** Que aspectos são desejáveis a serem tratados nos sistemas de recomendação musical?

As questões de pesquisa foram desenvolvidas para fornecer uma visão geral deste estudo, fornecendo orientação e estabelecendo limites. A **RQ-1** e suas auxiliares foram desenvolvidas para revelar quais abordagens os autores devem utilizar para realizar o processo de recomendação musical, de modo que a emoção e o contexto sejam significativos para este processo. A **RQ-1** e suas sub-questões ajuda a descobrir quais abordagens são utilizadas no processo de recomendação musical, onde a emoção e o contexto de uso são aspectos significativos. A **RQ-1.1** especifica que as abordagens consideram apenas a emoção e podem ser relacionadas ao usuário ou à música. Ao contrário da **RQ-1.1**, a **RQ-1.2** especifica que as abordagens consideram apenas o contexto do usuário ou o contexto da música. Após o estudo inicial, uma escassez de estudos considerando simultaneamente abordagens emocionais e contextuais foi observada, portanto, a **RQ-1.3** foi definida para cobrir esta lacuna. Finalmente, a **RQ-2** foi definida para fornecer uma visão sobre quais aspectos são significativos para melhorar as abordagens de recomendação musical.



Tabela 3 – Frequência de palavras-chave por termo único

Palavras	Ocorrências
music	21
recommendation	14
emotion	12
context	6
recognition	5
retrieval	5
user	4
low	3
level	3
feature	3
aware	3
information	3

Fonte: Elaborado pelo autor.

Tabela 4 – Frequência de palavras-chave por termo composto

Palavras	Ocorrências
music recommendation	9
emotion recognition	4
context-aware	3
music information retrieval	3

Fonte: Elaborado pelo autor.

### 3.3 Definição da string de busca

A base da string de busca veio das 15 publicações que surgiram na primeira análise da literatura (veja a Tabela 2). As palavras-chave das publicações foram usadas para iniciar o processo de construção da string de busca.

Considerando que as palavras-chave na tabela 2 cobrem diferentes aspectos do objetivo da revisão, decidiu-se criar a string de busca a partir das palavras-chave mais relevantes nas publicações. A frequência das palavras-chave foram verificadas utilizando a plataforma Write Word<sup>2</sup>. A plataforma Write Word tem um contador de frequência de palavras que permite contar a frequência de uso de cada palavra em um texto. Com isso, as incidências por uma única palavra (termo único) e por palavras compostas (termos compostos) puderam ser contadas. A Tabela 3 mostra o número de ocorrências para uma única palavra e a Tabela 4, o número de termos compostos. Apenas palavras com pelo menos três ocorrências foram consideradas para a construção da string de busca.

No passo seguinte, identificou que os termos “music” “recommendation” foram as palavras com o maior número de ocorrências e que formaram o termo composto com mais frequência. Portanto, o termo “music recommendation” foi o único definido e os demais descartados. Também foi definidos termos “emotion” e “context”, pois eles estão diretamente ligados ao objetivo do RSL. Outros termos foram considerados opcionais para a busca, sendo: “recognition”, “retrieval” e “user”. Os termos “aware”, “low”, “level”, “feature” e “information” foram descartados por fazerem parte dos termos compostos descartados ou por estarem presentes em apenas um trabalho. Depois de escolher os termos mais relevantes, três testes foram realizados para definir a string de busca.

<sup>2</sup> <http://www.writewords.org.uk/>

Tabela 5 – Lista de string de busca testadas em todos os repositórios.

#	Strings de busca	Publicações
1	("music recommendation") AND (context AND emotion) OR ("recognition" OR "retrieval" OR "user")	1.612.790
2	("music recommendation") AND (context OR emotion OR recognition OR retrieval OR user)	1.759
3	("music recommendation") AND (context OR emotion) AND ("recognition" OR "retrieval" OR "user")	1.119

Fonte: Elaborado pelo autor.

Para apoiar a pesquisa, foi definido repositórios científicos com um amplo escopo e boa reputação na área de computação. Estes repositórios foram definidos por Buchinger, Cavalcanti e Hounsell (2014), sendo: ACM Digital Library<sup>3</sup>, IEEE Explorer<sup>4</sup>, Scopus<sup>5</sup> e Science@Direct<sup>6</sup>. Além desses repositórios, o repositório científico Springer<sup>7</sup> foi acrescentado .

Todas as versões da cadeia de busca estão descritas na Tabela 5. Cada versão da string de busca foi executada nos repositórios científicos e os resultados analisados quanto ao número de publicações retornadas. A primeira versão da string foi muito genérica e retornou 1.612.790 porque não filtrava corretamente as contribuições pesquisadas. O melhor resultado foi obtido com a terceira string de busca retornando 950 publicações. A formulação da última string seguiu um padrão de três grupos ligados pelo operador AND. O primeiro grupo permite focalizar os estudos na área de recomendação musical. O segundo grupo faz um refinamento permitindo que somente estudos que abordem a emoção ou o contexto sejam envolvidos. Finalmente, a inclusão do terceiro grupo faz com que os resultados abordem como recuperar ou reconhecer tanto o contexto quanto a emoção.

### 3.4 Estratégia de busca

A definição do período é crucial para a estratégia de busca. Para obter respostas concisas e confiáveis às perguntas, o período de busca definido foi entre 2010 e 2019. A partir de 2010, houve um aumento exponencial de smartphones, tablets e várias aplicações personalizadas para estes dispositivos (MRÓZ, 2016). Este avanço tem permitido que mais e mais aplicações musicais surjam ao longo dos anos.

<sup>3</sup> <https://dl.acm.org/>

<sup>4</sup> <https://ieeexplore.ieee.org/>

<sup>5</sup> <https://www.scopus.com/>

<sup>6</sup> <https://www.sciencedirect.com/>

<sup>7</sup> <https://link.springer.com/>

Tabela 6 – Critérios de inclusão.

Critério	Descrição
<b>CI-1</b>	O trabalho está relacionado à recomendação musical
<b>CI-2</b>	O trabalho apresenta uma abordagem de recomendação musical que considera o contexto ou as emoções
<b>CI-3</b>	O trabalho é um estudo primário
<b>CI-4</b>	O trabalho foi publicado em um periódico ou conferência científica

Fonte: Elaborado pelo autor.

Tabela 7 – Critérios de Exclusão.

Critério	Descrição
<b>CE-1</b>	O objetivo do trabalho não está relacionado com a recomendação musical
<b>CE-2</b>	O trabalho não propõe uma abordagem de recomendação musical baseada na emoção ou no contexto
<b>CE-3</b>	O objetivo do trabalho é propor um novo modelo de predição de emoções ligado ao usuário ou à música
<b>CE-4</b>	O trabalho tem três páginas ou menos
<b>CE-5</b>	O trabalho não está escrito em inglês

Fonte: Elaborado pelo autor.

A busca foi realizada entre 13 e 17 de janeiro de 2020, na qual a string de busca foi aplicada em todos os repositórios. No total, a busca retornou 950. Os resultados da busca foram exportados para a plataforma Parisif<sup>8</sup>, que identificou automaticamente 149 publicações duplicadas. Todos os resultados foram baixados manualmente para análise.

### 3.5 Seleção dos estudos

Para reforçar a validade da revisão, os estudos relevantes foram identificados com base nos critérios de inclusão e exclusão (veja a Tabela 6 e 7 respectivamente). Os critérios de inclusão e exclusão foram elaborados considerando a questão de pesquisa (veja a Seção 3.2).

Os critérios de seleção foram testados individualmente para cada trabalho. A etapa (2), mostrado na Figura 2, apresenta um fluxograma que detalha o processo de seleção dos estudos. O procedimento de análise foi dividido em quatro etapas. No primeiro passo, os critérios de exclusão **CE-4** e **CE-5** foram aplicados para reduzir o número de publicações a serem lidas. Na segunda etapa, 515 publicações foram excluídas pelo critério **CE-1**, porque são estudos que não incluem a recomendação musical. Em seguida,

<sup>8</sup> <https://parsif.al/>

na terceira etapa, 148 publicações foram excluídas pelo critério **CE-2** porque a abordagem de recomendação não considera a emoção ou o contexto. Finalmente, o critério CE-3 foi aplicado, excluindo 13 outras publicações. No total, 110 publicações foram selecionados de acordo com o critério de inclusão para a próxima etapa. A Tabela 8 mostra uma visão geral das publicações aceitas por cada repositório científico.

Tabela 8 – Publicações aceitas e rejeitadas em cada repositório científico.

	ACM	IEEE	Scopus	Springer	ScienceDirect	<b>Total</b>
	89	40	170	484	167	<b>950</b>
Duplicados	3	5	101	38	2	<b>149</b>
Rejeitados	41	16	39	433	162	<b>691</b>
Aceitos	45	19	30	13	3	<b>110</b>

Fonte: Elaborado pelo autor.

### 3.6 Lista de verificação de avaliação de qualidade

Para determinar o rigor metodológico e a qualidade dos estudos primários, um conjunto de questões de qualidade foram elaborados, veja a Tabela 9. No total, 10 questões de qualidade foram criadas, sendo 8 questões a partir do objetivo desta revisão e 2 sugeridas por (KITCHENHAM et al., 2009) (**Q1** e **Q10**). O objetivo das questões era considerar a importância dos estudos individuais selecionados quando os resultados estavam sendo sintetizados. As respostas às perguntas foram classificadas como 1 (sim), 0 (não) e 0,5 (parcialmente). Um estudo poderia ter uma pontuação máxima de 10 e uma pontuação mínima de 0.

Ao aplicar os critérios de inclusão e exclusão, as 110 publicações foram avaliadas individualmente quanto a questões de qualidade e receberam pontuações entre 0 e 10. Assim como o estudo de Sagar e Saha (2017), o intervalo de pontuação: baixa, média e alta foi adotado, mas com as seguintes faixas: baixo ( $0.0 \leq \text{pontos} \leq 3.0$ ), médio ( $3.5 \leq \text{pontos} \leq 5.0$ ) e alto ( $5.5 \leq \text{pontos} \leq 10.0$ ). Para esta revisão, apenas estudos na faixa alta foram considerados ( $5.5 \leq \text{pontos} \leq 10.0$ ). Assim, 56 publicações foram considerados para leitura completa e extração de dados. A Tabela 10 mostra as cinco publicações com a pontuação mais alta. A lista completa das 110 publicações avaliadas e a pontuação atribuída a cada trabalho estão em um apêndice<sup>9</sup> externo.

### 3.7 Extração de dados

Após executar a lista de verificação da avaliação de qualidade, a fase de extração de dados foi iniciada. A Tabela 11 mostra o formulário de extração de dados usado

<sup>9</sup> Apêndice - <<https://appendix.herokuapp.com/>>

Tabela 9 – Questões de qualidade

Questão	Descrição
<b>Q1</b>	Os objetivos da pesquisa estão claramente especificados?
<b>Q2</b>	O processo de recuperação emocional do usuário é adequadamente detalhado?
<b>Q3</b>	O processo de recuperação emocional da música é adequadamente detalhado?
<b>Q4</b>	O processo de identificação do contexto do usuário é devidamente detalhado?
<b>Q5</b>	O processo de identificação do contexto da música é adequadamente detalhado?
<b>Q6</b>	A emoção e o contexto do usuário são considerados em conjunto?
<b>Q7</b>	O processo de recomendação musical é devidamente detalhado?
<b>Q8</b>	A recomendação musical é abordada usando um dispositivo móvel?
<b>Q9</b>	A avaliação com usuários reais é devidamente detalhada?
<b>Q10</b>	Os métodos de coleta de dados são adequadamente detalhados?

Fonte: Elaborado pelo autor.

Tabela 10 – Lista de publicações avaliadas.

Publicações	Pontuação
Mood-Based On-Car Music Recommendations	<b>9.5</b>
Ameliorating Music Recommendation: Integrating Music Content, Music Context, and User Context for Improved Music Retrieval and Recommendation	<b>9.5</b>
SAfeDJ: A Crowd-Cloud Codesign Approach to Situation-Aware Music Delivery for Drivers	<b>9.0</b>
From sensors to songs: A learning-free novel music recommendation system using contextual sensor data	<b>8.5</b>
Quantitative Study of Music Listening Behavior in a Smartphone Context	<b>8.5</b>

Fonte: Elaborado pelo autor.

Tabela 11 – Conjunto de perguntas do formulário de extração de dados.

Questões	Descrições
Q1	Qual é o objetivo do trabalho?
Q2	Como a emoção do usuário é recuperada?
Q3	Como a emoção da música é recuperada?
Q4	Qual é o modelo de classificação das emoções utilizado?
Q5	Como é recuperado o contexto (usuário e música)?
Q6	Como é o processo de recomendação musical?
Q7	A recomendação considera a emoção e o contexto do usuário juntos?
Q8	O trabalho mostra evidências para o uso de sensores? Quais sensores?
Q9	O trabalho explora a recomendação em um ambiente móvel? (Sim/Não)
Q10	Como foi feita a avaliação e quais métodos foram utilizados?
Q11	O trabalho mostra evidência de uma avaliação com os usuários? Quantos?
Q12	Quais são os aspectos relevantes da publicação?
Q13	Quais são as limitações ou evidências para o trabalho futuro?
Q14	Qual é a conclusão da publicação?

Fonte: Elaborado pelo autor.


para registrar informações detalhadas para cada estudo. Para cada estudo selecionado, o formulário de extração de dados foi preenchido para que as perguntas pudessem ser respondidas e satisfeitas. Esta etapa visava registrar as informações relevantes para cada estudo. Para isso, a ferramenta digital Parisif<sup>10</sup> foi usada para extração de dados. A ferramenta permitiu criar um formulário com perguntas definidas e salvar os dados extraídos em documentos do Microsoft Excel.

### 3.8 Resultados

Nesta seção, são apresentadas as respostas às perguntas de pesquisa sobre as abordagens adotadas nos sistemas de recomendação (**RQ-1**) e os aspectos desejáveis (**RQ-2**). A Figura 3 mostra a distribuição dos 56 estudos primários por ano selecionados para responder às questões de pesquisa. Cada linha permite a visualização do número de publicações por ano, considerando os tópicos da RSL, conforme descrito a seguir: (a) a linha verde refere-se a trabalhos com abordagens de recomendação musical focalizados apenas no contexto; (b) a linha cinza refere-se apenas às emoções; (c) a linha amarela são publicações que abordam a emoção e o contexto juntos; e a linha azul indica a distribuição total de publicações ao longo dos anos.

<sup>10</sup> <https://parsif.al/>

Figura 3 – Publicações por ano versus tópicos.



Fonte: Elaborado pelo autor

Olhando para a linha do total de publicações, apenas 4 publicações foram identificadas antes de 2012. A partir de 2012, houve um aumento considerável e quase constante das publicações que cobrem a recomendação musical. Nos anos 2011 e 2015, o processo de seleção desta revisão não qualificou nenhuma publicação com ênfase no contexto. Da mesma forma, nos anos 2010 e 2013 para publicações com ênfase nas emoções e 2014 para publicações com ênfase no contexto e nas emoções. Observa-se também que o número de publicações aumentou em 2013 (linha azul), assim como o número de publicações que abordaram os tópicos de emoção e contexto juntos (linha amarela).

Para explorar as publicações que respondem às perguntas da pesquisa, o termo **abordagens** foi definido como todas as metodologias, técnicas, diretrizes, estruturas, práticas ou processos utilizados pelos autores durante a proposta da recomendação musical que considera as emoções e o contexto.

Os diferentes tipos de abordagens encontradas na literatura estão resumidos na Tabela 12 com as siglas e descrições. Estas siglas serão usados para se referir às abordagens adotadas pelos estudos encontrados na revisão. Por exemplo, a sigla **UH** refere-se a trabalhos que utilizam técnicas ou métodos associados à recuperação do histórico do usuário ao recomendar música para o usuário. Este tipo de recurso geralmente pode ser usado em abordagens de recomendação musical, enfatizando o contexto ou a emoção. As seguintes Subseções apresentam as respostas às questões de pesquisa definidas e apresentadas na Seção 3.2.

### 3.8.1 RQ-1: Que abordagens são usadas para a recomendação musical?

Até o momento, a percepção humana da música ainda não é totalmente compreendida (LEVITIN; TIROVOLAS, 2009; CAMERON et al., 2017; DALY et al., 2020). Portanto,

Tabela 12 – Lista de abordagens.

Siglas	Abordagens
CCI	Informações de contexto comum ( <i>Common Context Information</i> )
CF	Filtragem colaborativa ( <i>Collaborative filtering</i> )
DIM	Modelo dimensional de emoção ( <i>Dimensional Emotion Model</i> )
DISC	Modelo de emoção discreta ( <i>Discrete Emotion Model</i> )
FE	Expressão facial ( <i>Facial Expression</i> )
FEED	Feedback
MC	Contexto musical ( <i>Music Context</i> )
MD	Dados musicais ( <i>Musical Data</i> )
MDI	Informações sobre dispositivos móveis ( <i>Mobile Device Information</i> )
ML	Aprendizado de máquina ( <i>Machine Learning</i> )
MP	Preferências musicais ( <i>Musical Preferences</i> )
ON	Ontologias ( <i>Ontology</i> )
SEN	Sensores ( <i>Sensors</i> )
SI	Informações subjetivas ( <i>Subjective Information</i> )
SIM	Similaridade ( <i>Similarity</i> )
SN	Redes sociais ( <i>Social Networks</i> )
UA	Atividade do usuário ( <i>User Activity</i> )
UB	Comportamento do usuário ( <i>User Behavior</i> )
UH	Histórico do usuário ( <i>User History</i> )

Fonte: Elaborado pelo autor.

não há consenso sobre a melhor abordagem para fornecer recomendações musicais. Na literatura, ela tem sido influenciada por vários fatores, tais como idade, sexo, traços de personalidade, origem sócio-econômica, cultural e muitos outros fatores. Para melhorar o desempenho deste sistema, foram encontradas diferentes abordagens. Nesta revisão, o foco é o contexto e a emoção dos usuários, como refletido na **RQ-1**

Os estudos e abordagens que respondem a **RQ-1** estão descritos na Tabela 13, juntamente com a ênfase do trabalho, da plataforma móvel, sigla e abordagens adotadas.

Tabela 13 – Publicações selecionadas.

ID	Autores	Abordagens relacionadas	Foco	Móvel
1	Volokhin e Agichtein (2018)	AU		X
2	Bauer, Jellenek e Kientz (2018)	AM		X
3	Lee et al. (2017)	AU, AM, FC		X
4	Jiang e He (2016)	AM, MUS, IFEED		X
5	Magara et al. (2016)	CCC, PMU, HU, DM		X
6	Jenkins e Yang (2016)	RS, HU, IFEED		X
7	Schedl, Breitschopf e Ionescu (2014)	IFFED, MUS, CM		X



Tabela 13 continuada da página anterior

ID	Autores	Abordagens relacionadas	Foco	Móvel
8	Lee e Cho (2014)	CCC		X
9	Cheng e Shen (2014)	HU,CCC		X
10	Helmholz, Vetter e Robra-Bissantz (2014)	SEN, CCC,		X
11	Hong et al. (2014)	HU, CCC, IFEED		X
12	Teng, Kuo e Yang (2013)	DM, AU, CCC, AM, FC		X
13	Okada et al. (2013)	AM, COMP, MUS		X
14	Karlsson, Okada e Noletto (2012)	HU, DM		X
15	Nirjon et al. (2012)	SEN, AU, DM		X
16	Wang, Rosenblum e Wang (2012)	DM, AU, MUS, AM		X
17	Miller et al. (2010)	CCC, MUS		X
18	Chang et al. (2019)	MUS, AM		-
19	Dias, Fonseca e Cunha (2014)	AU, MUS		-
20	Assunção e Neris (2019)	MD, ISBJ, MUS		X
21	Kang e Seo (2019)	MD, DM, CCC		X
22	Abdul et al. (2018)	CL, ISBJ, SM, AM		X
23	Chiu e Ko (2017)	CL, SEN, AM, ISBJ		X
24	Iyer et al. (2017)	SEN, EF		X
25	Rosa, Rodriguez e Bressan (2015)	MD, RS		X
26	Guo, Wu e Peteiro-Barral (2012)	SEN, SM		X
27	Lehtiniemi e Holm (2012)	MD, ISBJ		X
28	Andjelkovic, Parra e O'Donovan (2019)	MD, MUS,SM		-
29	Lopes et al. (2018)	CL, AM		-
30	Li e Liu (2017)	COMP, PMU		-
31	Padovani, Ferreira e Lelis (2017)	CL, ISBJ, AM		-
32	Gilda et al. (2017)	CL, EF, MUS AM		-
33	Vateekul et al. (2015)	MD, FC, SM		-
34	Narducci, Gemmis e Lops (2015)	CL, RS		-
35	Deng et al. (2015)	MD, HU, AM		-
36	Ferwerda e Schedl (2014)	CL, RS, MUS		-
37	Le et al. (2011)	MD, SEN, IFEED		-
38	Jin et al. (2019)	ISBJ, PMU, CCC		X
39	Kasinathan et al. (2019)	AU, PMU		X
40	Çano et al. (2016)	CL, MD, SEN, PMU, CCC		X
41	Hu et al. (2015)	SEN, MUS, AM		X
42	Sen e Larson (2015)	MD, DM, CCC, CM		X
43	Yang e Teng (2015)	MD, ISBJ, DM, AU, PMU		X
44	Schedl (2013)	IFEED, CCC, MUS		X
45	Wohlfahrt-Laymanna e Heimburgerh (2017)	MD, MUS, SM		-
46	Giri e Harjoko (2016)	CL, CCC, AM,	Contexto	-
47	Yang et al. (2016)	CCC, HU, PMU	e	-
48	Braunhofer, Kaminskas e Ricci (2013)	CCC, MUS, SM,	Emoção	-
49	Rho et al. (2013)	CL, MUS, ON		-
50	Kaminskas, Ricci e Schedl (2013)	CCC, MUS, SM,		-
51	Chen et al. (2013b)	MD, MUS, FC, AM		-
52	Chen et al. (2013a)	SM, AM		-

**Tabela 13 continuada da página anterior**

ID	Autores	Abordagens relacionadas	Foco	Móvel
53	Yoon, Lee e Kim (2012)	MD, ISBJ, HU		-
54	Kaminskas e Ricci (2011)	CL, CM, CCC		-
55	Han et al. (2010)	CL, MUS, ON		-
56	Wang, Wang e Chou (2018)	MD, IFEEED, MUS, FC		-

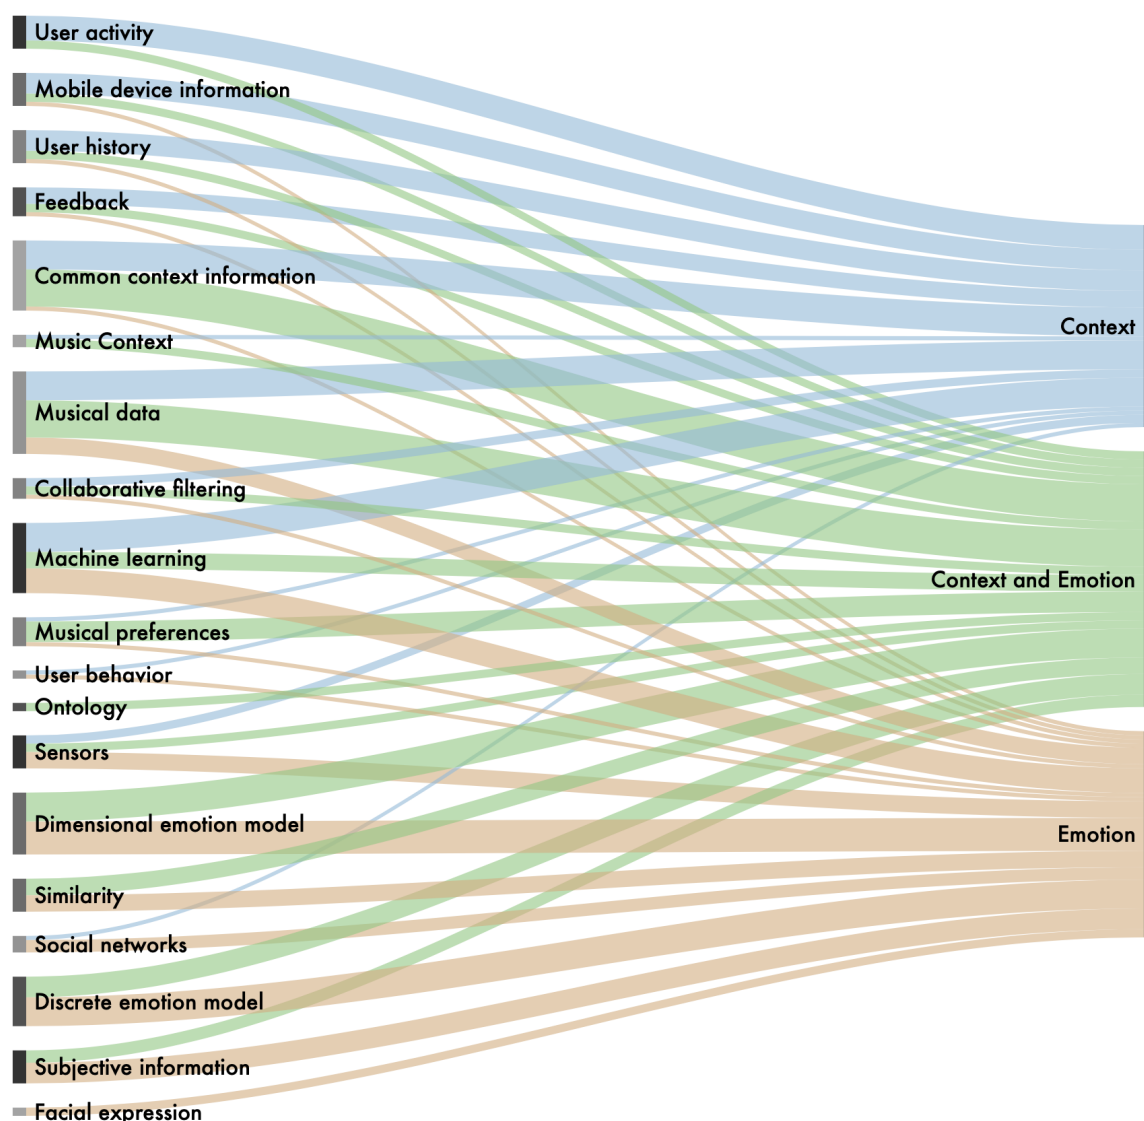
Após resumir as abordagens de cada publicação, percebeu-se que muitas dessas abordagens tinham uma forte relação com informações contextuais ou emoções. Dada esta relação, o diagrama Sankey da Figura 4 é apresentado. Tradicionalmente, os diagramas Sankey ilustram informações quantitativas sobre fluxos, relacionamentos e transformação (RIEHMANN; HANFLER; FROEHLICH, 2005). O diagrama Sankey mostrado na Figura 4 mostra a relação entre as abordagens mencionadas anteriormente, com ênfase na recomendação musical. O diagrama mostra as abordagens mais utilizadas para cada escopo de recomendação musical, além de identificar o nível de presença de cada abordagem em um dos escopos de acordo com o tamanho de cada linha.

Ao analisar o diagrama Sankey, especificamente as abordagens do contexto, nota-se que o contexto é mais explorado por técnicas que utilizam informações contextuais padrão (por exemplo, localização, tempo, clima), histórico, atividade do usuário, aprendizagem de máquina, entre outras informações relacionadas à música (metadados e interação). Por outro lado, ainda no diagrama, observa-se que o contexto do usuário ainda é pouco explorado, envolvendo as seguintes abordagens: contexto musical, preferências musicais, redes sociais, comportamento do usuário, e até mesmo o uso de sensores.

Embora muitas dessas abordagens ainda sejam pouco exploradas, muitas são consideradas fontes de dados essenciais para recuperar o contexto do usuário. Um exemplo disso são as redes sociais com um fluxo intenso de interação do usuário. Na maioria das vezes, os usuários permanecem lá, fazendo várias postagens mostrando seus sentimentos e rotinas diárias (JENKINS; YANG, 2016; NARDUCCI; GEMMIS; LOPS, 2015; FERWERDA; SCHEDL, 2014). Suponhamos que os pesquisadores percebam a importância de combinar várias abordagens contextuais. Nesse caso, em breve sistemas de recomendação musical cada vez mais inteligentes poderão ser vistos. Um exemplo sugestivo disto seria um sistema capaz de identificar o contexto musical relacionado ao comportamento do usuário. Sensores móveis ou redes sociais poderiam identificar o comportamento do usuário.

Por outro lado, ao analisar as abordagens de recomendação musical que consideram a emoção, observa-se no diagrama de Sankey que muitos dos estudos que consideram a emoção exploram intensamente abordagens que utilizam a expressão facial para obter a emoção, assim como informações subjetivas dos usuários, redes sociais, sensores, similaridade, informações musicais e aprendizagem de máquinas. Além disso, a maioria dos estudos adota modelos que descrevem as emoções de forma contínua e discreta. Por outro

Figura 4 – Correlação entre as abordagens de recomendação musical.



Fonte: Elaborado pelo autor

lado, é perceptível que os estudos dificilmente envolvem abordagens tais como atividade e histórico do usuário, *feedback*, comportamento e preferências do usuário.

A música é a atividade de lazer mais executada pelas pessoas (RENTFROW; GOSLING, 2003). Isto se deve à significativa proliferação de plataformas de transmissão de música que permitem aos consumidores ouvir música em qualquer lugar e a qualquer hora. Os usuários destes sistemas passam grande parte de seu tempo interagindo com estas plataformas e consumindo música. Cada interação com estas plataformas resulta em uma grande quantidade de dados que podem melhorar as novas recomendações que consideram as emoções. A recomendação musical pode ser melhorada utilizando as abordagens pouco exploradas nesta revisão. Por exemplo, suponha que os sistemas de recomendação pudessem combinar várias abordagens que considerem as emoções. Nesse caso, o usuário poderia aproximar de um estado emocional desejado com base apenas em suas preferências

musicais, comportamento, atividade, histórico e *feedback*.

Por fim, prosseguindo com a análise do diagrama Sankey e observando abordagens híbridas que consideram tanto a emoção quanto o contexto, percebe-se que os estudos híbridos tendem a explorar abordagens mais do que os estudos que consideram apenas o contexto ou apenas a emoção. As abordagens mais exploradas envolvem dados musicais, preferências musicais, informações contextuais comuns e o modelo emocional discreto. Esta revisão não retornou nenhum estudo explorando a expressão facial, as redes sociais e o comportamento do usuário nas abordagens híbridas. Este fato indica uma possível abertura para novas pesquisas sobre recomendações específicas para as emoções e o contexto. Em seguida, cada uma das abordagens apresentadas nas seções que respondem às sub-questões RQ-1.1, R-1.2, e RQ-1.3 serão exploradas com mais detalhes.

### **3.8.1.1 RQ-1.1: Que abordagens são usadas para recomendar música considerando o contexto?**

Esta seção apresenta abordagens de recomendação musical que consideram apenas o contexto, seja da música ou do usuário. Primeiro, é feita uma síntese das informações contextuais que os estudos utilizam e depois uma discussão sobre os métodos de recomendação musical.

Nos últimos anos, houve várias tentativas de incorporar informações contextuais para melhorar a recomendação musical (MAGARA et al., 2016; LEE; CHO, 2014; CHENG; SHEN, 2014; HELMHOLZ; VETTER; ROBRA-BISSANTZ, 2014; HONG et al., 2014; TENG; KUO; YANG, 2013; MILLER et al., 2010). Em geral, esta informação é composta de dados como localização, hora, data e aceleração. Tais conjuntos de dados são chamados de Características Comuns de Contexto (CCC) porque frequentemente incorporam outras abordagens contextuais e são amplamente utilizados na literatura. Um exemplo pode ser visto no trabalho de Miller et al. (2010), que usa a localização para determinar o contexto do usuário através da escuta. No trabalho, os autores consideram que a qualidade das listas de reprodução geradas automaticamente pode ser melhorada levando em conta os dados de localização disponíveis.

Wang, Rosenblum e Wang (2012) apresentam um modelo probabilístico para integrar informações contextuais com a análise do conteúdo musical. As informações contextuais são recuperadas utilizando dados sobre a atividade do usuário, com informações provenientes de um dispositivo móvel, assim como em (BAUER; JELLENEK; KIENTZ, 2018; VOLOKHIN; AGICHTEIN, 2018). A atividade do usuário é inferida em tempo real, e a música é recomendada com base na análise do conteúdo musical.

Karlsson, Okada e Noleto (2012) apresentam um sistema de coleta de dados contextuais para recomendar músicas de acordo com perfis de usuário aprendidos e situações específicas. Os autores sugerem um contexto com músicas pré-definidas e depois utilizam a primeira interação do usuário e sua resposta de interação para moldar outro contexto.

Na proposta de Nirjon et al. (2012), a atividade do usuário é continuamente inferida através do monitoramento do ritmo cardíaco. Para este fim, eles introduziram uma plataforma de detecção de desgaste chamada Septimu, que consiste de um par de fones de ouvido equipados com sensores que comunicam com o smartphone através do conector de áudio. O smartphone recolhe periodicamente amostras do acelerômetro e do microfone para determinar o nível de atividade e a frequência cardíaca de uma pessoa. Sensores também foram utilizados no trabalho de Helmholtz, Vetter e Robra-Bissantz (2014) para complementar o estudo, no qual os autores utilizaram sensores GPS, temperatura da pele e condutância, para analisar os efeitos de vários tipos de recomendações musicais enquanto um motorista está dirigindo.

Outra abordagem notável pode ser vista no trabalho de Teng, Kuo e Yang (2013), os autores classificam o contexto do usuário em 10 categorias predefinidas de atividade (brincar, acordar, exercitar-se, em um veículo, dirigir, andar, ler, trabalhar, comer, dormir), para isso utilizam informações dos sensores de um dispositivo móvel. Após identificar o contexto, os autores implementaram o algoritmo *Factoring Machine (FM)* para usar como mecanismo de recomendação.

Dias, Fonseca e Cunha (2014) também recuperam o contexto da situação através da atividade do usuário. Para isso, utilizaram uma abordagem associada ao conteúdo musical (recursos acústicos) e atividades (contexto), que permite analisar quais músicas são mais apropriadas para cada atividade (com base nas preferências do usuário). Okada et al. (2013) criaram um aplicativo que toca e recomenda música aos usuários seguindo processos de design centrados no usuário. Os seguintes passos foram seguidos: a) determinar os objetivos do sistema; b) identificar as necessidades do usuário; c) delinear um projeto de produto de alto nível; d) protótipo; e e) iterar o projeto com resultados de avaliação. A aplicação recomenda música com base no comportamento do usuário e metadados musicais. Para isso, tem aprendizado não supervisionado dos perfis dos usuários. As recomendações utilizam a música do usuário com a possibilidade de descobrir novas músicas com base em dados de outras pessoas que escutam músicas semelhantes ou executam atividades semelhantes.

As informações contextuais que ganharam muito destaque nos últimos anos têm sido os dados da interação dos usuários com as redes sociais. Vários sistemas de recomendação coletaram diretamente esses dados, o que não era possível até algumas décadas atrás. Jenkins e Yang (2016) propuseram um algoritmo que fornece recomendações personalizadas exclusivas baseadas nas postagens dos usuários no Twitter e no histórico de escuta. O sistema seleciona a letra e outros campos para gerar uma lista de músicas similares e criar a recomendação. A proposta é uma abordagem híbrida que combina métodos colaborativos com o histórico do usuário. Cheng e Shen (2014) não utilizaram informações da rede social, mas, em troca, aproveitou o histórico do usuário na abordagem de recomendação musical, assim como em (HONG et al., 2014; MAGARA et al., 2016). Os

autores apresentam um sistema chamado "Just-for-Me" que considera contextos associados à localização do usuário e tendências globais na popularidade da música. Os resultados apresentados mostraram que a incorporação da popularidade das faixas musicais pode melhorar significativamente o desempenho.

Hong et al. (2014) procuraram recomendar músicas que correspondessem ao contexto do usuário, considerando as músicas recém-adicionadas e evitando canções repetidas. Para fazer isto, eles analisaram o *feedback* do usuário antes de recomendar novas músicas, pois entendem que se um usuário gosta de uma peça musical em um contexto particular, então ele irá ouvir aquela peça musical; caso contrário, ele irá pular a peça musical sem escutá-la até o final. Magara et al. (2016) propuseram a MPlaylist que recupera o contexto através do histórico de escuta. Para isso, os autores obtiveram dados de vários sensores em um dispositivo móvel do usuário e os utilizaram para inferir o contexto e a atividade do usuário, gerando uma playlist baseada em preferências contextuais.

Schedl, Breitschopf e Ionescu (2014) dizem que um conjunto abrangente de recursos derivados de sensores, informação espaço-temporal e interação do usuário pode ser essencial para aprender que tipo de ouvintes de música preferem em um determinado contexto. Os autores propuseram criar uma playlist em tempo real de duas maneiras: pelo contexto do usuário e pela informação das músicas usando tags (etiquetas) semânticas. As tags semânticas também são usadas em Kaminskis e Ricci (2011) para selecionar um conteúdo musical que se adapte a um local de interesse. Os autores usaram tags emocionais atribuídas pelo usuário às faixas musicais e pontos de interesse. Uma experiência on-line foi conduzida pelos autores para avaliar a adequação da música selecionada pelo sistema para o ponto de interesse. Os resultados mostraram que os usuários tendem a concordar na correspondência entre as tags emocionais das músicas com os pontos de interesse produzidos pelos próprios usuários da comunidade.

Por outro lado, alguns estudos têm usado técnicas de aprendizagem de máquinas na recomendação musical (JIANG; HE, 2016; LEE et al., 2017; CHANG et al., 2019). Jiang e He (2016) incorporaram um modelo evolutivo chamado Árvore de Regressão Incremental, que coleta dados contextuais, dados musicais e *feedback* do usuário de forma incremental para caracterizar seu gosto pessoal pela música. Lee et al. (2017) apresentaram um sistema móvel que inclui módulos para reconhecer as atividades humanas. O reconhecimento das atividades do usuário utiliza métodos de aprendizagem de máquinas com técnicas de seleção de recursos de sinal de smartphones e métodos de filtragem colaborativa para estimar a preferência musical do usuário. Outro estudo que também incorporou métodos de aprendizagem de máquinas para recomendação musical foi o de Chang et al. (2019). Os autores usaram algoritmos de aprendizagem de reforço para aprender as preferências do usuário e, em seguida, fazer as recomendações.

### 3.8.1.2 RQ-1.2: Que abordagens são usadas para recomendar música considerando as emoções?

A maioria dos sistemas de recomendação musical usa métodos de recomendação baseados no conteúdo ou em colaboração. Entretanto, a escolha da música de um usuário depende não apenas das preferências históricas ou do conteúdo musical, mas também das emoções do usuário (AYATA; YASLAN; KAMASAK, 2018). A análise das emoções humanas após a exposição à música é considerada uma direção essencial porque vários estudos têm investigado a influência das emoções na tomada de decisões e no processo de recomendação.

Com a emoção do usuário reconhecida, os sistemas de recomendação tornam-se capazes de sugerir mais boa música para o usuário, conforme apresentado por Iyer et al. (2017). O objetivo dos autores é minimizar o esforço do usuário e sugerir música com base na emoção atual. No trabalho, a emoção é identificada através de expressões faciais usando o algoritmo Fisherfaces. Ao reconhecer a emoção, o aplicativo envia a emoção para o servidor de música e depois sugere uma lista de reprodução apropriada. Outro trabalho que utiliza expressões faciais é apresentado por Gilda et al. (2017). Os autores apresentam um tocador de música que faz recomendações com base na emoção em tempo real. O tocador é chamado EMP e incorpora o contexto emocional dentro da recomendação adaptativa. A abordagem tem um módulo de reconhecimento emocional que utiliza recursos de áudio para classificar a música em quatro classes emocionais diferentes. O rosto do usuário é capturado e usado em algoritmos de aprendizagem de máquina para identificar a emoção do usuário. Com isto, a aplicação proposta sugere música ao usuário, mapeando as emoções do usuário com as da música, além de considerar as preferências do usuário.

Na publicação Chiu e Ko (2017), a música é descrita em quatro categorias: "*Misery*" e "*Arousal*"(I), "*Pleasure*" e "*Arousal*"(II), "*Misery*" e "*Sleepiness*"(III) e "*Pleasure*" e "*Sleepiness*"(IV). Músicas da mesma categoria são recomendadas ao usuário de acordo com o estado emocional detectado. A emoção foi recuperada de duas maneiras: por dispositivos vestíveis que detectam a variabilidade da frequência cardíaca e por questionários de sentimentos subjetivos. As emoções foram analisadas para que a música apropriada pudesse ser selecionada. Além disso, as preferências do usuário foram gravadas usando algoritmos de aprendizagem de máquina.

Os sinais fisiológicos têm sido estudados há décadas na psicofisiologia para explicar o comportamento humano, e vários sinais fisiológicos estão disponíveis para medição. Os sinais fisiológicos são informações diretas de um ser humano e podem dizer condições de saúde, captar ações corporais e até mesmo reagir com emoções (KO et al., 2015). Antes, estes sinais eram limitados à captura apenas no laboratório, mas com o avanço da tecnologia, a captura de sinais fisiológicos pode ser realizada em qualquer lugar e a qualquer momento. Em vez de instrumentos hospitalares volumosos, os dispositivos

móveis se tornaram uma tendência para esta captura nos últimos anos (WELCH, 2012; KO et al., 2015).

O reconhecimento das emoções através de sinais fisiológicos é um dos ramos da computação afetiva, e muitos pesquisadores usam bio-sinais para inferir as emoções das pessoas (GUO; WU; PETEIRO-BARRAL, 2012; LE et al., 2011). Guo, Wu e Peteiro-Barral (2012) usaram sensores eletroencefalograma (EEG) para registrar as atividades elétricas do cérebro. Através do sinal EEG, a emoção do usuário é recuperada e associada a partes da música que ativam esta emoção. Conseqüentemente, são sugeridas músicas com as mesmas características. Para monitorar a atividade cerebral ao ouvir música e refletir respostas emocionais, os autores usaram o telefone celular em arquitetura de nuvem para hospedar os algoritmos de processamento e recomendação.

A abordagem de recomendação proposta por Le et al. (2011) considera a emoção e o *feedback* dos usuários para sugerir música. Le et al. (2011) monitoram pequenas mudanças elétricas na pele do corpo usando um sensor de Eletrocardiograma (ECG). De outra forma, Vateekul et al. (2015) fizeram um estudo utilizando sinais EEG para prever as emoções musicais. Neste estudo, os autores apresentam um novo algoritmo para prever emoções aplicando Filtragem Colaborativa (FC) e pontuação de similaridade com base em sinais EEG. Os resultados mostram que o método proposto é superior ao tradicional FC e às técnicas convencionais de classificação, incluindo C4.5, SVM (Support Vector Regression) e MLP (Multilayer Perceptron).

Uma abordagem de recomendação notável é apresentada nos trabalhos em (KANG; SEO, 2019; ANDJELKOVIC; PARRA; O'DONOVAN, 2019). Kang e Seo (2019) estimam a emoção de um usuário com base nos textos do smartphone e recomendam música com as mesmas emoções quando o usuário voltar para casa. Andjelkovic, Parra e O'Donovan (2019) apresentam uma nova forma de recomendar músicas baseadas na similaridade de emoções do mesmo artista. Além disso, o sistema traz uma nova maneira de visualizar a emoção em um espaço visual que permite uma melhor compreensão das recomendações dos usuários.

Outra abordagem de recomendação musical pode ser vista no trabalho de Abdul et al. (2018). Os autores apresentam um sistema de recomendação musical personalizado que considera as emoções e associa os dados do usuário com a música. Duas abordagens foram combinadas para alcançar esta correlação: a abordagem de rede neural convolucional e a abordagem de extração ponderada de recursos. Além de combinar as duas abordagens, a emoção do usuário foi considerada e recuperada subjetivamente, como em (LEHTINIEMI; HOLM, 2012; PADOVANI; FERREIRA; LELIS, 2017; ASSUNÇÃO; NERIS, 2019).

Lehtiniemi e Holm (2012) usaram imagens animadas e emocionalmente definidas para identificar o contexto do usuário e recomendar música. Por outro lado, Padovani, Ferreira e Lelis (2017) apresentaram o Bardo, um sistema que seleciona automaticamente a música de fundo para jogos de mesa. O sistema reconhece o discurso do usuário e transforma em



texto tudo o que os jogadores dizem durante uma sessão de jogo. Então, um algoritmo de aprendizagem supervisionado é usado para classificar o texto em uma emoção. Assunção e Neris (2019) apresentaram um aplicativo móvel que, ao recomendar música, considera o estado emocional atual e desejado do usuário. O principal objetivo do trabalho é ajudar o usuário a alcançar um estado emocional desejado. O estudo aplica o algoritmo de Assunção e Neris (2018) que recebe três parâmetros de entrada: o estado emocional atual, o estado emocional desejado e um conjunto de músicas com as emoções expressas em um modelo dimensional.

Embora existam estudos que classificam as emoções em modelos dimensionais (DENG et al., 2015), geralmente, muitos estudos descrevem as emoções a partir de uma perspectiva discreta (NARDUCCI; GEMMIS; LOPS, 2015; LOPES et al., 2018). Na perspectiva discreta, as emoções são vistas como uma soma de categorias que podem ser separadas para obter subcategorias mais refinadas e menores. Os modelos discretos são bastante populares porque são facilmente ligados à "psicologia popular" (LOCKNER et al., 2014).

A proposta de Narducci, Gemmis e Lops (2015) é baseada em técnicas de filtragem de conteúdo para inferir as emoções do usuário. Os autores assumem extrair as emoções do usuário de algum texto gerado pelo usuário (por exemplo, um post no Facebook, um tweet), utilizando técnicas de análise de texto, disponibilizando as informações emocionais para o algoritmo de recomendação. O mesmo ocorre nos trabalhos em (LOPES et al., 2018; FERWERDA; SCHEDL, 2014; ROSA; RODRIGUEZ; BRESSAN, 2015).

Li e Liu (2017) apresentam uma abordagem de recomendação musical baseada na análise do comportamento do usuário e na extração das emoções do usuário. Para isso, estabelece um modelo de interesse do usuário através da análise das preferências musicais. A emoção do usuário é recuperada das mensagens das redes sociais usando o método de agrupamento do Word2vec. A recomendação musical combina a lista recomendada pelo método de filtragem colaborativa com os resultados da análise emocional para gerar recomendações musicais de acordo com a emoção do usuário.

### **3.8.1.3 RQ-1.3: Que abordagens são usadas para recomendar música considerando as emoções e o contexto ao mesmo tempo?**

Outra abordagem de recomendação que observa as preferências musicais foi introduzida por Kasinathan et al. (2019) e é chamado de HeartBeats. O HeartBeats usa um mecanismo de inferência difusa que considera as atividades (contexto) e a emoção do usuário como parte dos parâmetros de recomendação. O sistema de recomendação utiliza características do perfil do usuário para recomendar músicas corretas com base nas preferências. Os resultados mostram que é possível melhorar a experiência de audição musical do usuário através de recomendações que consideram as emoções e o contexto.

Yang et al. (2016) mostram a associação das condições climáticas com a observação dos fatores emocionais do usuário melhora o sistema de recomendação musical. No traba-

lho, os autores apresentam um método de recomendação musical sensível à emoção que propõe música e artistas com base na emoção de cada usuário. Os autores recuperaram a emoção do usuário a partir de informações meteorológicas em tempo real. O processo de recomendação analisa o histórico de audição do usuário e classifica a música e os artistas que são favoráveis em diferentes condições meteorológicas. Os pesquisadores descobrem a preferência musical do usuário pelo comportamento do usuário e padrão de consumo do serviço.

Chen et al. (2013b), Chen et al. (2013a) apresentam duas abordagens para a recomendação de música consciente do contexto e da emoção. No primeiro estudo, Chen et al. (2013b) propuseram uma abordagem contextual que recomenda música a um usuário com base no estado emocional previsto no texto que ele escreve. Os autores analisaram a associação entre o texto e a música gerada pelo usuário, a partir de um conjunto de dados do mundo real. O comportamento de escuta moldou a emoção e o contexto do usuário. Para isto, adotaram o algoritmo da Máquina de Fatoração (MF) com uma abordagem de aprendizagem pelo próprio autor. No segundo estudo, Chen et al. (2013a) apresentam uma abordagem de recomendação baseada em várias informações de similaridade via MF, incluindo semelhanças baseadas no conteúdo e no contexto. Através da análise de texto realizada no conjunto de dados do mundo real do LiveJournal<sup>11</sup> foram recuperados, o contexto e a emoção do usuário.

Yoon, Lee e Kim (2012) implementaram um sistema de recomendação personalizado utilizando recursos selecionados, informações de contexto e histórico de escuta. No sistema de recomendação proposto, após o usuário fornecer o estado emocional por emojis, informações de contexto (temperatura, umidade e iluminação), o sistema cria uma lista de reprodução. O usuário pode selecionar uma música da lista de reprodução e ouvir ou obter uma lista de recomendações do servidor. O módulo de recomendação recupera o histórico de audição, características de baixo nível, informações contextuais e então cria uma lista de reprodução e a sugere ao usuário. No trabalho, os autores adotaram o modelo de Thayer (1990) para classificação de emoções.

Wang, Wang e Chou (2018) dizem que poucos estudos levam em conta tanto o contexto de uso quanto as emoções simultaneamente. Diante disto, os autores propuseram uma abordagem integrada para melhorar a previsão da preferência do usuário, uma abordagem que incorpora fatores de contexto e emoções. Em primeiro lugar, o mecanismo de recomendação coleta o local, a hora de ouvir as músicas e a emoção representativa. Em seguida, recomenda uma playlist que se relaciona às emoções dos usuários e informações contextuais.

Um tipo particular de recomendação musical é apresentado em (BRAUNHOFER; KAMINSKAS; RICCI, 2013; KAMINSKAS; RICCI; SCHEDL, 2013; KAMINSKAS; RICCI, 2011). Os trabalhos são bastante semelhantes. A principal tarefa é recomendar uma mú-

<sup>11</sup> <https://www.livejournal.com/>

sica que se encaixe em um local de interesse. Portanto, foram atribuídas tags emocionais tanto para as músicas quanto para os locais de interesse. Com isto, a semelhança das características das tags foi usada para estabelecer uma correspondência entre as músicas e os pontos de interesse. A busca de similaridade como uma forma de detectar o contexto e a emoção durante a recomendação de músicas também pode ser vista no trabalho de Wohlfahrt-Laymanna e Heimburgerh (2017). Os autores fornecem uma solução que gera uma playlist baseada na emoção expressa pela letra e pelos recursos musicais. Com estes valores, o sistema mediu a distância entre outros valores e procurou automaticamente por uma playlist semelhante que fosse contextualmente significativa.

Em Han et al. (2010), os autores propuseram uma ontologia chamada COMUS para representar várias situações de usuários. Também foi proposta uma classificação da transição emocional para mapear a transição emocional com recursos musicais de baixo nível. A ontologia COMUS também é utilizada no trabalho de Rho et al. (2013). Os autores apresentam um novo esquema para um serviço de recomendação de música sensível à situação/adaptável no ambiente da web semântica. A ontologia é usada para modelar as preferências e contextos musicais do usuário e apoiar o raciocínio sobre as emoções e preferências do usuário.

Outra abordagem pode ser vista no trabalho de Giri e Harjoko (2016). Neste, os usuários informam sua atividade e emoção desejada para receber uma playlist musical baseada em seu contexto. Para isso, os autores utilizaram o Raciocínio Baseado em Casos (RBC). A RBC pode ser aplicada a vários tipos de problemas, e a RBC pode fornecer uma solução utilizando o acúmulo de casos anteriores na base do caso. recomendações musicais para um contexto particular podem ser determinadas com base em escolhas musicais feitas anteriormente, de modo que a RBC possa dar recomendações baseadas em casos de solicitação musical em estações de rádio que tenham acontecido.

Quando uma abordagem de recomendação musical é proposta para um ambiente móvel, ela deve considerar as limitações de recursos que um dispositivo móvel impõe e os aspectos de experiência do usuário (JIANG; HE, 2016). Em particular, os aspectos contextuais do usuário também devem ser considerados significativos, já que o consumo de música em um contexto de ambiente móvel muda muito (LEE et al., 2017).

O objetivo de Sen e Larson (2015) é fornecer recomendações musicais baseadas em informações contextuais recuperadas por sensores. O contexto é inferido pela localização do dispositivo móvel e sensores, por exemplo, o acelerômetro. Os autores utilizaram fatores climáticos para definir a emoção do usuário. Ou seja, eles consideraram que a condição climática afeta as pessoas em uma determinada área geográfica. O modelo de classificação emocional utilizado foi o de Russell (RUSSELL; WEISS; MENDELSON, 1989). O processo de recomendação une os dados dos sensores com informações da web passando por uma cascata de modelos de Lógica Fuzzy para inferir o contexto do usuário e depois recomendar música.

Além de fatores climáticos, Jin et al. (2019) projetaram um sistema que permite ao usuário controlar qual característica deseja considerar durante a recomendação musical. Os usuários podem indicar a importância de seis características contextuais: humor, localização, clima, aspectos sociais, atividade atual e hora do dia. O algoritmo de recomendação criado foi baseado no Spotify API. As listas de reprodução são criadas para diferentes características contextuais. Os resultados do trabalho mostram que a emoção parece ser a característica contextual mais significativa.

De outra perspectiva, Schedl (2013) apresentaram o MMG (Mobile Music Genius), um reprodutor de música capaz de gerar uma playlist de música com reconhecimento do usuário e correspondência de locais de interesse. O MMG não realiza o processamento de sinais para recuperar a emoção musical. As emoções da música são descritas por tags emocionais anotadas pela comunidade de ouvintes. As emoções e atividades do usuário são solicitadas toda vez que uma nova música é tocada. Os autores apresentaram algumas informações contextuais, por exemplo, hora, localização, clima, ambiente, atividade física, status telefônico, conectividade, entre outras que podem ser vistas no trabalho. O MMG aprende relações entre os dados contextuais e o *feedback* implícito do usuário (tocar, pausar, parar, pular eventos), ou seja, que tipo de música você prefere e em que situação.

Outra abordagem de recomendação proposta para smartphones é o SAfeDJ (HU et al., 2015). O SAfeDJ é um sistema de recomendação musical projetado para transformar a condução em uma experiência segura e prazerosa. O objetivo do trabalho é ajudar os motoristas a reduzir a fadiga e as emoções negativas. O projeto é baseado em métodos interativos que permitem aos smartphones dentro do carro orquestrar múltiplas fontes de dados de sensoriamento e o contexto social dos motoristas. A solução proposta é interessante porque diferentes smartphones podem recomendar músicas preferíveis aos motoristas de acordo com a situação específica de cada motorista.

Também, pensando em como recomendar música que possa melhorar a condução de um motorista, Çano et al. (2016) apresentaram um projeto de recomendação musical contextual para trazer influências positivas no comportamento de direção do motorista. Para isso, eles se concentram na emoção do usuário. Além disso, consideraram informações fisiológicas sobre a dinâmica do batimento cardíaco do motorista obtidas a partir de sensores vestíveis; preferências musicais salvas do usuário para levar em conta seus gostos musicais; telemetria da unidade atual para considerar o estilo de condução atual do usuário; informações de localização e tempo para adaptar as listas de reprodução escolhidas ao contexto de condução.

Por outro lado, um estudo quantitativo dos fatores de preferência pessoal, situacional e musical em um contexto de smartphone foi apresentado por Yang e Teng (2015). Neste trabalho, foi realizada uma experiência com 48 participantes sujeitos a uma aplicação de escuta musical. A aplicação pediu a cada participante que escrevesse suas atividades e emoções antes de começar a ouvir música. As emoções foram classificadas em dez estados

emocionais: feliz, abençoado, animado, triste, melancólico, irado, pacífico, temido, inquieto, nenhum. A atividade do usuário poderia ser uma das 13 atividades classificadas pelos autores (acordar, exercitar, dirigir, caminhar, entre outras). A recomendação utilizada na experiência era que o usuário pudesse escolher qualquer música. Era suficiente que o participante da experiência informasse a atividade e o estado emocional antes de começar a tocar alguma música. Embora a abordagem possa parecer simples, ela é rica porque traz resultados que explicam melhor como é a recomendação do manual dos ouvintes.

### 3.8.2 RQ-2: Quais aspectos são desejáveis a serem tratados nos sistemas de recomendação musical?

Embora os sistemas de recomendação musical muitas vezes apoiem os usuários a encontrar a música que os agrada, ainda há desafios que precisam ser explorados por esses sistemas. Especialmente quando se trata de construir, incorporar e avaliar estratégias que vão além da ligação com as escolhas que os usuários fazem ou os descritores baseados em conteúdo. Estes desafios envolvem pesquisas adicionais sobre as necessidades, preferências e intenções dos ouvintes. (SCHEDL et al., 2018).

O desejo dos usuários de ouvir uma música depende de vários fatores, que muitas vezes não são suficientemente considerados pelas abordagens atuais das recomendações musicais. A Tabela 14 apresenta aspectos que podem ser considerados significativos e desejáveis de serem tratados pelos sistemas de recomendação musical. Durante a etapa 4 da RSL (veja a Seção 3.7), estes aspectos foram extraídos e identificados a partir das abordagens das publicações ou mencionados como fatores essenciais para a recomendação musical por parte dos autores. Considerando a Tabela 14, será discutido cada aspecto como se segue.

#### Atividade do usuário

Teng, Kuo e Yang (2013) identificam a atividade do usuário em 10 categorias: "no trabalho", "comendo", "dirigindo", "fazendo exercícios", "brincando", "em um veículo", "lendo", "dormindo", "andando" e "subindo". Nos experimentos do trabalho, cada usuário selecionou as atividades antes de ouvir as músicas. Os autores concluem que a recomendação de música sensível ao contexto obteve uma melhor performance quando utilizaram tags que descreviam as atividades do usuário. Outra forma de detectar a atividade do usuário é utilizando um dispositivo móvel (JIANG; HE, 2016; LEE et al., 2017). Jiang e He (2016) recuperaram atividade do usuário usando a magnitude linear da aceleração. Lee et al. (2017) consideraram três atividades no estudo: pegar transporte público (transporte), sair para fazer compras (compras) e relaxar. Para isso, utilizaram técnicas de seleção de recursos baseadas em dados de smartphone (localização, movimento, tempo, nível de ruído, entre outros) e inferiram a atividade do usuário utilizando métodos de aprendizagem de máquinas.

Tabela 14 – Aspectos desejáveis da recomendação musical.

Aspectos	Referências
Atividade do usuário	(TENG; KUO; YANG, 2013; JIANG; HE, 2016; LEE et al., 2017)
Satisfação	(CHIU; KO, 2017; KARLSSON; OKADA; NOLETO, 2012), (WANG; WANG; CHOU, 2018; HAN et al., 2010; OKADA et al., 2013; JIANG; HE, 2016)
Feedback	(WANG; ROSENBLUM; WANG, 2012; OKADA et al., 2013; MAGARA et al., 2016; JIANG; HE, 2016; LI; LIU, 2017; SCHEDL, 2013; WANG; WANG; CHOU, 2018)
Cold-start	(WANG; ROSENBLUM; WANG, 2012; CHANG et al., 2019; JENKINS; YANG, 2016; MAGARA et al., 2016; GUO; WU; PETEIRO-BARRAL, 2012)
Esforço cognitivo	(JIN et al., 2019)
Aprendizado	(MAGARA et al., 2016; CHANG et al., 2019)
Personalidade e preferências do usuário	(HAN et al., 2010; FERWERDA; SCHEDL, 2014, 2014)

Fonte: Elaborado pelo autor.

### Satisfação do usuário

A avaliação da qualidade de um sistema de recomendação é geralmente feita por testes funcionais, qualidade de saída do algoritmo de recomendação ou avaliação de usabilidade. Entretanto, estes métodos nem sempre refletem a aceitação do usuário, e recentemente tem havido um crescente consenso de que os sistemas de recomendação devem se concentrar menos na avaliação off-line dos algoritmos e se concentrar mais em abordagens centradas no usuário (OKADA et al., 2013). Jiang e He (2016) buscaram preservar a experiência do usuário durante a audição, utilizando algoritmos de aprendizagem de máquinas para aprender as preferências musicais dos usuários em diferentes contextos, incorporando a alimentação explícita e implícita do usuário. Okada et al. (2013) optaram por se concentrar mais em uma avaliação qualitativa baseada em testes UX. De acordo com os autores, fornecer recomendações em um contexto móvel enquanto se aprende perfis de usuários ainda é um desafio, porque eles descobriram que os usuários se sentem confusos pela falta de controle sobre quais músicas seriam tocadas.

Várias abordagens de recomendação propostas são avaliadas medindo a precisão das recomendações corretas. No entanto, Karlsson, Okada e Noletto (2012) conduziram um teste de usabilidade com ouvintes de música ativos para coletar preferências, necessidades e opiniões sobre possíveis melhorias no sistema de recomendações proposto. O teste preliminar mostrou que os usuários se sentiam confusos pela falta de controle direto sobre quais músicas eram tocadas e estavam curiosos para saber qual música seria a próxima sugerida.

Chiu e Ko (2017) seguiram outra abordagem e mediram a satisfação subjetiva do usuário

através do questionário *System Usability Scale (SUS)* (BROOKE et al., 1996). A pontuação média do SUS para todas as pesquisas foi de 75,94, mostrando que a usabilidade varia de *Ok* para *Excelente*. No entanto, ao analisar as questões que tratam de aspectos negativos, nota-se que a questão com a média negativa mais alta indica a necessidade de apoio técnico de outras pessoas para usar o sistema, uma importante lacuna de usabilidade a ser abordada.

De acordo com a ISO 9241 (ISO, 1998), a satisfação é considerada um aspecto essencial da usabilidade. Entre os aspectos da usabilidade (eficácia, eficiência e satisfação), a satisfação é considerada o atributo mais desafiador para medir e quantificar, uma vez que está relacionada a fatores subjetivos. A satisfação refere-se ao grau de conforto que os usuários sentem ao utilizar um produto. (NIELSEN, 1994). Estudos recentes buscam investigar cada vez mais a satisfação dos usuários nos sistemas de recomendação (WANG; WANG; CHOU, 2018; LEE; CHO, 2014; HAN et al., 2010). Estes estudos apontam que a satisfação em sistemas de recomendação musical pode ser associada a cada tipo de interação do usuário, (por exemplo, salvar uma música, adicionar uma música a uma playlist, visualizar uma página de artista ou álbum). Em geral, os estudos identificam o grau de satisfação com as recomendações que são sugeridas a partir dos dados coletados em entrevistas e questionários.

### ***Feedback***

As atuais abordagens de recomendação ignoram as informações ricas e personalizadas que podem ser coletadas a partir da interação do usuário com dispositivos móveis (JIANG; HE, 2016). Para melhorar a precisão dos sistemas de recomendação, o *feedback* do usuário pode ser inferido a partir das ações implícitas do usuário com o sistema. Por exemplo, se um ouvinte ouve uma música, em última análise, o usuário provavelmente dá um gostinho dessa música, o que pode ser considerado um *feedback* positivo (WANG; ROSENBLUM; WANG, 2012). Wang, Rosenblum e Wang (2012) exploraram implicitamente o *feedback* analisando as interações dos usuários com os sistemas de recomendação musical, tais como em (OKADA et al., 2013; MAGARA et al., 2016; SCHEDL, 2013).

Ao receber o *feedback*, os sistemas de recomendação podem aceitar várias sugestões para melhorar as informações sobre o contexto, a emoção, a atividade do usuário e o design (OKADA et al., 2013). Magara et al. (2016) usaram o feedback implícito do ouvinte para aprendizado contínuo, melhorando assim sua precisão na previsão. O *feedback* implícito é capturado pela ação do usuário (por exemplo, música selecionada) e enviado para o servidor, de modo que a lista de reprodução do usuário é atualizada com base na resposta do usuário e mudança no contexto. Li e Liu (2017) propuseram analisar em profundidade os dados de comportamento do usuário a partir dos registros do usuário e exibir as informações de *feedback* para examinar qual música o usuário ouve com mais frequência.

Wang, Wang e Chou (2018) utilizaram questionários para obter *feedback* dos participantes durante os experimentos e melhorar a recomendação.

### ***Cold-start***

A maioria dos sistemas de recomendação atuais emprega o modelo de filtragem colaborativa, e esses sistemas são vulneráveis ao problema do *cold-start* (CHANG et al., 2019). O problema do *cold-start* surge porque quando um sistema de recomendação tem um novo usuário, pouca informação é conhecida sobre esse usuário. Os "novos usuários" representam um grupo particular de usuários que ainda não geraram muitos dados. Normalmente, o sistema de recomendação precisa extrair suas preferências atuais de sua localização (CHEN; CHEN; WANG, 2015). Wang, Rosenblum e Wang (2012) apresentam uma solução para o problema do *cold-start* utilizando a localização dos usuários, procurando as músicas mais tocadas na região do usuário e para cada música faz uma análise de áudio para verificar se essa música é adequada para uma tarefa específica do usuário ou estado emocional. Jenkins e Yang (2016) buscaram resolver o problema do *cold-start* usando informações de contexto coletadas no Twitter combinadas com uma abordagem colaborativa usando o algoritmo K-Nearest Neighbourhood (K-NN). Entretanto, se o usuário não tem conta no Twitter, a abordagem não funciona. Magara et al. (2016) mostraram que resolvem o problema do *cold-start* usando dados de sensores instalados em dispositivos móveis e os usam para inferir o contexto do usuário e a atividade atual. Guo, Wu e Peteiro-Barral (2012) apenas enfatizam a importância de evitar o *cold-start* e deixam para trabalho futuro a investigação de como evitar o problema com o método de filtragem de conteúdo.

### **Carga cognitiva**

O esforço cognitivo ou carga cognitiva diz respeito à utilização dos recursos psicológicos das pessoas para estimular sua capacidade de aplicar os conhecimentos e habilidades adquiridos na resolução de problemas (PAAS et al., 2003). Jin et al. (2019) apresentaram o ContextPlay, um recomendador de música reconhecido pelo contexto que permite ao usuário controlar as características contextuais e preferências musicais. O estudo mostra que fornecer controle sobre as informações contextuais aumenta a qualidade da recomendação percebida sem aumentar a carga cognitiva. Por fim, os autores sugerem que os designers de recomendações incluem o controle do contexto para aumentar a qualidade das recomendações percebidas.

### **Aprendizado**

Uma suposição relevante é se os sistemas de recomendação tornaram possível reconhecer, interpretar, adaptar e aprender as atividades dos usuários, além do contexto e das preferências auditivas. Nesse caso, os usuários poderiam reduzir o esforço na busca de uma música entre bilhões de outras músicas nos sistemas de recomendação (MAGARA et al., 2016). Um sistema que aprende com os dados é um sistema inteligente que toma decisões



automaticamente, assim como a MPlist proposto por Magara et al. (2016). O aprendizado do MPlist é constituído de algoritmos de aprendizagem de máquinas e *feedback* implícito para melhorar a precisão na previsão. Em parte, Chang et al. (2019) utilizaram um método de aprendizado por máquina chamado de aprendizagem por booster, que toma uma sequência de decisões para aprender as preferências do usuário a partir do registro de reprodução de música.

### **Personalidade e preferências do usuário**

As preferências dos usuários são essenciais e devem ser levadas em conta pelos sistemas de recomendação musical. Por exemplo, uma pessoa que tem o hábito de ouvir música clássica pela manhã, ao acordar, recebe a sugestão de uma música do gênero rock. Esta pessoa provavelmente terá uma experiência ruim porque a música sugerida não pertencia ao seu estilo musical. Além do gênero musical fortemente ligado às preferências das pessoas, a popularidade de uma música é um aspecto importante que pode influenciar na escolha de uma música pelo ouvinte. Os projetistas de sistemas de recomendação devem sempre considerar as preferências do usuário. Muitas abordagens de recomendação buscam priorizar as preferências dos usuários (HAN et al., 2010; FERWERDA; SCHEDL, 2014). Na arquitetura de recomendação proposta por Han et al. (2010), a preferência do usuário inclui informações pessoais (por exemplo, idade, sexo, trabalho) e propriedades musicais (por exemplo, gênero favorito, cantor, descrição musical detalhada). Ao contrário de outros trabalhos, Ferwerda e Schedl (2014) não informam quais informações contextuais estão associadas à preferência do usuário, mas demonstram que a personalidade pode ser um aspecto essencial para entender a preferência do usuário para melhorar a recomendação musical.

A personalidade tem provado ser um fator duradouro influenciando o comportamento, interesse e gostos de um indivíduo (SNYDER; ICKES, 1985). Existe um interesse emergente em como a personalidade se relaciona com as preferências do usuário Ferwerda e Schedl (2014). Ferwerda e Schedl (2014) discutem ideias iniciais para melhorar os sistemas de recomendação, incorporando a personalidade do usuário e o estado emocional atual. Também sugerem que como as redes sociais geram um fluxo de comunicação constante, elas podem extrair a personalidade e os estados emocionais.

## **3.9 Desafios**

As descobertas desta revisão revelam algumas limitações e desafios em relação aos sistemas de recomendação musical, como descrito anteriormente. Estes desafios precisam ser superados para que os sistemas de recomendação musical possam sugerir músicas que atendam às perspectivas do usuário e, conseqüentemente, possibilitem uma melhor experiência musical. A seguir é apresentado os desafios a partir das perspectivas do

contexto e das emoções, que são os dois principais tópicos desta revisão. Para cada perspectiva, dois tipos de desafios são discutidos, os técnicos e os centrados no usuário.

### 3.9.1 Perspectiva do contexto

O principal objetivo dos sistemas de recomendação musical que consideram informações contextuais é permitir que os usuários escutem a música que melhor se adapte ao seu contexto de uso atual. Entretanto, para que isso seja alcançado, os sistemas de recomendação devem primeiro identificar as informações contextuais. Várias informações contextuais têm sido propostas e aplicadas para melhorar a experiência auditiva do usuário (veja as publicações 1-19 na Tabela 13). Veja que na maioria das publicações, as informações de contexto são frequentemente encontradas usando técnicas de aprendizagem de máquinas, dados smartphone, histórico do usuário, atividade do usuário, localização, clima, localização, temperatura e informações musicais. Embora os estudos de recomendação musical que consideram informações contextuais apresentadas até agora tenham apresentado resultados relevantes, os estudos ainda precisam explorar mais os desafios técnicos e centrados no usuário que existem durante a recomendação musical.

#### 3.9.1.1 Desafios técnicos

A incorporação de informações contextuais é muito importante em vários domínios de aplicação, incluindo sistemas de recomendação musical, onde a opinião do usuário sobre a música sugerida é dependente do contexto. Atualmente, é bastante comum que novas propostas de recomendação de música frequentemente forneçam recursos de recomendação para dispositivos móveis, já que estes dispositivos, como os smartphones, permitem recuperar o contexto mais facilmente. Entretanto, muitos destes sistemas rodando em dispositivos móveis têm limitações de recursos. Um esforço significativo de processamento pode ser necessário para aplicar técnicas de recomendação populares e robustas, tais como Support Vector Arrays ou Deep Learning (JIANG; HE, 2016). Além disso, existe uma preocupação com a duração da bateria e o tráfego de dados. Dependendo da aplicação, o sistema pode estar associado ao reconhecimento constante do contexto.

Outras abordagens de recomendação geralmente aplicam o histórico do usuário para identificar o contexto e sugerir música. Estas abordagens assumem que o contexto atual pode ser recuperado de padrões de audição similares e, portanto, têm alcançado resultados significativos em recomendações (MAGARA et al., 2016; JENKINS; YANG, 2016; CHENG; SHEN, 2014; HONG et al., 2014; KARLSSON; OKADA; NOLETO, 2012). Entretanto, estas abordagens só são eficientes quando o histórico do usuário é composto de uma série de variáveis (por exemplo, uso diário do sistema e avaliações constantes de música) envolvendo a interação do usuário com o sistema ou com o ambiente ao redor.

Além do histórico do usuário, a atividade do usuário tem sido levada em conta em muitas abordagens durante a recomendação musical, considerando o contexto (VOLOKHIN; AGICHTEIN, 2018; LEE et al., 2017; TENG; KUO; YANG, 2013; NIRJON et al., 2012; WANG; ROSENBLUM; WANG, 2012; DIAS; FONSECA; CUNHA, 2014). Nestas abordagens, o contexto é identificado a partir da atividade que realiza, seja correndo, andando ou trabalhando. O maior desafio destas abordagens é identificar a atividade atual, que é uma tarefa complexa, pois a diversidade de atividades possíveis é extensa. Por ser uma tarefa complexa, muitos destes sistemas utilizam um conjunto menor de atividades pré-definidas ou encontram padrões durante a interação com os sistemas.

Muitas abordagens que relacionam música a condições contextuais tendem a usar uma mistura de aspectos contextuais em um algoritmo de recomendação musical. Por exemplo, em Magara et al. (2016), os autores utilizam as informações de um dispositivo móvel, recuperam o histórico do usuário e consideram as preferências musicais. Da mesma forma, Teng, Kuo e Yang (2013) aproveitam as informações de um dispositivo móvel, recuperam a atividade do usuário e se juntam aos métodos de aprendizagem de máquinas para sugerir música considerando o contexto. Embora em ambos os trabalhos a união de vários aspectos contextuais pareça interessante para melhorar as recomendações musicais, os autores não destacam as condições contextuais nas quais a música é recomendada.

### 3.9.1.2 Desafios centrados no usuário

Além dos desafios tecnológicos, os fatores humanos podem ter impacto nas recomendações baseadas em informações contextuais. Selecionar uma música para tocar normalmente requer a atenção do usuário e várias operações na tela. Portanto, quando o usuário está em movimento, o que é mais desafiador do que ficar parado, espera-se que a aplicação proporcione uma experiência mais envolvente. Entretanto, poucas abordagens que consideram as emoções e o contexto apresentados por esta revisão estão preocupadas com a experiência do usuário (OKADA et al., 2013; JIANG; HE, 2016). Tipicamente, as avaliações de sistemas de recomendação musical utilizam métricas de precisão e medidas quantitativas relacionadas, como precisão, recall ou médias de erro (entre a previsão e a classificação real) (TENG; KUO; YANG, 2013; MAGARA et al., 2016; CHEN et al., 2013a).

A avaliação da exatidão das recomendações não garante que o usuário terá uma boa experiência musical. Existe um consenso crescente de que os sistemas de recomendação devem se concentrar menos na avaliação off-line de algoritmos e se concentrar mais em abordagens centradas no usuário, pois aspectos como apresentação e interação impactam significativamente a experiência do usuário (KONSTAN; RIEDL, 2012). Konstan e Riedl (2012) dizem que a medição da experiência do usuário é um desafio para a pesquisa sobre sistemas de recomendação. Requer o desenvolvimento de um sistema que inclua algoritmos e uma interface para realizar estudos de campo com usuários de longo prazo

do sistema.

### 3.9.2 Perspectiva da emoção

Os sistemas de recomendação musical que consideram as emoções visam sugerir a música que melhor se adapta às emoções dos usuários. Identificar e considerar a emoção tanto dos usuários quanto da música é essencial para atingir este objetivo. Nesta revisão, várias abordagens de recomendação que consideram as emoções foram apresentadas (veja as publicações 20-37 listadas na Tabela 13). Em geral, cada abordagem associada aos estudos está relacionada a mecanismos que utilizam a aprendizagem de máquinas, informações subjetivas, dados sensoriais, redes sociais e informações musicais. As abordagens não podem ser limitadas apenas a estes mecanismos, pois muitos têm limitações de implementação e há muito a ser explorado. Por esta razão, segue-se uma discussão sobre os principais desafios técnicos e centrados no usuário associados às recomendações musicais sensíveis às emoções.

#### 3.9.2.1 Desafios técnicos

Okada et al. (2013) exploraram as informações contextuais no sistemas de recomendação e analisaram a experiência do usuário. Os autores identificaram que entre os fatores contextuais, a emoção é um fator que pode afetar o que o usuário escuta e o seu comportamento. De acordo com Scherer (2005), a emoção envolve diferentes componentes: uma reação observável, uma reação fisiológica, uma interpretação cognitiva, uma expressão motora e uma experiência subjetiva. Em geral, as abordagens de recomendação que consideram as emoções obtêm o estado emocional do usuário através de uma reação fisiológica (GUO; WU; PETEIRO-BARRAL, 2012; LE et al., 2011) ou perguntando ao usuário (ASSUNÇÃO; NERIS, 2019; ABDUL et al., 2018; CHIU; KO, 2017; LEHTINIEMI; HOLM, 2012; PADOVANI; FERREIRA; LELIS, 2017). A maneira mais comum de obter a emoção que a literatura apresenta é utilizando sensores (CHIU; KO, 2017; IYER et al., 2017; GUO; WU; PETEIRO-BARRAL, 2012; LE et al., 2011) e expressões faciais (CHIU; KO, 2017; GILDA et al., 2017).

Entretanto, o uso de apenas uma fonte de entrada para identificar a emoção do usuário pode não ser muito preciso, pois a emoção envolve diferentes componentes. A emoção do usuário pode ser mais precisa quando existem múltiplas entradas, por exemplo, unindo sensores fisiológicos com dados de emoções subjetivas ou de expressão motora. (ASSUNÇÃO; NERIS, 2019).

Além de considerar a emoção do usuário, outras abordagens se esforçam para descobrir a emoção que uma música carrega (intencional, percebida ou induzida) (SCHEDL et al., 2018). A área que aborda este tema é chamada de Reconhecimento de Emoções Musicais (REM) (YANG; CHEN, 2011). O REM procura detectar a expressão emocional das

peessoas a partir de uma música e é útil na compreensão musical, na recuperação da música e em outras aplicações relacionadas à música.

Várias abordagens apresentadas até agora consideram a extração de informações da música (ASSUNÇÃO; NERIS, 2019; ANDJELKOVIC; PARRA; O'DONOVAN, 2019; GILDA et al., 2017; FERWERDA; SCHEDL, 2014) para obter emoção musical, seja através do processamento de sinais de áudio, similaridade ou tags emocionais. Muitos destes trabalhos apresentam um grande esforço para detectar a emoção musical. Os pesquisadores também utilizam este esforço para prever a emoção do usuário, a partir da emoção prevista da música.

É essencial enfatizar que este tipo de aplicação pode se tornar cada vez mais comum devido a proliferação de aplicações para dispositivos móveis. Entretanto, em virtude da possível necessidade de envolver métodos de processamento de sinais e algoritmos de aprendizagem de máquina, muitas restrições de recursos ainda serão mantidas nos dispositivos móveis (JIANG; HE, 2016). Vários sistemas de recomendação musical, como o Spotify<sup>12</sup>, Deezer<sup>13</sup>, e Apple Music<sup>14</sup> não realizam a etapa de processamento do sinal do lado do cliente. No entanto, com o crescimento dos dispositivos de uso e consumo de música offline, um conjunto menor de operações no dispositivo do usuário pode ser necessário.

### 3.9.2.2 Desafios centrados no usuário

Durante muito tempo, o usuário teve que percorrer um enorme conjunto de músicas fornecidas pelos tocadores de música tradicionais para encontrar as músicas que melhor se adaptassem às suas emoções. Atualmente, este problema tem sido muito pesquisado na literatura e já tem várias propostas que buscam recomendar músicas automaticamente considerando as emoções (GILDA et al., 2017; IYER et al., 2017; PADOVANI; FERREIRA; LELIS, 2017; ROSA; RODRIGUEZ; BRESSAN, 2015). Este avanço mostra que os pesquisadores têm se preocupado em tornar a descoberta musical mais compreensível e mais casual para o usuário.

Entretanto, poucas abordagens procuraram melhorar a causalidade do usuário, mais precisamente em abordagens que utilizam sensores externos para detectar a emoção do usuário. Por exemplo, Guo, Wu e Peteiro-Barral (2012) usaram um sensor Eletroencefalográfico (EEG) que monitora a atividade cerebral ao ouvir música e reflete as respostas emocionais. Embora este tipo de sensor possa melhorar a sugestão de música para o usuário, por outro lado, dependendo do tipo de sensor utilizado pode não trazer uma excelente experiência musical, mas pode gerar desconforto com o uso do sensor. Assim,

<sup>12</sup> <https://www.spotify.com/>

<sup>13</sup> <https://www.deezer.com/>

<sup>14</sup> <https://www.apple.com/apple-music/>

futuras propostas de sistemas de recomendação de música devem considerar os aspectos ergonômicos do usuário.

Identificar a emoção do usuário enquanto recomenda a música ainda é um desafio. A mais comum entre as propostas apresentadas é a utilização de informações subjetivas do usuário (ASSUNÇÃO; NERIS, 2019; ABDUL et al., 2018; CHIU; KO, 2017; LEHTINIEMI; HOLM, 2012; PADOVANI; FERREIRA; LELIS, 2017). Os sistemas de recomendação perguntam inicialmente ao próprio usuário seu estado emocional atual e depois sugerem música de acordo com a emoção informada. Em geral, existem dois problemas ao se obter a emoção do usuário nestes sistemas. O primeiro é que o usuário pode não ter certeza em qual estado emocional ele está, o que pode dar ao sistema de recomendação uma emoção errada. O segundo é que se o usuário estiver triste, provavelmente lhe serão sugeridas músicas tristes. O ideal seria obter a emoção atual e desejada do usuário de várias fontes de entrada, além de receber constantemente o *feedback* (LE et al., 2011) para melhorar a precisão das músicas sugeridas.

A abordagem de recomendação musical que considera as emoções, além de estar consciente da emoção do usuário, também direciona os esforços para identificar as emoções das músicas. Normalmente, as abordagens recuperam a emoção da música, extrai informações das músicas (ASSUNÇÃO; NERIS, 2019; ANDJELKOVIC; PARRA; O'DONOVAN, 2019; GILDA et al., 2017; FERWERDA; SCHEDL, 2014), seja por tags emocionais, similaridade ou processamento de sinal de áudio acompanhado de métodos de aprendizagem de máquina. (ABDUL et al., 2018; CHIU; KO, 2017; LOPES et al., 2018; LI; LIU, 2017; VATEEKUL et al., 2015; DENG et al., 2015). A maioria destas abordagens requer o áudio da música e depende da intervenção do usuário/especialista durante certas fases de reconhecimento da emoção musical, tornando-a um desafio ainda mais significativo para o reconhecimento das emoções.

Por outro lado, várias abordagens têm se preocupado com as preferências musicais do usuário (LI; LIU, 2017; KASINATHAN et al., 2019; ÇANO et al., 2016; YANG; TENG, 2015; YANG et al., 2016). Contudo, os projetistas de sistemas de recomendação musical devem estar cientes de que ao sugerir música considerando as preferências musicais deve sempre levar em conta o estilo musical do usuário e relacioná-las às emoções. Suponha que um usuário tenha a intenção de melhorar seu estado de espírito para que possa estar mais satisfeito e, em um momento determinado, receba sugestões de músicas que carregue emoções alegres mas não pertença a seu estilo musical favorito. Consequentemente, o usuário poderá ter uma má experiência musical. Portanto, sugere-se que os pesquisadores adotem teorias psicológicas e reúnam características específicas do usuário para integrar e construir sistemas de recomendação mais conscientes das emoções (SCHEDL et al., 2018).

### 3.10 Considerações finais

Esta revisão mostrou que os pesquisadores estão tentando estabelecer um sistema automático para o reconhecimento das emoções e do contexto, utilizando vários métodos. Portanto, os sistemas de recomendação musical têm sido cada vez mais beneficiados e recebem mais e mais atenção. Este estudo analisou abordagens de recomendação musical nas quais consideram apenas o contexto, apenas as emoções e abordagens híbridas nas quais consideram tanto a emoção quanto o contexto durante a recomendação musical. Uma ampla discussão foi realizada sobre os principais desafios enfrentados pelo estudo desta revisão. Os desafios envolvem desafios técnicos e desafios centrados usuário que precisam ser superados pelos sistemas de recomendação musical.

Esta revisão também sugere que os pesquisadores precisam explorar mais outros fatores que afetam as recomendações musicais. Estes fatores envolvem atividade do usuário, satisfação, *feedback*, cold-start, carga cognitiva, aprendizagem, personalidade e preferências do usuário. Considera-se extremamente importante que os pesquisadores valorizem estes fatores separadamente ou em conjunto em suas pesquisas futuras.

Em geral, observou-se que as abordagens que consideram o contexto ainda carecem de mais clareza na descrição do contexto. Os pesquisadores precisam informar o modelo de contexto adotado e que tipo de informação contextual eles utilizam. Além disso, a privacidade deve ser mantida, e todas as informações sobre o usuário devem ser informadas. O mesmo ocorre com as abordagens que consideram a emoção. Os conceitos de emoção devem ser bem definidos. Os pesquisadores devem indicar se estão trabalhando com a emoção expressa ou percebida a partir da música. Como vários artefatos de avaliação propostos na literatura têm uma direção diferente sobre emoção, os autores devem estar claros sobre qual modelo emocional eles usam na pesquisa.

Outro ponto crítico é o fator humano, que está um pouco presente nas avaliações dos sistemas de recomendação musical. Muitos pesquisadores realizam avaliações em um conjunto de dados sem o envolvimento real do usuário. O usuário deve cooperar no projeto de criação do sistema. Entretanto, percebe-se que a participação real do usuário nos experimentos das aplicações de recomendação musical ainda é pouco explorada.

Tudo isso está acontecendo atualmente em um ambiente móvel, utilizando telefones celulares com pouca capacidade de armazenamento e processamento. O projeto de um sistema de recomendação deve considerar estas restrições. Muitas destas tarefas ocorrem no lado do usuário e não no servidor.

Por fim, espera-se que pesquisas futuras também considerem a intenção musical do usuário e seu estilo preferido, adotando teorias psicológicas e reunindo as características específicas dos usuários. Assim, novas abordagens de recomendação proporcionarão uma melhor experiência auditiva para os ouvintes e, conseqüentemente, farão avançar o estado da arte em direção a sistemas de recomendação musical conscientes da emoção e do contexto.

### 3.10.1 Considerações finais

Embora as questões de pesquisa RQ-1.2 e RQ-1.3 desta revisão sistemática tenham investigado abordagens de recomendação de música que consideram as emoções, seja do usuário ou inerentes às músicas, o desenvolvimento subsequente desta pesquisa revelou a necessidade de um foco mais específico. Ao aprofundar no tema, percebeu-se que a incorporação direta da emoção como um elemento central da recomendação poderia introduzir uma complexidade adicional, desviando o foco principal do trabalho. As emoções, embora intrinsecamente ligadas à música e à experiência do ouvinte, apresentam uma variedade de interpretações e manifestações subjetivas, o que poderia resultar em um escopo de pesquisa extenso e menos focado. Assim, optou-se por concentrar esforços na exploração do contexto da interação e na experiência do usuário (UX), elementos que, por sua natureza, já englobam aspectos emocionais indiretos, mas dentro de um quadro mais gerenciável e objetivo.

Esta decisão estratégica permitiu direcionar a pesquisa para uma abordagem mais consolidada e objetiva, em que o contexto e a UX são tratados como pilares fundamentais. A escolha por focar nesses elementos proporcionou uma base mais clara e direcionada para a construção da arquitetura UConteXt Arch, permitindo um tratamento mais profundo e detalhado das interações dos usuários com os sistemas de recomendação musical. Reconhece-se, no entanto, que a emoção é um aspecto importante e intrínseco à música e à experiência de ouvir música. Futuras pesquisas podem explorar mais a fundo a inter-relação entre emoção, contexto e UX, potencialmente expandindo o escopo da UConteXt Arch ou desenvolvendo abordagens complementares que integrem todos esses aspectos de forma mais explícita.



---

## Capítulo 4

# Avaliando a experiência do usuário na descoberta de música em Deezer e Spotify

---

*Este capítulo continua-se a exploração do ciclo de relevância e início do Design do DSR, investigando a experiência do usuário nas plataformas comerciais de streaming de música. Identificam-se problemas e falhas que reforçam a necessidade da arquitetura proposta. Destacam-se as falhas na comunicabilidade, justificando a hipótese de que uma arquitetura que integra contexto e experiência do usuário pode melhorar a recomendação musical.*

O estudo exploratório entre duas plataformas de reprodução de música, Spotify e Deezer, é descrito neste capítulo. A aprovação ética para esta pesquisa foi concedida pelo Comitê de Ética em Pesquisa da Universidade Federal de São Carlos, cuja função é defender e garantir a integridade dos participantes.

O objetivo deste estudo foi compreender a experiência do usuário com as recomendações musicais feitas nas plataformas do Spotify e Deezer. Para essa análise, a conformidade dos sistemas de recomendação com os aspectos desejáveis, conforme apresentados no Capítulo 3, foi verificada. Os aspectos considerados englobam a atividade do usuário, satisfação, feedback, cold-start, carga cognitiva, aprendizado, personalidade e preferências do usuário.

Além disso, foi adotado o Método de Avaliação da Comunicabilidade (MAC) (SOUZA; LEITÃO, 2009). O MAC é um método semiótico baseado em engenharia que explora falhas de comunicação entre o sistema projetado e o usuário, observando como um grupo

de usuários interage com um determinado sistema (SOUZA; LEITÃO, 2009). O método MAC foi escolhido porque permite visualizar como a interface do sistema sendo avaliada está comunicando as interações. Com o MAC, as falhas de comunicação que a interface de recomendação possuía foram verificadas. Além disso, tarefas foram criadas para atender aos aspectos desejáveis e analisar as falhas.

Adicionalmente ao MAC, adotou-se o Self-Assessment Manikin (SAM) como um método complementar para avaliar a experiência do usuário (UX) de forma mais abrangente. O SAM é uma técnica não-verbal de avaliação afetiva que mensura as reações emocionais dos usuários, baseando-se em três dimensões: prazer, excitação e dominância (BRADLEY; LANG, 1994). Este instrumento emprega uma escala de 1 a 9 pontos para medir as dimensões de prazer, excitação e dominância, refletindo a experiência afetiva do usuário. A utilização do SAM teve como objetivo capturar as respostas afetivas dos participantes às recomendações musicais oferecidas pelas plataformas, proporcionando uma compreensão da experiência do usuário em nível emocional. Este método foi integrado ao estudo para que pudesse correlacionar as falhas de comunicação identificadas pelo MAC com as reações elicitadas pelas interfaces das plataformas de streaming.

Este capítulo foi dividido em três etapas: Planejamento, Execução e Análise. Os três passos foram conduzidos durante o estudo, seguindo a orientação de Lazar, Feng e Hochheiser (2017).

## 4.1 Planejamento

Para este estudo, foram definidas duas plataformas comerciais de streaming de música, Spotify e Deezer. Nos últimos anos, um avanço significativo foi alcançado, assim como o fortalecimento dessas plataformas de streaming de música. A Deezer conta com mais de 16 milhões de usuários ativos, enquanto o Spotify ultrapassa 356 milhões de usuários ativos mensais em todo o mundo que consomem música (SPOTIFY, 2021; DEEZER, 2021). Ambas as plataformas oferecem acesso a uma vasta quantidade de músicas, acessíveis por computadores e dispositivos móveis. O principal motivo para a escolha dessas duas plataformas é a possibilidade de ouvir música na versão gratuita. Na avaliação com a Deezer e o Spotify, foi utilizada a versão web de cada plataforma, já que a plataforma web não requer uma assinatura mensal para o uso dos serviços oferecidos. Além disso, o sistema de recomendação das plataformas é o mesmo para ambas as versões, web e móvel.

Para analisar as interações dos participantes com as ferramentas Deezer e Spotify, foram criadas cinco tarefas para orientar os participantes durante a execução do estudo (ver Tabela 15). As tarefas foram criadas com base nos aspectos desejáveis, de modo a manter a relação com as emoções e o contexto. Esses aspectos foram fundamentais para a criação das tarefas de avaliação, roteiros de apresentação do sistema e cenários de descrição de tarefas. A Tabela 15 apresenta a relação existente entre as tarefas e os

Tabela 15 – Relação entre aspectos desejáveis e tarefas - Os participantes responderam a perguntas do SAM após as tarefas atribuídas por (\*)

ASPECTOS	TAREFAS				
	T1	T2*	T3	T4	T5*
	Vamos começar a avaliação. Primeiro, acessaremos o site da plataforma definida. Em seguida, você terá que criar uma nova playlist. Sinta-se à vontade para encontrar e adicionar 3 músicas que costuma ouvir quando está no carro/no trabalho.	Agora vamos para a Tarefa 2. Vamos ver quais recomendações a plataforma produziu para você. Vamos para a página principal do aplicativo. Na tela principal, encontre outras três músicas para ouvir quando estiver no carro/no trabalho. Sinta-se à vontade para avaliar as sugestões que a plataforma recomendou.	Chegamos à Tarefa 3. Agora, navegue na plataforma mais uma vez. Encontre mais três músicas que você costuma ouvir quando está em um estado emocional feliz/triste. Não se esqueça de adicioná-las a uma nova playlist.	Agora vamos em busca do seu gênero musical favorito. Você precisará criar uma nova playlist com músicas relacionadas ao seu gênero musical preferido. Selecione 3 músicas das sugestões da plataforma.	Chegamos à última etapa. Agora vamos analisar as recomendações que a plataforma nos oferece. Voltemos para a tela principal da ferramenta. Das recomendações que a plataforma nos oferece, selecione mais 3 músicas. Escolha músicas que você gosta de ouvir quando está feliz/triste e no carro/no trabalho. Não se esqueça de criar uma nova playlist.
Atividade do Usuário					
Satisfação					
Feedback					
Cold-start					
Esforço cognitivo					
Aprendizado					
Personalidade e preferências do usuário					

aspectos desejáveis.

A *satisfação do usuário* e o *feedback* são compreendidos pelas ações tomadas pelo usuário ao escolher ou não ouvir uma música na plataforma e pela decisão de avaliar explicitamente se uma música sugerida é adequada ou não para o contexto atual. Por causa disso, as Tarefas 2 e 3 verificam a satisfação do usuário quando o participante avalia as recomendações tanto de forma implícita quanto explícita. Por outro lado, as Tarefas 2 e 4 verificam o feedback do usuário quando este aprecia as recomendações que a plataforma oferece e, conseqüentemente, decide adicioná-las à sua playlist.

O aspecto de *cold-start* é verificado nas Tarefas 1 e 2. Na Tarefa 1, o usuário é novo na plataforma e já realizou algumas interações. Na Tarefa 2, a plataforma realiza as primeiras sugestões musicais com base nas interações iniciais do usuário.

Nas Tarefas 1 e 3, solicita-se ao usuário que acesse o site da plataforma, crie uma playlist e procure e adicione 3 músicas. Compreende-se que, por serem tarefas manuais, pode levar muito tempo para o usuário percorrer a biblioteca musical, causando maior carga cognitiva.

O aspecto de *aprendizado* das plataformas é verificado nas Tarefas 2, 4 e 5. Nessas Tarefas, os usuários avaliam se gostam das sugestões das plataformas. Com o tempo, quanto mais o usuário interage com as plataformas, mais as ferramentas aprendem sobre os usuários. Com isso, verifica-se este aspecto em três momentos diferentes.

Compreende-se que, se as plataformas aprendem os gostos do usuário ao longo do tempo a partir das avaliações que o usuário faz durante o uso, então as plataformas serão capazes de prever a *personalidade* e as *preferências* do usuário. Assim, verifica-se os

aspectos de personalidade e preferência nas Tarefas 4 e 5. A Tarefa 4 é sobre o gênero musical e a Tarefa 5 é sobre o estado emocional e o contexto do usuário.

Além do questionário de perfil demográfico e de tarefa, adotou-se o questionário Self-Assessment Manikin (SAM) (BRADLEY; LANG, 1994). Utilizou-se o questionário SAM para obter avaliações subjetivas dos estímulos de cada participante quando a plataforma realiza uma recomendação musical. O SAM é um instrumento composto por conjuntos de figuras bidimensionais que avaliam diretamente as dimensões de satisfação, motivação e dominância de controle ao realizar uma determinada atividade. Cada dimensão é representada por cinco desenhos que simbolizam diferentes gradações emocionais. Por exemplo, a dimensão de satisfação é representada por um manequim triste/insatisfeito em uma extremidade e um feliz/sorrindo na outra. As respectivas gradações estão intercaladas entre esses extremos. Os participantes respondem marcando um X em um dos cinco desenhos em cada escala ou nos espaços entre eles, resultando em nove possibilidades de resposta. O valor mais baixo para cada dimensão é 1, que indica a menor pontuação de satisfação, motivação ou dominância. Ao mesmo tempo, 9 é o valor máximo e reflete o maior nível das mesmas dimensões.

Durante a etapa de planejamento, conduziu-se um estudo piloto que teve o objetivo de reproduzir os métodos planejados para o estudo para que pudéssemos encontrar falhas e respostas para possíveis problemas no desenho do estudo. Realizou-se o estudo piloto com 4 participantes, 2 usuários para cada ferramenta avaliada.

Após a realização do estudo piloto, ajustaram-se 5 tarefas para aproximar a descrição da realidade do participante. Além disso, em cada tarefa do estudo, os participantes adicionaram previamente 5 músicas à playlist, totalizando uma seleção de 25 músicas por usuário. O tempo médio do estudo foi de cerca de 1 hora, e para não cansar os participantes, reduziu-se a seleção para 3 músicas para cada tarefa.

Também houve ajustes no questionário de perfil demográfico. Modificaram-se as perguntas relacionadas ao contexto e ao estado emocional de audição musical mais preferido. Anteriormente as perguntas eram fechadas, e o usuário informava apenas um contexto e um estado emocional. Não era fácil separar os membros em dois grupos com apenas uma escolha. Portanto, tornaram-se as escolhas abertas, e os participantes puderam selecionar mais de um contexto de audição e mais de um estado emocional.

Convidaram-se os participantes via mídias sociais e email. Os contatos pré-estabelecidos pelos pesquisadores receberam o convite. Direcionou-se o convite para pessoas que habitualmente ouvem música em seu dia a dia enquanto realizam alguma atividade.

A avaliação de comunicabilidade é um método qualitativo que enfatiza a análise em profundidade. O número de participantes é geralmente pequeno, variando de cinco a dez (SOUZA; LEITÃO, 2009). Dado isso, o recrutamento ocorreu por um mês e alcançou 10 participações, sendo 5 participantes para cada avaliação de ferramenta. Os critérios de inclusão para os sujeitos na pesquisa foram: ter mais de 18 anos; ser brasileiro; e ser

alfabetizado.

A amostra de participantes foi composta por 5 participantes do sexo masculino e 5 do sexo feminino, com idades entre 18 e 54 anos. Todos os participantes têm o hábito de ouvir música em seu dia a dia, e 60% deles ouvem música todos os dias. O nível escolar dos participantes era de ensino médio, graduação e pós-graduação participaram na avaliação. Além disso, distribuíram-se os participantes para que houvesse participantes com pouco, muito ou nenhum conhecimento sobre a ferramenta que avaliamos para cada ferramenta.

Por meio do questionário de perfil demográfico, coletaram-se as seguintes informações: os dispositivos (por exemplo, computador, celular, televisão e outros) que os participantes preferem para ouvir música, as principais plataformas de

Tabela 16 – Distribuição dos participantes em cada grupo de experimento.

Participantes	Grupo	Plataforma
1	Grupo A - Carro/Feliz	Deezer
2		Deezer
3		Spotify
4		Spotify
5		Spotify
6	Grupo B - No Trabalho/Triste	Deezer
7		Deezer
8		Deezer
9		Spotify
10		Spotify

## 4.2 Condução

O estudo foi realizado em novembro de 2021 e conduzido ao longo de 15 dias de acordo com a disponibilidade de cada participante. Antes de iniciar o estudo, foi enviado a cada participante um link para uma sala online na plataforma Google Meet<sup>1</sup>, onde seria realizada a pesquisa. A pesquisa foi conduzida usando a plataforma Google Meet. Ao acessar a sala virtual, foi dada uma breve explicação sobre cada etapa do estudo. Além disso, todas as interações dos participantes foram gravadas em vídeo.

Durante as avaliações das ferramentas, o protocolo Think Aloud (SOMEREN; BARNARD; SANDBERG, 1994) foi utilizado, que consiste no usuário expressar suas ideias em voz alta enquanto explora as ferramentas. Portanto, antes de iniciar o estudo, o protocolo foi explicado aos participantes. Adicionalmente, os participantes foram instruídos a comentar sobre qualquer tomada de decisão durante a interação com a ferramenta.

Em seguida, foi entregue aos participantes o formulário de tarefas, no qual cada tarefa do estudo foi descrita (ver Tabela 15). O formulário permitiu ao usuário visualizar apenas

<sup>1</sup> <https://meet.google.com>

uma tarefa de cada vez, e sempre que completavam a tarefa na ferramenta, o usuário voltava ao formulário e marcava a tarefa como concluída, parcialmente concluída ou não concluída.

Nas Tarefas 2, 4 e 5, as músicas selecionadas pelo usuário vieram apenas das recomendações da plataforma. Portanto, no final dessas tarefas, os participantes foram instruídos a responder ao questionário SAM, marcando a alternativa que melhor representasse seu grau de satisfação, motivação e sensação de controle em relação às recomendações oferecidas pela plataforma.

Quando os participantes concluíram as Tarefas 1, 2 e 3, foi perguntado ao participante se alguma música adicionada à sua playlist pertencia ao seu gênero favorito. Se nenhuma música foi adicionada à sua playlist, então a Tarefa 4 foi mostrada. O tempo necessário para completar as tarefas variou de 15 a 30 minutos. Finalmente, o pesquisador agradeceu aos voluntários pela participação.

### 4.3 Análise

A avaliação de cada participante foi gravada, e os vídeos das gravações foram assistidos pelo menos duas vezes para codificar as falhas de comunicação com a plataforma. O estudo gerou 4 horas e 38 minutos de gravação. A organização dos dados, por sua vez, foi realizada com a ajuda do software Atlas-Ti<sup>2</sup>. Não houve transcrição das falas dos participantes para o Atlas.Ti, mas sim a inserção de tags ao longo dos vídeos.

O passo de rotulagem foi realizado conforme sugerido pelo método MAC durante a análise. O passo de codificação seguiu uma abordagem de codificação aberta e fechada. A codificação aberta visa desmembrar os dados e rotulá-los com códigos que permitem ao pesquisador comparar e contrastar eventos semelhantes em seus dados continuamente (CORBIN; STRAUSS, 1990; BANDEIRA-DE-MELLO, 2006). A codificação fechada identifica e marca itens relevantes usando um esquema de codificação preestabelecido (SALDAÑA, 2021). Alguns dos códigos que surgiram da codificação aberta são semelhantes ao MAC. No entanto, a codificação aberta forneceu rótulos que conferem maior significado aos termos do domínio dos sistemas de recomendação de música. Essa aderência aos termos permite que os resultados da codificação fechada sejam complementares aos resultados da codificação aberta, o que nos ajuda a comparar eventos semelhantes com a codificação MAC.

Primeiramente, realizou-se a codificação aberta no decorrer das gravações. Em seguida, criaram-se citações usando a ferramenta Atlas de forma a identificar as dificuldades dos usuários durante a interação com a plataforma. Depois, todas as citações que criadas passaram por um processo de refinamento, e foram agrupadas por similaridade. Assim, criou-se um conjunto de 17 codificações abertas. Paralelamente à codificação aberta,

---

<sup>2</sup> <https://atlasti.com>

realizou-se a codificação fechada e aplicaram-se os 13 códigos predefinidos pelo MAC. A Tabela 17 mostra os códigos criados para a codificação aberta e fechada.

Ao quantificar o número de ocorrências por tarefa, identificou-se a possibilidade de criar uma relação entre códigos e tarefas e, conseqüentemente, uma relação entre códigos e aspectos desejáveis. Dessa forma, foi criada uma relação entre código por tarefa e tarefa por aspectos desejáveis para identificar qual aspecto é menos explorado nas plataformas.

## 4.4 Resultados e discussões

Durante a análise, foi constatada a presença de 76 rupturas na codificação aberta, com destaque para o código **O14** e a Tarefa 2, os quais apresentaram o maior número de ocorrências de falhas de comunicabilidade. Paralelamente, foram registrados 78 pontos de interrupção na codificação fechada, sendo a maioria deles relacionados ao código "Onde está?" na Tarefa 2. A partir de uma perspectiva de plataforma, ao se examinar os pontos de interrupção, pôde-se constatar, na Tabela 18, um equilíbrio de ocorrências entre o Deezer e o Spotify, indicando que ambos os aplicativos apresentam problemas de comunicabilidade similares, com 37 e 41 códigos, respectivamente.

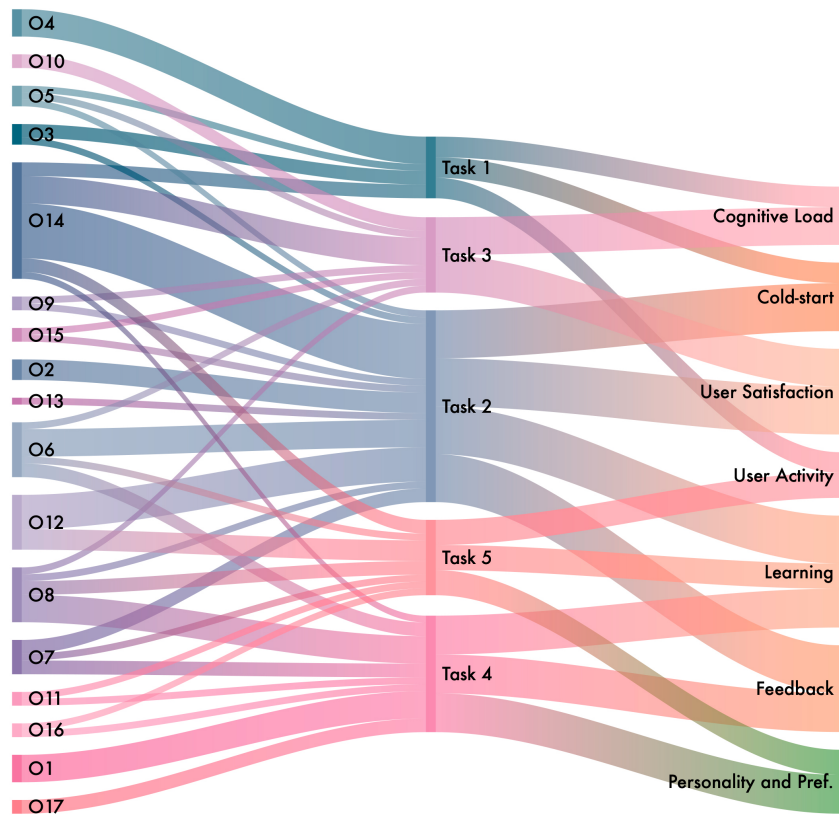
Conforme os dados apresentados nas Tabelas 17 e 18, não é possível determinar qual plataforma apresentou mais problemas de ruptura, uma vez que o número de rupturas foi semelhante. Além disso, considerando que a quantidade de rupturas entre codificação aberta e fechada se aproxima, pode-se dizer que os mesmos problemas parecem ocorrer em ambas as plataformas.

A relação entre os códigos abertos e fechados com aspectos desejáveis é apresentada por meio de um diagrama de Sankey nas Figuras 5a e 5b. Na análise dos dois diagramas de Sankey, foi observado que o aspecto mais negligenciado era *Aprendizado*, o qual possui uma forte relação com a Tarefa 2. A Tarefa 2 demonstra que existe uma grande insatisfação por parte dos usuários com as recomendações sugeridas pelas plataformas. Essa insatisfação ocorre em função da alta incidência dos códigos "Onde está?" e "Obrigado, mas não" para a codificação fechada. Da mesma forma, ocorre para os códigos "Onde estão as músicas?" e "Não gostei das recomendações." para a codificação aberta.

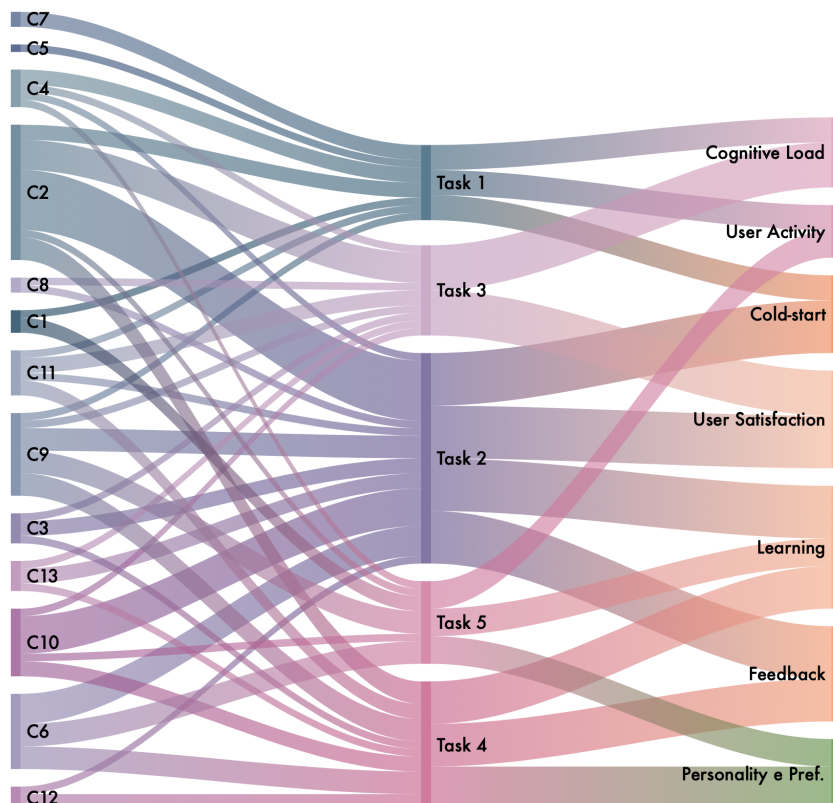
No diagrama de Sankey, um aspecto desejável é visto como menos explorado quando a altura de sua rede é maior do que a dos outros aspectos. Em resumo, observou-se uma ordem entre os aspectos menos explorados pelas plataformas. *Aprendizado* foi o aspecto mais negligenciado pelas plataformas, uma vez que vários códigos se referem à sua rede e sua altura é a mais elevada. *Atividade do Usuário* foi o menos negligenciado. Sob a perspectiva de código aberto, *Feedback* veio em segundo lugar, seguido por *Satisfação do Usuário*. Sob a perspectiva da codificação do MAC, a *Satisfação do Usuário* veio em segundo lugar, seguido por *Feedback*. Os outros aspectos seguiram a mesma ordem para ambas as perspectivas de análise. Dito isto, essa análise mostra evidências de uma ordem

Figura 5 – Codificação (aberta e fechada) x Aspectos Desejáveis.

(a) Relação entre código aberto e aspectos desejáveis



(b) Relação entre códigos fechados e aspectos



Fonte: Elaborado pelo autor



Tabela 17 – Codificação aberta e fechada (MAC) para cada tarefa.

(a) Codificação Aberta

Codificação Aberta		TAREFAS					Total
		T1	T2	T3	T4	T5	
O1	Cadê as músicas do meu gênero musical?	0	0	0	4	0	4
O2	Cadê as recomendações?	0	3	0	0	0	3
O3	Como adicionar as músicas?	2	1	0	0	0	3
O4	Como eu crio a playlist?	4	0	0	0	0	4
O5	Como renomear uma playlist?	1	1	1	0	0	3
O6	Gostei das recomendações	0	4	1	2	1	8
O7	Músicas boas, porém não	0	2	0	2	1	5
O8	Não atualiza!	0	1	1	4	2	8
O9	Não consigo terminar	0	1	1	0	0	2
O10	Não consigo lembrar	0	0	2	0	0	2
O11	Não encontro as músicas	0	0	0	1	1	2
O12	Não gostei das recomendações	0	5	0	0	3	8
O13	Nenhuma música do meu estilo	0	1	0	0	0	1
O14	Onde estão as músicas?	2	8	4	1	2	17
O15	Onde estou?	0	1	1	0	0	2
O16	Poucas recomendações boas	0	0	0	1	1	2
O17	Vou continuar buscando	0	0	0	2	0	2
<b>Total</b>		<b>9</b>	<b>28</b>	<b>11</b>	<b>17</b>	<b>11</b>	<b>76</b>

(b) Codificação do MAC

Codificação do MAC		TAREFAS					Total
		T1	T2	T3	T4	T5	
C1	Assim não dá	1	0	0	0	2	3
C2	Cadê?	2	8	4	3	1	18
C3	Desisto	0	2	1	1	0	4
C4	E agora?	2	1	1	0	1	5
C5	Epa!	1	0	0	0	0	1
C6	Não, obrigado	0	4	0	3	3	10
C7	O que é isto?	2	0	0	0	0	2
C8	Onde estou?	0	1	1	0	0	2
C9	Por que não funciona?	1	3	1	3	3	11
C10	Pra mim, está bom	0	5	1	2	1	9
C11	Socorro!	1	1	2	2	0	6
C12	Ué, o que houve?	0	1	0	2	0	3
C13	Vai de outro jeito	0	2	1	1	0	4
<b>Total</b>		<b>10</b>	<b>28</b>	<b>12</b>	<b>17</b>	<b>11</b>	<b>78</b>

Tabela 18 – Codificação aberta e fechada (MAC) para cada plataforma.

(a) Codificação Aberta

Codificação Aberta	Plataforma		Total
	Deezer	Spotify	
O1	3	1	4
O2	1	2	3
O3	0	3	3
O4	3	1	4
O5	1	2	3
O6	6	2	8
O7	4	1	5
O8	4	4	8
O9	1	1	2
O10	1	1	2
O11	0	2	2
O12	3	5	8
O13	0	1	1
O14	7	10	17
O15	0	2	2
O16	2	0	2
O17	0	2	2
<b>Total</b>	<b>36</b>	<b>40</b>	<b>76</b>

(b) Codificação do MAC

Codificação do MAC	Plataforma		Total
	Deezer	Spotify	
C1	1	2	3
C2	7	11	18
C3	3	1	4
C4	2	3	5
C5	0	1	1
C6	6	5	11
C7	2	0	2
C8	0	2	2
C9	4	6	10
C10	7	2	9
C11	2	4	6
C12	2	1	3
C13	1	3	4
<b>Total</b>	<b>37</b>	<b>41</b>	<b>78</b>

de negligência dos aspectos desejáveis.

As tarefas foram fundamentais para determinar quais aspectos desejáveis foram mais negligenciados pelas plataformas. Na Tarefa 1, os usuários tiveram que criar uma playlist e adicionar 3 músicas de acordo com o contexto definido para cada uma. Como foi a primeira interação do participante com a plataforma, neste primeiro contato, ocorreram um grande número de rupturas para os códigos "Onde está?", "E agora?", "O que é isso?", "Como posso criar a playlist?", "Como adiciono a música?" e "Como renomear uma playlist?". Em geral, o problema de Carga Cognitiva direcionou essas rupturas. Nesta tarefa, os participantes tiveram dificuldade no primeiro contato em encontrar a opção para criar uma playlist, renomear uma playlist e encontrar suas músicas. Ao procurar uma música, muitos participantes tentaram lembrar o nome da música e, quando pesquisaram pelo título, a plataforma retornou uma playlist pronta ou um álbum com apenas uma música. Essa dificuldade pode ter criado alguma confusão nas expectativas dos participantes. Por outro lado, é notável que em muitos desses códigos, especialmente os códigos O3, O4 e O5, o número de incidências diminuiu após a segunda tarefa, indicando que os participantes se adaptaram às plataformas (veja a Tabela 17).

Na Tarefa 2, os participantes não precisaram criar uma nova playlist. Os participantes foram instruídos a selecionar músicas de acordo com o contexto definido a partir das recomendações sugeridas pela plataforma. Esta tarefa mostrou que os participantes tiveram dificuldade em localizar onde estavam as músicas recomendadas pela plataforma. Esta dificuldade é justificada pela incidência dos códigos "Onde está?", "Eu desisto.", "Por que não?", "Posso fazer de outra maneira.", "Onde estão as recomendações?" e "Onde estão as músicas?".

Identificou-se a Tarefa 2 como um ponto essencial para a análise do comportamento das recomendações da plataforma após a primeira interação dos participantes. Nesta tarefa, foi possível verificar que não havia um consenso em relação à satisfação dos participantes com as recomendações sugeridas pelas plataformas. De certa forma, houve um equilíbrio de códigos com intenções opostas para participantes satisfeitos ("Eu gostei das recomendações.", "Parece bom para mim.") e insatisfeitos ("Boa música, mas não.", "Não gostei das recomendações.", "Não tem música do meu gosto pessoal.", "Obrigado, mas não.", "Por que não?") com as recomendações.

Semelhante à Tarefa 1, na Tarefa 3, os participantes foram instruídos a criar uma nova playlist e adicionar livremente 3 músicas de acordo com o estado emocional definido. Nesta tarefa, os participantes tiveram menos dificuldade em criar a playlist, mas mantiveram a dificuldade no esforço para lembrar o nome da música ou identificar as músicas ao navegar pela biblioteca da plataforma.

A Tarefa 4 visava criar uma nova playlist e adicionar 3 músicas de acordo com o gênero musical de cada participante, mas as músicas deveriam ser selecionadas a partir das recomendações sugeridas de cada plataforma. Nesta tarefa, houve mais rupturas para as recomendações da plataforma. Muitos usuários relataram dificuldade em encontrar as músicas pertencentes ao seu gênero favorito, já que tinham que navegar muito pela variedade de sugestões que a plataforma apresentava a eles. Além disso, os participantes questionaram a plataforma sobre a atualização das recomendações, já que não era perceptível que as sugestões foram atualizadas.

Finalmente, na Tarefa 5, os participantes foram instruídos a selecionar 3 músicas de acordo com o contexto e estado emocional definidos. A Tarefa 5 repete as Tarefas 1 e 3 em uma única tarefa para verificar como as plataformas evoluíram ao longo das interações dos participantes.

A partir desta Tarefa, foi notado que as dificuldades relacionadas à manipulação das ferramentas diminuíram. Contudo, não se observou uma diminuição nas rupturas como "Não atualiza!", "Não gostei das recomendações.", "Onde estão as músicas?". Isso indica que, mesmo que as plataformas tenham recebido dados da interação dos participantes com as 5 tarefas, não foi possível evitar completamente a insatisfação dos usuários com as ferramentas. Por outro lado, foi percebida uma diminuição no número de rupturas, pois na tarefa onde os participantes receberam as primeiras recomendações, o número de

rupturas foi de 28, e na última tarefa, foi de 11.

Cada plataforma possui peculiaridades em relação às versões para web, mobile e desktop. No entanto, é essencial salientar que a Deezer, diferentemente da Spotify, requer que o usuário selecione pelo menos 3 artistas ao acessar a plataforma pela primeira vez. Essa exigência permite que a plataforma possua mais dados sobre esse usuário e melhore a recomendação. Este fato foi observado na Tarefa 2, que é uma tarefa onde ocorreram as primeiras recomendações de cada plataforma. O número mais alto de rupturas nesta tarefa foi de 28, comparado às outras tarefas. As rupturas mais significativas foram os códigos ligados à insatisfação com as recomendações.

No entanto, ao analisar o código "Parece bom para mim." sob a perspectiva da plataforma (ver Tabela 18), observou-se um número maior de aceitações para a Deezer do que para a Spotify. Essa aceitação pode ter ocorrido porque a Deezer exige informações adicionais antes que o usuário interaja com a plataforma.

Grande parte dos participantes do estudo da Deezer selecionaram pelo menos 3 artistas antes de iniciar as tarefas, e apenas um participante selecionou 20 artistas na primeira interação. Este evento trouxe uma observação crucial, pois os participantes que selecionaram pelo menos 3 artistas perceberam que a plataforma estava muito presa a esses 3 artistas no início das tarefas. Portanto, os participantes receberam poucas sugestões com novidades. Em contraste, o participante que selecionou 20 artistas no início relatou ter recebido poucas recomendações ruins.

#### 4.4.1 Avaliação da experiência do usuário

A análise da percepção da Experiência do Usuário (UX) é embasada em uma abordagem holística e na interpretação do feedback fornecido pelos usuários no contexto do Método de Avaliação da Satisfação do Usuário (SAM). A Tabela 19 apresenta um resumo das dimensões do SAM e das respostas atribuídas pelos participantes em cada tarefa. Ao proceder com a avaliação e a segregação dos resultados dos participantes por plataforma, foi possível identificar um contraste evidente entre elas. Para ilustrar essas diferenças de maneira mais explícita, a Figura 6 proporciona uma comparação direta entre as duas plataformas.

Nas Tarefas 2, 4 e 5, as músicas selecionadas pelo usuário pertenciam às recomendações sugeridas em cada plataforma. Ao final de cada tarefa, os participantes foram instruídos a responder ao questionário SAM, marcando a alternativa que melhor representava seu grau de prazer, excitação e domínio em relação às recomendações da plataforma. As respostas do questionário SAM foram quantificadas com base nas marcas feitas pelos participantes. As escalas do SAM são estabelecidas em um intervalo de 1 a 9 pontos em cada uma de suas três dimensões. Entende-se que o valor 1 representa a pontuação mínima, enquanto o valor 9 corresponde à pontuação máxima. As pontuações do SAM para cada dimensão

Tabela 19 – Perfil dos participantes: Plataforma, Grupo (contexto e emoção) e Resultados do SAM: PI - Pleasure Index, AI - Arousal Index, DI - Dominance Index.

Particip.	Plataforma	Grupo	Tarefa 2			Tarefa 4			Tarefa 5		
			PI	AI	DI	PI	AI	DI	PI	AI	DI
P1	Spotify	Dirigindo/ Feliz	4	4	4	8	8	8	7	8	7
P2	Spotify	Dirigindo/ Feliz	3	3	3	1	5	1	1	5	1
P3	Spotify	Dirigindo/ Feliz	5	8	6	4	5	5	7	8	7
P4	Spotify	Trabalhando/ Triste	4	7	6	8	7	6	9	8	7
P5	Spotify	Trabalhando/ Triste	5	6	7	7	7	8	7	7	8
P6	Deezer	Dirigindo/ Feliz	9	9	9	9	9	9	9	9	9
P7	Deezer	Dirigindo/ Feliz	8	9	3	8	9	4	6	8	3
P8	Deezer	Trabalhando/ Triste	1	5	1	9	8	6	9	8	8
P9	Deezer	Trabalhando/ Triste	4	7	4	6	7	7	8	8	7
P10	Deezer	Trabalhando/ Triste	7	9	9	7	8	9	9	9	8

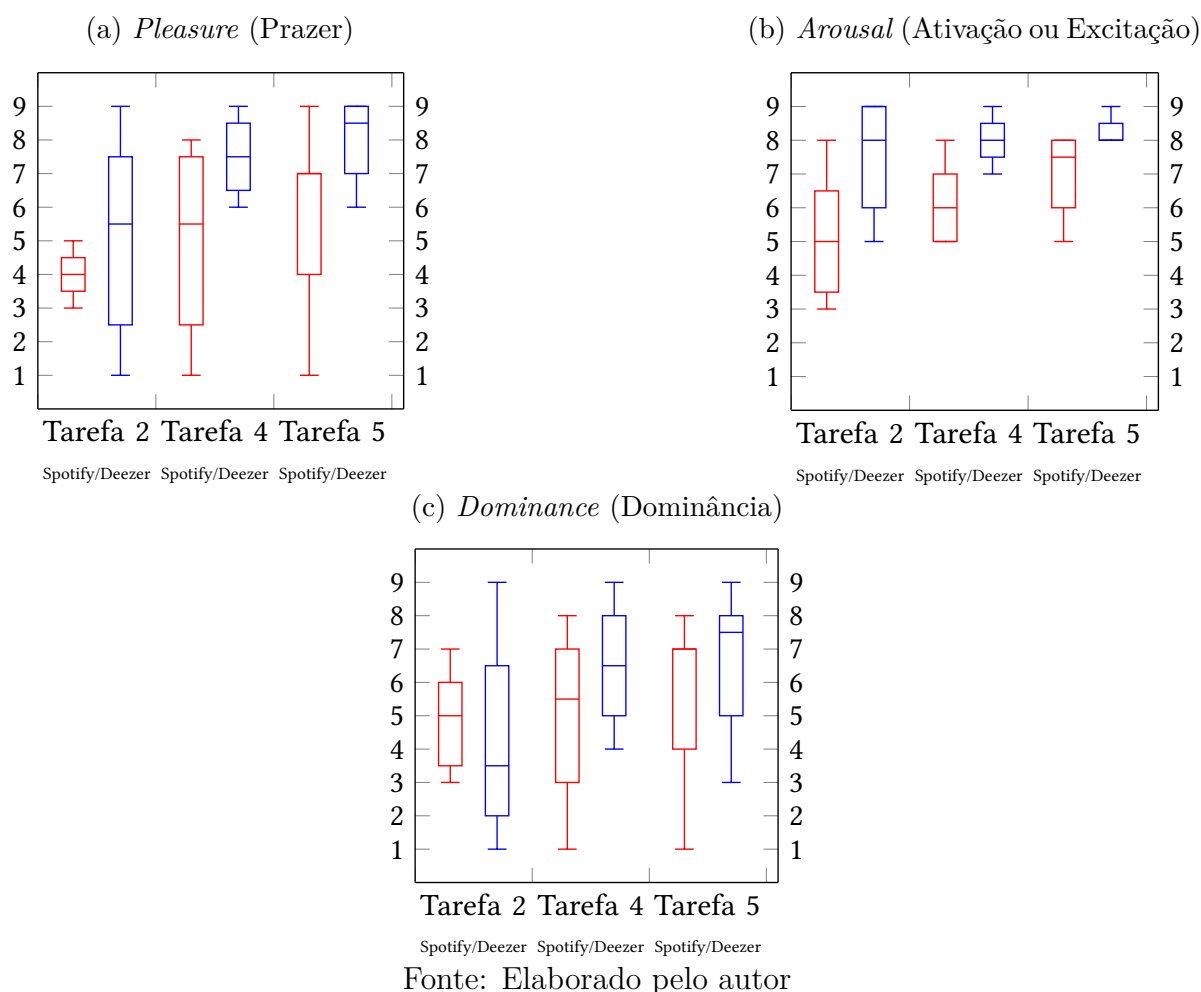
são ilustradas da seguinte forma: a dimensão do prazer na Figura 6a, a dimensão da excitação na Figura 6b e a dimensão de dominância na Figura 6c.

Ao associar os resultados da Tabela 1 e da Figura 2, mais precisamente para a plataforma Spotify, observou-se uma média baixa para o índice de prazer nas Tarefas 2 e 4. Esta média baixa é consequência das muitas falhas de comunicabilidade codificadas para ambas as tarefas. O valor mais baixo foi indicado por [P2]. Após uma revisão das gravações, foi identificado que o participante [P2] demonstrou considerável dificuldade em localizar as sugestões de músicas na plataforma. Esta situação foi observada tanto na tarefa inicial quanto nas Tarefas 4 e 5.

Por outro lado, o participante [P6] indicou a pontuação mais alta durante a avaliação em todas as tarefas. Novamente, após as revisar a gravação do participante, foi notado que o participante relatou que estava acostumado a usar a ferramenta durante a vida cotidiana. Essa familiaridade com a ferramenta levou à maior pontuação para a Deezer em todos os domínios do SAM.

Foi observado que os índices mais baixos corresponderam ao prazer, excitação e domínio na Tarefa 2. Ao analisar-se os índices das dimensões do SAM unicamente sob a

Figura 6 – Resultados do questionário SAM aplicados às Tarefas 2, 4 e 5 - Vermelho para Spotify e Azul para o Deezer.



perspectiva da plataforma, verificou-se que, nas avaliações do Deezer, os índices excederam os valores observados no Spotify. De forma geral, foi constatado que, na Tarefa 5, o valor médio do índice superou 7 para ambas as plataformas e todos os domínios avaliados. Conforme os participantes interagem com as plataformas e novas tarefas eram apresentadas, uma maior familiaridade com as ferramentas foi sendo desenvolvida. Adicionalmente, as ferramentas foram capazes de compreender de maneira eficaz as preferências dos participantes.

Detectou-se que falhas como "Não atualiza!", "Onde estão as músicas?" e "Como posso criar a playlist?" impactaram na experiência do usuário. Os participantes P2 e P7 relataram que o sistema parecia não realizar atualizações. Nenhum indicador visual que sinalizasse alguma ação de atualização do estado do sistema foi percebido por eles. O participante P3 teve sua experiência afetada pela carga cognitiva, uma vez que necessitou de um grande esforço mental para identificar onde estavam localizadas as recomendações para as peças musicais, visto que somente conseguia encontrar recomendações para playlists. Além disso, as falhas de comunicação relacionadas às recomendações musicais nas

primeiras tarefas tiveram um impacto na experiência do usuário. Os resultados do SAM revelaram que houve uma insatisfação dos participantes com as primeiras sugestões de músicas recebidas da plataforma.

## 4.5 Considerações finais

Neste estudo, procurou-se entender a experiência do usuário nas plataformas de recomendação musical Spotify e Deezer. Diante deste reconhecimento, tomou-se a iniciativa de verificar como as plataformas atendem aos aspectos desejáveis. Foi analisada a interação dos ouvintes de música em ambas as plataformas e verificado como a experiência do usuário se relaciona com os aspectos.

Realizou-se uma análise qualitativa utilizando MAC e SAM com 10 participações. Os resultados da análise para codificação aberta e fechada mostraram que os aspectos desejáveis não são suficientemente considerados pelos métodos de recomendação das duas plataformas, uma vez que o número de falhas de comunicação foi semelhante entre ambas. O aspecto *Aprendizado* foi o mais negligenciado. Os sistemas de recomendação negligenciaram os aspectos seguindo quase a mesma ordem para ambas as plataformas. Os resultados dos questionários SAM, por outro lado, mostram que a satisfação, a motivação e o sentimento de controle durante as recomendações sugeridas pelas plataformas foram obtendo melhores avaliações à medida que as tarefas avançavam. Além disso, a plataforma Deezer obteve melhores avaliações em comparação com o Spotify.

Este estudo discute como as falhas de comunicação podem afetar a experiência do usuário em sistemas comerciais de recomendação de música quando são incorporados aspectos além da precisão do algoritmo. Implicações significativas foram demonstradas para a melhoria da experiência do usuário no projeto de sistemas de recomendação de música. Quando os sistemas abordam múltiplos aspectos (por exemplo, feedback, satisfação, aprendizado e outros) do usuário e os avaliam além da precisão do algoritmo, os sistemas de recomendação melhoram a experiência de escuta do usuário.

A relação entre os resultados obtidos pelo MAC e a arquitetura UConteXt Arch é estabelecida através da identificação de falhas de comunicação que diretamente influenciam os componentes de recomendação musical da arquitetura. As rupturas como 'Não atualiza!' e 'Onde estão as músicas?' evidenciaram a necessidade de módulos de serviço mais intuitivos e interfaces de usuário que comuniquem claramente as atualizações do sistema e o status das recomendações. Estas observações foram cruciais para a concepção do módulo de predição adaptativa e do gerenciador de recomendações na UConteXt Arch, demonstrando a aplicabilidade direta dos resultados do MAC na arquitetura proposta.

Os rótulos adicionais desenvolvidos neste estudo foram concebidos para se alinhar intimamente com os desafios específicos encontrados nas plataformas de streaming de música. As falhas de comunicação identificadas através do MAC e os rótulos correspondentes for-

neceram compreensões diretas para o aprimoramento da arquitetura UConteXt Arch. Por exemplo, uma falha comum identificada foi a inadequação das recomendações musicais em relação ao contexto atual do usuário, o que ressaltou a necessidade de um módulo de contexto e preferências musicais mais robusto.

Além disso, o feedback dos usuários sobre a dificuldade em fornecer avaliações explícitas para as músicas recomendadas ressaltou a necessidade de um sistema de feedback mais intuitivo e acessível. Isto levou à integração de um mecanismo de feedback aprimorado na camada de interface da UConteXt Arch, que permite aos usuários fornecer suas preferências de forma mais natural e menos intrusiva. O módulo de recálculo de recursos de áudio foi refinado para responder dinamicamente às interações do usuário, ajustando as recomendações em tempo real para refletir mudanças nas preferências ou no contexto do usuário. Por fim, a análise do MAC, fundamentou a configuração de uma arquitetura que visa otimizar a experiência do usuário ao interagir com recomendações musicais contextualmente relevantes.



---

## Capítulo 5

# UConteXt Arch: Uma Arquitetura para Recomendação Musical Baseada em Contexto e Experiência do Usuário

---

*Este capítulo representa a culminação de várias iterações do ciclo de design. Inicialmente, a arquitetura foi concebida em um estado teórico. Posteriormente, duas iterações de desenvolvimento e testes foram realizadas, cada uma resultando em refinamentos significativos dos módulos e da integração dos componentes, baseados em feedback iterativo e avaliações técnicas.*

Os sistemas de recomendação musical atuais, embora avançados, enfrentam o desafio de alinhar as recomendações musicais com o contexto e as experiências recentes do usuário (VELANKAR; KULKARNI, 2023; XU; GAN; ZHANG, 2023; ASSUNCAO; PICCOLO; ZAINA, 2022). Essa lacuna entre a capacidade atual dos sistemas e as necessidades dinâmicas dos usuários destaca a necessidade de uma nova arquitetura. A UConteXt Arch surge como uma resposta a essa necessidade, oferecendo uma estrutura que integra de maneira mais efetiva o contexto do usuário e suas experiências recentes com as recomendações musicais.

Enquanto a precisão dos algoritmos é essencial, ela não é suficiente por si só para garantir a satisfação do usuário. A UConteXt Arch busca ir além, incorporando uma abordagem centrada no usuário que considera não apenas suas preferências musicais, mas também seu contexto e experiências recentes, aspectos frequentemente negligenciados

nas arquiteturas existentes (HUO, 2021; SUN, 2022b). Pesquisas recentes, incluindo Assuncao, Piccolo e Zaina (2022), enfatizam a importância de uma abordagem mais centrada no usuário, levando em conta elementos como contexto do usuário, preferências e experiências recentes.

Este capítulo introduz a UConteXt Arch, uma proposta para preencher essa lacuna, fornecendo uma solução que é ao mesmo tempo robusta e adaptável, capaz de personalizar recomendações de música de forma eficaz e alinhada com as necessidades e o contexto do usuário. A UConteXt Arch é estruturada em camadas e módulos, cada um com um objetivo específico, visando a eficiência na entrega de uma experiência musical personalizada.

A arquitetura, ilustrada na Figura 7, distingue entre componentes essenciais (Camadas de Middleware, Serviços e Dados) e aqueles adaptáveis (Camada de Interface), permitindo uma integração facilitada com plataformas comerciais de música. A área delimitada pela linha tracejada com o fundo azul na ilustração representa os componentes integrantes da arquitetura UConteXt Arch. A área com linha tracejada e fundo cinza indica as plataformas de streaming de música comerciais, as quais podem ser integradas com facilidade à arquitetura

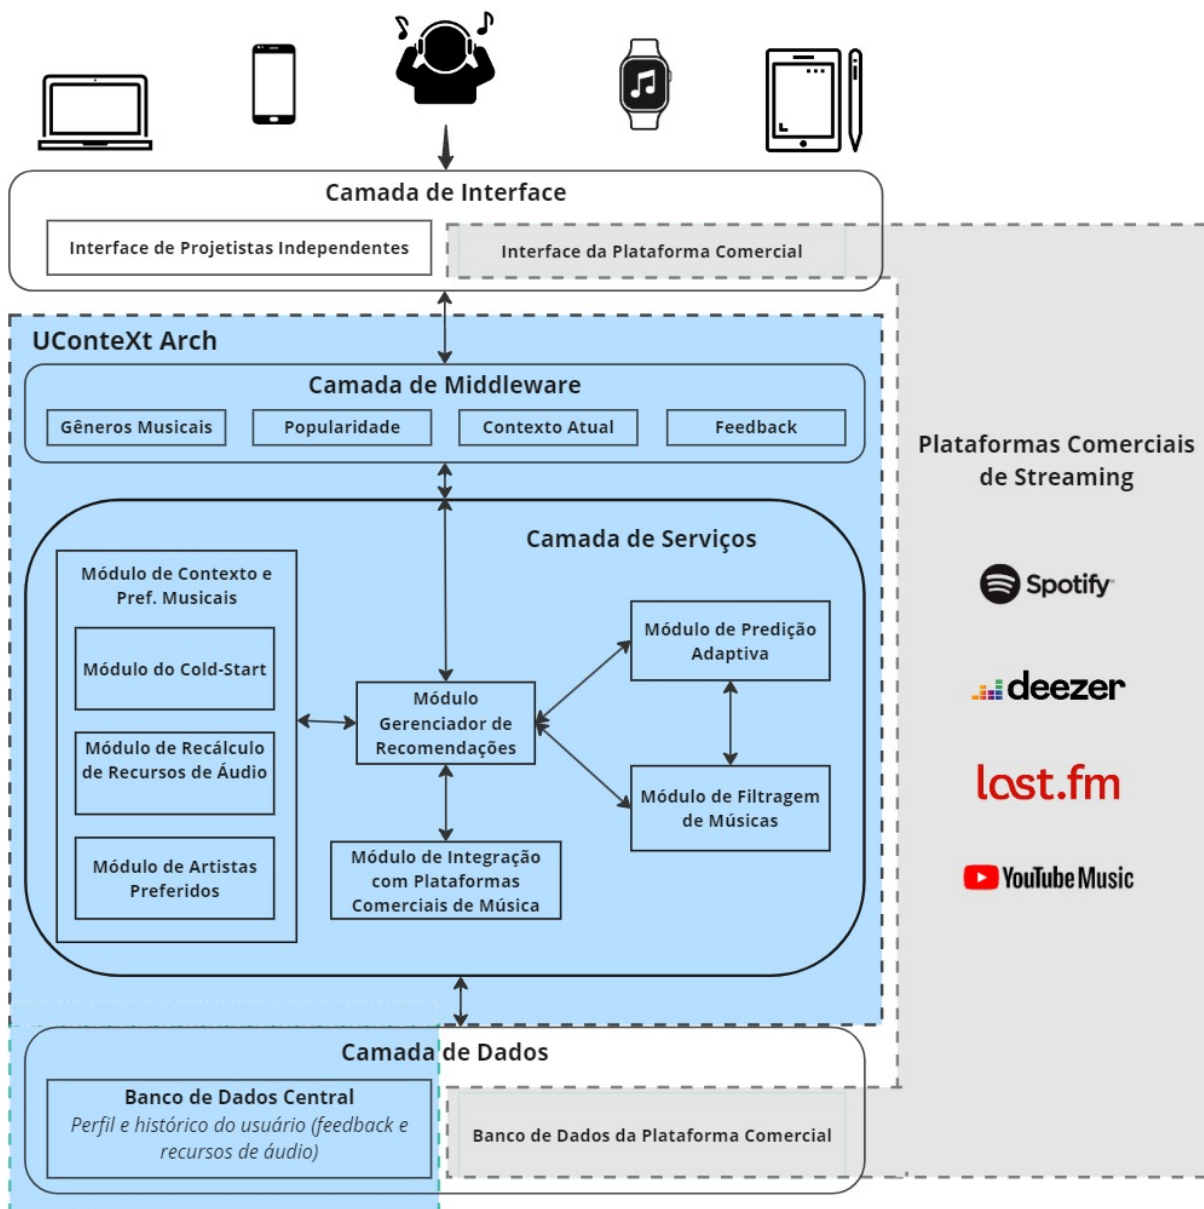
No detalhamento gráfico da arquitetura UConteXt Arch, os elementos com bordas arredondadas simbolizam as camadas do sistema, enquanto os elementos com bordas retas representam os módulos. As conexões diretas entre estes elementos são indicadas por setas sólidas. A arquitetura UConteXt Arch é descrita como uma estrutura tanto robusta quanto clara, oferecendo também flexibilidade para adequação às necessidades singulares de cada projeto implementado.

## 5.1 Visão geral da arquitetura

A arquitetura UConteXt Arch é estruturada de maneira a promover uma integração com sistemas de recomendação de música ou plataformas já existentes. O desenho da arquitetura inclui uma Camada de Interface, que, embora não faça parte da proposta principal, é representada para ilustrar a interação usual dos usuários com o sistema através de interfaces já existentes. Nesta camada, os elementos comuns que coletam a entrada para o processo de recomendação incluem: interfaces de usuário para coleta de feedback direto, sensores para detecção do contexto atual (como localização e horário), sistemas de análise de tendências para identificar a popularidade das músicas e algoritmos de classificação para determinar gêneros musicais com base nas escolhas dos usuários.

Estes elementos, já implementados pelas Plataformas Comerciais de Música, são fundamentais para personalizar as recomendações musicais de acordo com as preferências e contextos dos usuários. Ao incorporar a UConteXt Arch, plataformas comerciais podem manter suas interfaces de usuário inalteradas e integrar-se efetivamente à Camada de Middleware, que processa as informações coletadas e as transmite para a Camada de

Figura 7 – Visão geral da Arquitetura



Fonte: Elaborada pelo próprio autor.

Serviços.

As Plataformas Comerciais de Música desempenham um papel fundamental como mediadoras entre o sistema de recomendação e a extensa biblioteca de músicas disponíveis online. É importante ressaltar que existe uma interdependência intrínseca entre a arquitetura proposta e as Plataformas Comerciais de Música, especificamente com o módulo do Cold-start, que será explorado na Seção 5.4.2.

A primeira camada substancial da arquitetura é a Camada de Middleware, que atua como elo entre a interface do usuário e as operações mais avançadas encontradas nas camadas subsequentes. Essa camada processa e transmite as informações capturadas na Camada de Interface para a Camada de Serviços, garantindo que as preferências e o

feedback dos usuários sejam considerados na geração de recomendações musicais.

A Camada de Serviços é o núcleo operacional da arquitetura. Ela é composta por cinco módulos: Gerenciador de Recomendações, Predição Adaptativa, Filtragem de Músicas, Integração com Plataformas Comerciais de Música e o Módulo de Contexto e Preferências Musicais. Este último é composto por três submódulos: Módulo do Cold-start, Recálculo de Recursos de Áudio e Artistas Preferidos. Esses submódulos atuam na compreensão do contexto atual do usuário com base no feedback contínuo do usuário. Eles serão abordados com mais profundidade nas seções subsequentes.

Por fim, A Camada de Dados é o repositório central para o armazenamento de todas as informações pertinentes. Ela é composta por dois módulos principais: o Banco de Dados Central e o Banco de Dados da Plataforma Comercial. Esta camada funciona como o núcleo para a persistência do histórico do usuário, incluindo as interações, feedbacks e preferências musicais. O Banco de Dados Central se adapta a diferentes estruturas de dados, o que é essencial para integrar informações de diversas plataformas de streaming, como Spotify, Deezer, e outras. A arquitetura foi concebida para ser agnóstica à fonte dos dados, incorporando um mecanismo de tradução e mapeamento que unifica as estruturas de dados heterogêneas. Essa abordagem permite que o Módulo de Integração com Plataformas de Música, por exemplo, traduza e forneça dados de metadados musicais que são compatíveis com o esquema do banco de dados, assegurando que os processos de recomendação sejam alimentados por dados atualizados e relevantes. A arquitetura contempla, assim, não só a armazenagem mas também o processamento e a análise do histórico do usuário, o que permite que a Camada de Serviços realize predições e recomendações adaptativas baseadas em um entendimento profundo das preferências e comportamentos do usuário ao longo do tempo. Isso é evidenciado pela interação dinâmica entre o Banco de Dados Central e os módulos como Recálculo de Recursos de Áudio e Predição Adaptativa, que juntos, garantem que o histórico do usuário seja aplicado de maneira a refinar as recomendações musicais para uma experiência personalizada.

Em relação a escalabilidade, arquitetura permite que novas variáveis sejam incorporadas ao processo de recomendação de maneira sistemática e controlada. Por exemplo, se deseja-se introduzir uma nova variável, como 'emoção' ou 'tempo', na recomendação, pode-se adicionar um novo módulo de 'Análise de Sentimento' ou 'Previsão Climática' respectivamente, que interage com a Camada de Serviços. Cada módulo da UConteXt Arch opera com um alto grau de independência, comunicando-se com outros módulos por meio de interfaces definidas. Isso significa que a adição de uma nova variável envolve o desenvolvimento de um novo módulo que processa essa variável e a implementação de um protocolo de comunicação para que ele possa fornecer suas saídas para o Módulo Gerenciador de Recomendações. Além disso, o esquema flexível do Banco de Dados Central permite que novos dados podem ser facilmente armazenados e integrados aos processos existentes de recomendação.

Na prática, escalar a arquitetura para incorporar novas variáveis de recomendação ou métodos envolve três etapas principais: desenvolvimento de um novo módulo ou adaptação de um existente para processar a nova variável, integração do novo módulo ao ecossistema UConteXt Arch através de interfaces de comunicação e atualização do Banco de Dados Central para armazenar e recuperar dados relacionados à nova variável.

## 5.2 Camada de Interface

A Camada de Interface é reconhecida como o portal através do qual os usuários interagem com mecanismos de recomendação (FREZZO; BEHRENS; MISLEVY, 2010). Sua importância em estabelecer uma comunicação transparente entre o usuário e o sistema, bem como sua capacidade de gerar respostas funcionais e interagir com o plano de fundo do sistema, é evidente em várias literaturas (REN; MA; WANG, 2016; SUN, 2022a; SUN, 2023; FREZZO; BEHRENS; MISLEVY, 2010).

Nesta arquitetura, ela não é uma parte integral da arquitetura proposta, mas é fundamental para garantir uma comunicação fluida entre o usuário e o sistema de recomendação. Nesta camada, os usuários podem expressar suas preferências, receber sugestões musicais e fornecer feedback, criando assim uma experiência musical dinâmica e personalizada.

A arquitetura distingue dois módulos de interface principais: a *Interface de Projetistas Independentes* e a *Interface da Plataforma Comercial*. A primeira é concebida para desenvolvedores, projetistas de sistemas de recomendação musicais ou entidades que desejam criar e integrar suas próprias interfaces com a arquitetura proposta. A segunda é projetada para integrar plataformas musicais comerciais já estabelecidas, como Spotify ou Deezer, com a arquitetura proposta.

Importante notar que, dependendo do cenário de implementação, apenas um destes módulos seria empregado. Por exemplo, se uma plataforma comercial adota a arquitetura, ela utilizaria a *Interface da Plataforma Comercial*, eliminando a necessidade da Interface de Projetistas Independentes, e vice-versa.

A responsabilidade de implementar e gerenciar essas interfaces recai sobre os implementadores da arquitetura. Essas interfaces capturam informações cruciais, como o gênero musical do usuário, o nível de popularidade da música atual, o contexto atual do usuário (determinado de forma subjetiva ou automática) e o feedback do usuário. Essas informações são então transmitidas à Camada de Middleware da arquitetura proposta.

## 5.3 Camada de Middleware

Uma camada de middleware é comumente usada na arquitetura de sistemas para integrar diferentes partes do sistema ou conectar camadas (TERZIS et al., 2005; JRAD; AHMED; SUNDARAM, 2013; ALI et al., 2022). Nesta arquitetura, a Camada de Mid-

dleware é responsável por conectar a interface do usuário à Camada de Serviços, facilitando a comunicação e o processamento de dados entre essas camadas. Ela abriga quatro módulos importantes: Feedback, Gêneros Musicais, Popularidade e Contexto Atual do Usuário.

O módulo de Feedback coleta avaliações dos usuários sobre as recomendações. O módulo de Gêneros Musicais ajuda a categorizar as preferências musicais dos usuários. O módulo de Popularidade observa a aceitação coletiva das músicas. E o módulo de Contexto Atual do Usuário interpreta o cenário atual do usuário para fornecer recomendações mais personalizadas.

Esses módulos são essenciais para garantir um fluxo de dados eficiente e para ampliar a funcionalidade do sistema de recomendação musical. As seções subsequentes apresentam cada um dos módulos mencionados, elucidando suas funções e como eles contribuem para a eficácia do sistema de recomendação.

### 5.3.1 Módulo de Feedback

**Objetivo:** O objetivo do Módulo de Feedback é coletar e analisar o feedback dos usuários sobre as recomendações musicais fornecidas, utilizando este como base para o aprendizado contínuo do sistema sobre as preferências do usuário.

**Fundamentação:** A incorporação de feedback do usuário é uma prática recomendada para sistemas de recomendação, sendo associada à melhoria da precisão e personalização das sugestões (SINHA; GLEICH; RAMANI, 2017). Conforme apontado por Barnawal et al. (2017), feedback textual é repleto informações qualitativas valiosas que podem oferecer insights sobre nuances que simples classificações numéricas podem não capturar.

A importância de capturar feedback detalhado vai além da simples coleta de avaliações. Ao combinar feedback implícito, tags e descrições textuais de músicas, um novo conjunto de dados pode ser criado para replicar as condições de um cenário típico de recomendação musical, melhorando assim a granularidade e a precisão das recomendações (ORAMAS et al., 2016).

**Comportamento:** Inicialmente, o Módulo de Feedback recebe a entrada dos usuários através da interface, requerendo informações numéricas e textuais que são padronizadas para assegurar compatibilidade com o sistema. A integração deste feedback no ciclo de recomendação permite ajustes contínuos e refinamento das sugestões musicais, aumentando a precisão e a satisfação do usuário.

O módulo foi projetado para ser flexível e permitir uma variedade de mecanismos de feedback, incluindo avaliações em uma escala de quatro pontos. No entanto, a conformidade com um formato padrão é exigida para garantir uma comunicação com outros módulos do sistema. Esse formato padrão inclui um valor numérico e um feedback textual. O valor numérico fornece uma avaliação geral da recomendação, enquanto o feedback textual pode fornecer informações mais detalhadas sobre as preferências do usuário. A

conformidade com este formato é exigida da camada de interface, garantindo assim uma comunicação consistente com o módulo de feedback na camada de middleware.

Após o recebimento, o feedback é processado e direcionado para a camada de serviços de forma eficiente. Isso garante que as informações valiosas contidas no feedback sejam utilizadas prontamente para refinar as recomendações subsequentes, alinhando-as com as preferências evolutivas do usuário. Esse processo de integração em tempo real é considerado essencial para a eficácia dos sistemas de recomendação, conforme destacado por Gong et al. (2020).

Além disso, o módulo mantém um registro do feedback processado e analisa o impacto do mesmo sobre a qualidade das recomendações. Isso permite avaliações iterativas sobre a eficácia do mecanismo de feedback em melhorar a precisão das recomendações.

O Algoritmo 1 ilustra a estrutura e o funcionamento do Módulo de Feedback dentro da arquitetura proposta. Este módulo coleta e transmite o feedback do usuário para a Camada de Serviços, onde o feedback é processado e utilizado para refinar continuamente o sistema de recomendação.

A primeira etapa no fluxo de operações deste módulo é a recepção do feedback do usuário através da função *ReceberFeedbackDaInterface()*. O feedback recebido deve estar em um formato padrão, que inclui uma avaliação numérica, um comentário textual e um identificador único para a música que está sendo avaliada.

Após o recebimento do feedback, a sua validade é verificada. Caso o feedback não esteja no formato padrão, um erro é tratado, que pode envolver o registro do erro e/ou o envio de um alerta. Se o feedback for válido, ele é encaminhado para a Camada de Serviços através da função *EncaminharFeedbackParaCamadaDeServicos(feedback)*, onde será processado e armazenado. A função também trata de qualquer falha na transmissão do feedback, garantindo que os erros sejam devidamente tratados e registrados.

### 5.3.2 Módulo de Gêneros Musicais

**Objetivo:** Este módulo tem o propósito de categorizar conteúdo musical através de gêneros, facilitando a personalização inicial e a superação do desafio de cold-start, especialmente para novos usuários na plataforma.

**Fundamentação:** A integração de gêneros musicais neste módulo é uma estratégia deliberada respaldada pela literatura científica, que historicamente tem utilizado gêneros como uma maneira de categorizar e personalizar conteúdo musical (SILVER; LEE; CHIL-DRESS, 2016; MANKEL; BARBER; BIDELMAN, 2020). A inclusão de uma escolha inicial de gêneros é crucial, como apontado por Anwaar et al. (2018), pois oferece uma solução prática ao desafio de cold-start, especialmente ao considerar novos usuários em uma plataforma.

A estratégia incorporada neste módulo se baseia em um conjunto de gêneros reconhecido globalmente. A personalização é otimizada quando os sistemas oferecem opções

---

**Algoritmo 1:** Módulo de Feedback

---

```

Estrutura Feedback {
    Int valorNumerico; // Avaliação numérica, por exemplo, escala de 1 a 4
    String comentarioTexto; // Feedback textual do usuário
    String identificadorMusica; // Identificador único da música
}
Função InicializarModuloDeFeedback()
    // Aguarda a recepção do feedback da Camada de Interface
    while verdadeiro do
        | feedback ← API.ReceberFeedback()
        | if feedback ≠ nulo then
            | EncaminharFeedbackParaCamadaDeServicos(feedback)
        | end
        | Esperar(intervaloDeAtualizacao)
    end
Fim
Função ReceberFeedbackDaInterface()
    // Supondo uma função de API que recebe o feedback da Camada de
    Interface
    feedback ← API.ReceberFeedback()
    if feedback não segue o formato padrão then
        | // Tratar erro, possivelmente logar e/ou enviar alerta
        | return nulo
    end
    return feedback
Fim
Função EncaminharFeedbackParaCamadaDeServicos(feedback)
    // Supondo uma função de API que envia o feedback para a Camada
    de Serviços
    sucesso ← API.EncaminharFeedback(feedback)
    if not sucesso then
        | // Tratar erro, possivelmente logar e/ou enviar alerta
    end
Fim

```

---

estruturadas e flexíveis (RAJESWARI; HARIHARAN, 2016). Além disso, o módulo é adaptável regionalmente, permitindo ajustes na seleção de gêneros com base na popularidade local. Essa ênfase na adaptabilidade regional é apoiada pela observação de (KNEES; SCHEDL, 2013), que destaca a importância de sistemas de recomendação serem culturalmente adaptativos e conscientes.

**Comportamento:** Este módulo define um tipo de dado chamado *GeneroMusical*, que contém dois campos: nome e tipo. O campo nome armazena o nome do gênero musical, como "Rock" ou "Jazz", enquanto o campo tipo indica se o gênero é global ou local. Uma lista, nomeada *generosMusicais*, é usada para armazenar os objetos de *GeneroMusical*. Esta lista serve como um repositório centralizado para todos os gêneros musicais



reconhecidos, facilitando o acesso e a manipulação dos gêneros ao longo do código.

É importante notar que o Algoritmo 2 apresentado está simplificado, mostrando apenas a estrutura básica do módulo. O comportamento das demais funções é semelhante ao do módulo de feedback, para evitar redundâncias e facilitar a compreensão.

---

**Algoritmo 2:** Módulo de Gêneros Musicais

---

```
Estrutura GeneroMusical {  
    String nome; Nome do gênero musical, por exemplo: "Rock", "Pop", "Jazz"  
    String tipo; Tipo do gênero musical, por exemplo: "Global"ou "Local"  
}  
Lista<GeneroMusical> generosMusicais;
```

---

As escolhas iniciais de gênero musical são benéficas para o usuário e o sistema. Jin et al. (2019) afirmam que oferecer aos usuários um senso de controle desde o início pode aumentar sua confiança no sistema, o que é essencial para a satisfação do usuário (AFCHAR et al., 2022). Além disso, a experiência de escuta é enriquecida quando os usuários sentem que suas preferências são priorizadas, como observado por Millecamp et al. (2018) em seu estudo sobre o engajamento do usuário em plataformas de streaming.

Este módulo adota uma estratégia de distinguir entre gêneros globais e locais para permitir uma adaptação regional. Essa ênfase na adaptabilidade regional é respaldada pela literatura, que afirma que as recomendações devem ser culturalmente relevantes e precisas Zangerle, Pichl e Schedl (2020).

A implementação deve garantir que a lista de gêneros musicais seja populada de forma adequada durante a inicialização, seja a partir de uma fonte externa ou definida manualmente. Além disso, é fundamental que os gêneros definidos neste módulo sejam mapeados para os gêneros reconhecidos na plataforma de música comercial integrada. Isso pode ser feito em um módulo posterior na camada de serviços, garantindo que os gêneros selecionados pelos usuários sejam mapeados corretamente para os gêneros na plataforma de música, permitindo a recomendação precisa de músicas.

Este módulo, portanto, forma a base para a personalização inicial das recomendações musicais, facilitando a interação do usuário com o sistema e permitindo que o sistema adquira um entendimento inicial das preferências do usuário.

### 5.3.3 Módulo de Popularidade

**Objetivo:** O Módulo de Popularidade tem como finalidade incorporar a métrica de popularidade de faixas musicais para enriquecer o processo de recomendação, proporcionando aos usuários recomendações que considerem tanto as tendências atuais quanto suas preferências individuais.

**Fundamentação:** A popularidade é uma métrica amplamente reconhecida que reflete a aceitação de uma faixa musical pelo público e é usada para prever o sucesso de

músicas em diferentes audiências (KARYDIS; GKIOKAS; KATSOUROS, 2016). O controle da popularidade nas recomendações fortalece a autonomia do usuário e personaliza a experiência, aumentando a satisfação e o engajamento (Wischenbart, 2020; Warriner, 2017).

Dar aos usuários a opção de ajustar a popularidade das faixas que desejam ouvir é apoiado pela pesquisa sobre autonomia do usuário e personalização. Wischenbart et al. (2020) afirmam que dar aos usuários mais controle sobre os parâmetros de recomendação pode levar a maior satisfação e engajamento. O controle direto sobre a popularidade, como um controle deslizante, é uma implementação prática dessa ideia. De fato, a pesquisa de Warriner et al. (2017) sugere que os controles deslizantes são uma forma intuitiva de interação com os usuários.

O Spotify já oferece controle sobre a popularidade das faixas. Isso reforça a adoção desta prática na indústria e inspirou o módulo de popularidade da arquitetura proposta. Conforme discutido por Millecamp et al. (2018), plataformas de streaming líderes frequentemente estabelecem padrões que influenciam o design de sistemas emergentes. Assim, a arquitetura se posiciona como relevante no cenário atual de streaming de música ao incorporar esta prática.

**Comportamento:** Compreendendo a importância da popularidade na recomendação de músicas, o Módulo de Popularidade é concebido para incorporar esse aspecto importante na arquitetura proposta. Como ilustrado no Algoritmo 3, este módulo é estruturado para receber, armazenar e fornecer a preferência de popularidade indicada pelo usuário, que será utilizada posteriormente pelo módulo gerenciador de recomendações na camada de serviços.

---

**Algoritmo 3:** Módulo de Popularidade

---

**Input:** *valor\_preferencia*

**Output:** *PreferenciaPopularidade*

**Procedimento** *ReceberPreferenciaPopularidade(valor\_preferencia):*

  | *PreferenciaPopularidade* ← *valor\_preferencia*;

**Função** *ObterPreferenciaPopularidade():*

  | **return** *PreferenciaPopularidade*;

**Procedimento** *AtualizarPreferenciaPopularidade(valor\_atualizacao):*

  | *PreferenciaPopularidade* ← *valor\_atualizacao*;

---

A função *ReceberPreferenciaPopularidade* é dedicada a receber a preferência do usuário em relação ao nível de popularidade desejado das músicas, que é um valor que pode variar de 0 a 100. Esse valor é então armazenado na variável *PreferenciaPopularidade*, que pode ser acessada através da função *ObterPreferenciaPopularidade* sempre que o módulo gerenciador de recomendações necessitar desta informação para processar as recomendações. Além disso, a função *AtualizarPreferenciaPopularidade* permite atualizações subsequentes da preferência de popularidade, garantindo que o sistema possa

adaptar-se às mudanças nas preferências do usuário. Este design modular não apenas facilita a integração com diferentes plataformas, mas também promove uma experiência de usuário personalizada e interativa, alinhada com as descobertas literárias discutidas anteriormente. Portanto, o código apresentado serve como uma estrutura básica, orientando os implementadores sobre como o módulo de popularidade pode ser configurado para atender aos requisitos de personalização e adaptabilidade necessários para um sistema de recomendação musical.

### 5.3.4 Módulo de Contexto Atual do Usuário

**Objetivo:** Este módulo tem como objetivo capturar e interpretar o contexto atual do usuário para fornecer recomendações musicais mais adequadas e personalizadas, melhorando significativamente a experiência do usuário.

**Fundamentação:** O contexto do usuário é reconhecido como um elemento importante para personalizar recomendações musicais, tornando-as mais pertinentes e impactantes (MURCIEGO et al., 2021). Permitir que os usuários definam seu contexto manualmente oferece controle e personalização, alinhando as recomendações com suas necessidades e expectativas imediatas.

A determinação automatizada do contexto, conforme proposto por Deldjoo, Schedl e Knees (2021), emprega ferramentas tecnológicas como geolocalização, análise de padrões comportamentais e integração com aplicativos de calendário para discernir o contexto do usuário sem necessidade de interação direta. Essa abordagem minimiza o atrito na interação do usuário e pode revelar contextos mais sutis que podem não ser imediatamente reconhecidos ou considerados pelos usuários.

Na abordagem manual, os usuários podem especificar seu contexto atual por meio de uma interface intuitiva. Essa abordagem permite que os usuários tenham controle sobre o tipo de música que desejam ouvir, alinhando as recomendações com suas expectativas imediatas. Conforme discutido por Murciego et al. (2021), muitos usuários têm preferências musicais claras para diferentes contextos, a seleção manual de contexto permite que essa compreensão seja diretamente traduzida em recomendações personalizadas. No entanto, para garantir uma experiência de usuário gerenciável, o número de contextos disponíveis para seleção manual é limitado a alguns dos mais comuns ou populares.

**Comportamento:** Dentro da UConteXt Arch, o conceito de "contexto" é interpretado conforme as definições estabelecidas por Abowd et al. (1999) e Dey (2001), representando as variáveis dinâmicas que caracterizam a situação do usuário enquanto interage com o sistema de recomendação musical. Essas variáveis incluem a atividade que o usuário está realizando no momento, como treinar, dirigir, trabalhar ou estar em casa, que são consideradas tarefas definidoras do contexto. Em essência, as "tarefas" são as atividades específicas que o usuário executa e que servem como uma dimensão crítica do contexto,

influenciando diretamente as preferências musicais e, conseqüentemente, as recomendações fornecidas pelo sistema.

A seleção de contextos específicos para a recomendação musical é inspirada no estudo de Wang, Rosenblum e Wang (2012), que identifica seis atividades diárias de alto nível do usuário: Treinando, Trabalhando, Dormindo, Caminhando, Comprando, Estudando. Este módulo, no entanto, foca especificamente nas atividades de 'Treinando' e 'Trabalhando', adicionando ainda as atividades de 'Estar em Casa' e 'Dirigindo'. Esta abordagem permite uma personalização mais detalhada das recomendações musicais, adequando-as aos diferentes contextos em que o usuário se encontra

O Módulo de Contexto Atual é projetado para ser flexível, reconhecendo a múltipla natureza do contexto do usuário e as diversas maneiras pelas quais ele pode ser capturado para aprimorar a experiência de recomendação. O Algoritmo 4 apresentado delinea o comportamento fundamental do Módulo de Contexto Atual do Usuário dentro da camada de middleware, estabelecendo uma conexão entre a Camada de Interface e a Camada de Serviço.

Inicialmente, é definida uma estrutura padrão para o contexto, garantindo um formato consistente para a informação de contexto que será recebida da Camada de Interface. Esta estrutura contém dois campos principais: *tipoContexto*, que indica se o contexto foi obtido de maneira subjetiva ou automática, e *valorContexto*, que reflete o contexto atual do usuário como "em casa", "trabalhando", ou "treinando".

A função *InicializarModuloDeContexto* é configurada para rodar indefinidamente, aguardando a recepção do contexto da Camada de Interface. Uma vez recebido, o contexto é validado para garantir que segue o formato padrão. Se o contexto for válido, ele é então passado para a Camada de Serviço através da função *AtualizarModuloGerenciadorDeRecomendacoes*, que, por sua vez, atualiza o Módulo Gerenciador de Recomendações com o novo contexto do usuário. Este processo de validação e atualização é fundamental para garantir que as recomendações geradas estejam alinhadas com o contexto atual do usuário, proporcionando uma experiência de usuário personalizada e relevante.

Para implementar este módulo, é imprescindível que a Camada de Interface seja configurada para fornecer o contexto do usuário no formato padrão definido. Além disso, a Camada de Serviço deve ter a capacidade de receber e processar o contexto do usuário para informar o processo de recomendação. O intervalo de atualização, denotado como *intervaloDeAtualizacao*, deve ser configurado de acordo com a necessidade de responsividade do sistema à mudança de contexto do usuário. A robustez do módulo também pode ser melhorada com o tratamento adequado de erros, garantindo que qualquer desvio do formato de contexto padrão ou falha na atualização do Módulo Gerenciador de Recomendações seja adequadamente logado e/ou alertado.

---

**Algoritmo 4:** Módulo de Contexto Atual do Usuário

---

```

Estrutura Contexto {
    String tipoContexto; // Ex: "subjetivo"ou "automático"
    String valorContexto; // Ex: "em casa", "trabalhando", "Dirigindo",
    "treinando"
}
Função InicializarModuloDeContexto()
    // Aguarda a recepção do contexto da Camada de Interface
    while verdadeiro do
        contexto ← API.ReceberContexto()
        if contexto ≠ nulo then
            contextoAtual ← contexto
            AtualizarModuloGerenciadorDeRecomendacoes(contextoAtual)
        end
        Esperar(intervaloDeAtualizacao)
    end
Fim
Função ReceberContextoDaInterface()
    // Supondo uma função de API que recebe o contexto da Camada de
    Interface
    contexto ← API.ReceberContexto()
    if contexto não segue o formato padrão then
        // Tratar erro, possivelmente logar e/ou enviar alerta
        return nulo
    end
    return contexto
Fim
Função AtualizarModuloGerenciadorDeRecomendacoes(contextoAtual)
    // Supondo uma função de API que atualiza o módulo de
    recomendação com o novo contexto
    sucesso ←
    API.AtualizarContextoNoModuloDeRecomendacao(contextoAtual)
    if not sucesso then
        // Tratar erro, possivelmente logar e/ou enviar alerta
    end
Fim

```

---

## 5.4 Camada de Serviços

A Camada de Serviços é responsável pelo gerenciamento de grandes conjuntos de dados, incluindo as preferências dos usuários e seus feedbacks. Esses dados são utilizados para otimizar o sistema de recomendações. A camada foi projetada para facilitar a interação com plataformas externas, como serviços musicais e APIs de terceiros. Isso garante uma operação estável e coerente. Nas seções subsequentes, serão detalhados os módulos internos da camada, explicando suas funcionalidades e importância para a arquitetura proposta.

### 5.4.1 Módulo de Integração com Plataformas de Música

**Objetivo:** Este módulo é projetado para estabelecer uma conexão eficiente com plataformas de música como Spotify e Deezer, fornecendo acesso a uma vasta gama de dados musicais e metadados essenciais para enriquecer a experiência de recomendação musical na UConteXt Arch.

**Fundamentação:** A integração com serviços de streaming de música é vital no cenário atual do consumo musical digital (JANSSON, 2021). O acesso a metadados ricos, como informações de artistas, álbuns e aspectos contextuais das músicas, é fundamental para aprimorar a qualidade das recomendações (KAMINSKAS; RICCI, 2012). Além disso, a constante evolução das APIs e estruturas das plataformas de música exige um módulo adaptável, capaz de gerenciar mudanças e manter a experiência do usuário contínua e de alta qualidade (BURKHARDT et al., 2020; XUE et al., 2019) .

**Comportamento:** Este módulo, designado para interação com serviços renomados como Spotify, Deezer entre outros, desempenha um papel importante na arquitetura, servindo como a ponte para o acesso a vastos repositórios de dados musicais. Devido à singularidade da estrutura de dados e das APIs de cada serviço de streaming, é essencial realizar um mapeamento e integração precisos para garantir a consistência e confiabilidade das informações obtidas e processadas. Essa variabilidade destaca a importância da adaptabilidade inerente a este módulo. Uma gestão proativa dessa adaptabilidade não apenas mitiga potenciais incompatibilidades, mas também garante uma experiência do usuário contínua na UConteXt Arch.

O Algoritmo 5 e 6 apresenta a estrutura fundamental e as operações do Módulo de Integração com Plataformas Comerciais de Música. O ponto central desta estrutura, reside a definição de uma *PlataformaMusica*, que encapsula as informações necessárias para interagir com uma plataforma de música específica, como Spotify ou Deezer. Esta estrutura inclui o nome da plataforma, a URL base da API e um *token* de autenticação. O módulo mantém uma lista de *plataformasMusicais* suportadas, que são inicializadas na função *InicializarModuloDeIntegracao* através da função *ObterPlataformasSuportadas*. Esta inicialização pode ser baseada em um arquivo de configuração ou outro repositório de dados, proporcionando uma flexibilidade para configurar as plataformas suportadas.

---

**Algoritmo 5:** Módulo de Integração com Plataformas de Música

---

```
Estrutura PlataformaMusica {
    String nomePlataforma; // Ex: "Spotify", "Deezer"
    String APIUrl; // URL base da API da plataforma
    String APIToken; // Token de autenticação para a API
}
Lista<PlataformaMusica>plataformasMusicais;
Função InicializarModuloDeIntegracao()
    // Inicializa a lista de plataformas de música suportadas
    plataformasMusicais ← ObterPlataformasSuportadas ();
Fim
Função ObterPlataformasSuportadas()
    // Esta função pode obter a lista de plataformas suportadas de
    // um arquivo de configuração, banco de dados, entre outros.
    // Código para obter a lista de plataformas suportadas
    return plataformasMusicais;
Fim
Função
    BuscarMusica(parametrosBusca, genero, artista, popularidade, plataforma)
    // Constrói a URL de requisição para a API da plataforma
    urlRequisicao ←
        ConstruirURLRequisicaoBuscaMusica(parametrosBusca, plataforma);
    // Faz a requisição para a API da plataforma
    resposta ← FazerRequisicaoAPI(urlRequisicao, plataforma.APIToken);
    // Processa a resposta da API e extrai as músicas
    musicas ← ProcessarRespostaBuscaMusica(resposta);
    return musicas;
Fim
Função IdentificarGeneroMusica(musicaID, plataforma)
    // Constrói a URL de requisição para a API da plataforma
    urlRequisicao ←
        ConstruirURLRequisicaoIdentificarGenero(musicaID, plataforma);
    // Faz a requisição para a API da plataforma
    resposta ← FazerRequisicaoAPI(urlRequisicao, plataforma.APIToken);
    // Processa a resposta da API e extrai o gênero
    genero ← ProcessarRespostaIdentificarGenero(resposta);
    return genero;
Fim
```

---

---

**Algoritmo 6:** Módulo de Integração com Plataformas de Música (Continuação)

---

**Função** *IdentificarArtistaMusica*(*musicaID*, *plataforma*)  
 // Constrói a URL de requisição para a API da plataforma  
*urlRequisicao* ←  
 ConstruirURLRequisicaoIdentificarArtista(*musicaID*, *plataforma*);  
 // Faz a requisição para a API da plataforma  
*resposta* ← FazerRequisicaoAPI(*urlRequisicao*, *plataforma.APIToken*);  
 // Processa a resposta da API e extrai o artista  
*artista* ← ProcessarRespostaIdentificarArtista(*resposta*);  
**return** *artista*;

**Fim**

**Função** *BuscarGeneroEquivalente*(*genero*, *plataforma*)  
 // Constrói a URL de requisição para a API da plataforma  
*urlRequisicao* ←  
 ConstruirURLRequisicaoBuscarGeneroEquivalente(*genero*, *plataforma*);  
 // Faz a requisição para a API da plataforma  
*resposta* ← FazerRequisicaoAPI(*urlRequisicao*, *plataforma.APIToken*);  
 // Processa a resposta da API e extrai o nome do gênero  
 equivalente  
*nomeGeneroEquivalente* ←  
 ProcessarRespostaBuscarGeneroEquivalente(*resposta*);  
**return** *nomeGeneroEquivalente*;

**Fim**

---

Dentro do módulo, diversas funções são definidas para facilitar as interações com as plataformas de música. A função *BuscarMusica* recebe parâmetros de busca e uma plataforma específica, constrói uma URL de requisição e faz uma requisição à API da plataforma, processando a resposta para extrair e retornar uma lista de músicas. De maneira semelhante, as funções *IdentificarGeneroMusica*, *IdentificarArtistaMusica*, e *BuscarGeneroEquivalente* são estruturadas para realizar operações específicas, respectivamente identificando o gênero de uma música, o artista de uma música e buscando o nome do gênero equivalente na plataforma comercial.

Cada uma dessas funções realiza uma operação importante para o Módulo Gerenciador de Recomendações, que orquestra as operações na camada de serviços. As funções são planejadas para isolar a lógica de requisição e processamento de resposta específica da plataforma, encapsulando as complexidades associadas à interação com diferentes APIs de plataformas de música. Isso é realizado através de funções auxiliares que constroem URLs de requisição e processam respostas da API, como *ConstruirURLRequisicaoBuscaMusica*, *ConstruirURLRequisicaoIdentificarGenero*, entre outras.

A organização modular e a separação de responsabilidades conferem ao módulo uma alta adaptabilidade às mudanças nas APIs e estruturas das plataformas de terceiros. Essa adaptabilidade é um aspecto crítico do módulo, conforme destacado na sua descrição. A estrutura proposta também permite uma integração harmoniosa e eficiente com diver-



sas plataformas de música. Isso garante que as informações obtidas sejam consistentes, confiáveis e alinhadas com as promessas feitas na descrição do módulo.

### 5.4.2 Módulo do Cold-start

**Objetivo:** Este módulo tem como finalidade superar o desafio do cold-start em sistemas de recomendação musical, fornecendo uma base inicial para recomendações alinhadas ao contexto atual do usuário e aos seus gêneros musicais preferidos.

**Fundamentação:** A problemática do cold-start em sistemas de recomendação é um desafio significativo, especialmente quando se trata de novos usuários que ainda não geraram dados suficientes para permitir uma personalização eficaz. A maioria dos sistemas modernos depende da filtragem colaborativa, mas esta abordagem é particularmente suscetível ao problema do cold-start, já que depende fortemente dos dados gerados pelo usuário (CHANG et al., 2019). Quando um novo usuário acessa um sistema de recomendação, pouca informação está disponível para extrair suas preferências atuais, tornando a recomendação inicial imprecisa ou genérica. Nesse contexto, é crucial implementar estratégias que possam efetivamente prever as preferências dos usuários desde o início, usando outras fontes de dados além do histórico de interações do usuário.

Diversas abordagens têm sido exploradas para solucionar o problema do cold-start. Por exemplo, Wang, Rosenblum e Wang (2012) propuseram uma solução que utiliza a localização do usuário para encontrar músicas populares na região e analisar se elas se encaixam em uma tarefa específica ou estado emocional do usuário. Jenkins e Yang (2016) buscaram resolver o problema utilizando informações de contexto coletadas do Twitter em combinação com uma abordagem colaborativa usando o algoritmo K-Nearest Neighbourhood (K-NN), embora essa estratégia seja limitada se o usuário não possuir uma conta no Twitter. Magara et al. (2016) mostraram a eficácia de usar dados de sensores em dispositivos móveis para inferir o contexto do usuário e a atividade atual. Estes estudos ilustram a diversidade de abordagens possíveis e destacam a necessidade de explorar novos métodos para superar o desafio do cold-start.

**Comportamento:** O módulo do Cold-start desempenha um papel essencial na análise da solução proposta, servindo como a base inicial para recomendações que se alinham ao contexto atual do usuário e aos seus gêneros musicais preferidos, abordando o desafio do cold-start. Este módulo tem sua origem a partir de uma investigação sobre a relação entre playlists criadas pelos usuários para contextos específicos e os recursos de áudio fornecidos por plataformas musicais comerciais. Ao adotar a arquitetura proposta, é importante que o projetista identifique a plataforma comercial de integração e utilize um dataset de playlists criados por usuários fornecido por essa plataforma específica, garantindo assim maior aderência e eficácia na implementação deste módulo.

Nesta pesquisa, o contexto dos usuários está associado às atividades que eles realizam no momento. Para a realização deste estudo, foram consideradas atividades como

trabalhar, dirigir, treinar e estando em casa. Estas atividades foram destacadas como os principais momentos em que as pessoas optam por ouvir música, conforme indicado no Relatório de Percepção do Consumidor de Música da IFPI<sup>1</sup>.

A ênfase deste módulo é entender com base em datasets como os usuários estruturam suas playlists para diferentes contextos. Resumidamente, o objetivo é examinar recursos de áudio fornecidos pelas plataformas de músicas e discernir qual o intervalo de valor que torna uma música adequada para um contexto e gênero musical específico afins de evitar o problema do cold-start.

Para resolver o problema do cold-start, que surge comumente quando um novo usuário acessa uma plataforma de música, inicialmente é preciso filtrar as playlists criadas pelos usuários por contexto e gênero musical para que possa chegar a intervalos de valores para de cada recurso de áudio. A Figura 8 mostra a visão geral de cada etapa seguida para a construção de um dataset com intervalos de valores mínimo e máximo para cada recurso de áudio, relacionando-os ao contexto atual do usuário e ao gênero musical.

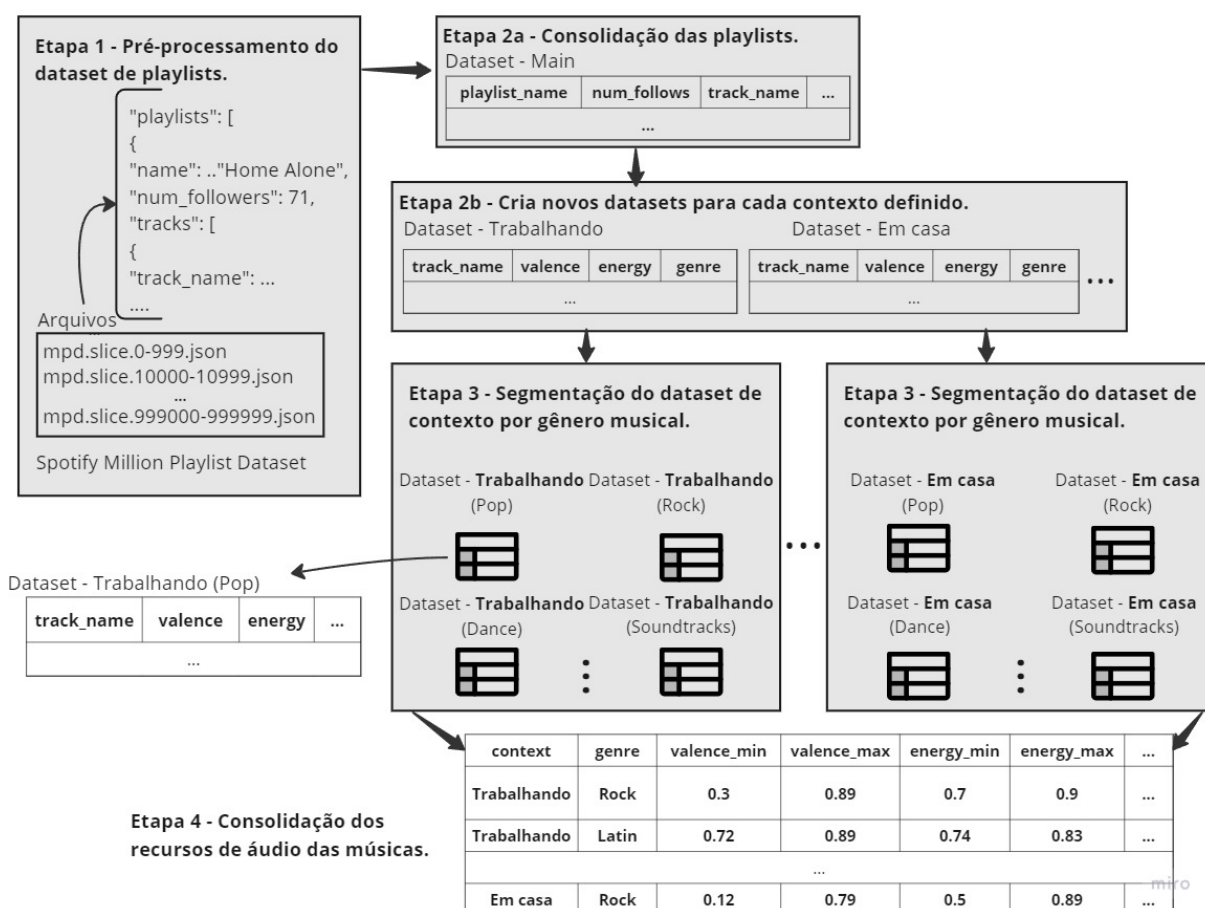


Figura 8 – Visão Geral - Etapas do processo de definição de valores para cada recurso de áudio.

<sup>1</sup> <https://www.ifpi.org/ifpi-releases-2018-music-consumer-insight-report/>

### 5.4.2.1 Pré-processamento do datasets de playlists

O módulo de Cold-Start é responsável por fornecer parâmetros iniciais que serão utilizados para filtrar as músicas, estabelecendo intervalos de mínimo e máximo para cada recurso de áudio. A importância deste módulo reside na investigação da relação entre atributos musicais, como valência, dançabilidade e energia e o contexto em que as músicas são ouvidas. Compreender esta relação é essencial, pois permite uma organização mais precisa das playlists dos usuários de acordo com diferentes ambientes e momentos, mesmo na ausência de um histórico de escuta prévio.

Para associar as playlists comuns criadas pelos usuários a um contexto específico, é importante definir um dataset para análise. Uma sugestão relevante para esta análise é o dataset do Spotify Million Playlist<sup>2</sup>, que contém playlists criadas por usuários. A preferência por este dataset decorre da facilidade de acesso e da popularidade atual do Spotify como plataforma musical. Embora outros datasets de plataformas comerciais possam ser usados, o Spotify se destaca como uma referência no setor.

O dataset do Spotify oferece acesso a recursos como: Dançabilidade, Valência, Energia, Ritmo, Volume, Falibilidade, Instrumentalidade, Vivacidade e Acusticidade. O dataset utilizado contém 1.000.000 de playlists, incluindo títulos de playlists e títulos de faixas, criadas por usuários na plataforma Spotify entre janeiro de 2010 e outubro de 2017. Este dataset também é composto por mais de 2 milhões de faixas únicas de quase 300.000 artistas, representando o maior dataset público de playlist de música (CHEN et al., 2018). Além disso, o dataset requer 31,2 GB de armazenamento em disco e é composto por 1000 arquivos em formato .json (ver formato na Figura 8 - Etapa 1).

### 5.4.2.2 Consolidação de playlists e segmentação por contexto

A Etapa 2 é uma fase no procedimento de pré-processamento de dados onde as playlists de música são organizadas e categorizadas com base em diferentes contextos. O principal objetivo desta etapa é refinar o dataset, tornando-o mais contextualmente relevante e específico para melhorar a análise e a precisão da recomendação. Dentro da Etapa 2, identificaram-se sub-etapas ou procedimentos como Etapa 2a e Etapa 2b.

Na Etapa 2a, o dataset é filtrado pelo nome da playlist. Foi desenvolvido um script responsável por gerar um arquivo contendo as playlists relacionadas ao título do contexto definido (trabalhar, dirigir, treinar e estar em casa). Na Etapa 2b, as playlists do dataset são automaticamente filtradas e divididas para os 4 contextos, nomeando-as com suas respectivas identificações de contexto.

A segmentação do dataset de música por contexto permite focar especificamente em um dataset contextual, permitindo o cálculo dos intervalos mínimo e máximo para cada recurso de áudio. Para determinar esses valores de intervalo, adotou-se uma abordagem

<sup>2</sup> <https://www.aicrowd.com/challenges/spotify-million-playlist-dataset-challenge>

estatística amplamente aceita, examinando a dispersão de cada característica em todo o dataset usando cálculos de quartis (LUO et al., 2018). Esta abordagem permite uma identificação rigorosa e sistemática dos intervalos de valores para cada recurso de áudio, fornecendo assim uma base confiável para o sistema de recomendação musical formular recomendações baseadas no contexto.

### 5.4.2.3 Segmentação do conjunto de dados do contexto por gênero musical

Os usuários costumam construir playlists voltadas para contextos específicos e usam títulos sugestivos para refletir esses contextos. No entanto, uma playlist pode ser ruidosa e não contextual, pois pode se relacionar com outras palavras populares fora do contexto (IBRAHIM et al., 2020a). Estudos mostram que vários fatores afetam a escolha musical do usuário em um dado contexto e o gênero musical é um desses fatores (GILLHOFER; SCHEDL, 2015; IBRAHIM et al., 2020a). Levando em conta os resultados relatados em Gillhofer e Schedl (2015), Ibrahim et al. (2020a), considera-se que a preferência dos usuários quanto ao gênero musical pode influenciar sua escolha de música para o contexto atual.

Dentro deste módulo, é importante analisar os conjuntos de dados de cada contexto sob a lente dos principais gêneros musicais (Etapa 3), a fim de obter uma compreensão mais precisa do cenário musical. Para determinar os valores iniciais para cada gênero musical dentro de um dado contexto, o processo é estruturado em duas etapas. Inicialmente, a variedade de gêneros musicais é delimitada para 10, de acordo com as preferências globais destacadas no último Relatório de Percepção do Consumidor de Música da IFPI<sup>3</sup>, que aponta os 10 gêneros musicais mais apreciados mundialmente: Pop, Rock, Dance/Eletrônico/House, Trilhas sonoras, Hip-Hop/Rap/Trap, Cantor/compositor, Clássico, R&B, Soul/Blues e Metal.

Na segunda etapa (ver Figura 8 - Etapa 3), é necessário determinar o gênero musical para cada faixa no conjunto de dados do Spotify. Dado que o conjunto de dados não fornece essa informação e sem um endpoint disponível para consulta direta de gênero, o módulo está configurado para atribuir o artista aos gêneros usando a API do Spotify, que fornece um endpoint para informações do artista. As faixas são então agrupadas por seus respectivos gêneros para cada contexto, resultando em 10 novos conjuntos de dados para cada um dos 4 conjuntos de dados contextuais, onde cada novo conjunto de dados corresponde a um gênero musical específico. Esta configuração no módulo facilita a categorização das faixas por seus respectivos gêneros, permitindo a avaliação de suas características de áudio e a geração de recomendações personalizadas para o usuário com base em seu contexto e preferências musicais

Ao implementar a arquitetura proposta, é importante conduzir uma análise inicial utilizando um dataset comercial, pois a eficácia do módulo de Cold-Start reside na defi-

<sup>3</sup> <https://www.ifpi.org/ifpi-releases-2018-music-consumer-insight-report/>

nição precisa de intervalos de valores mínimos e máximos, associados ao contexto atual do usuário e ao gênero musical selecionado. Esses intervalos são fundamentais, pois são empregados pelo módulo gerenciador de recomendações para aprimorar a precisão das sugestões musicais. Este aspecto da configuração do módulo é especialmente relevante ao identificar um novo usuário no sistema, com informações limitadas sobre suas preferências musicais, garantindo que as recomendações sejam pertinentes desde o início da interação

### 5.4.3 Módulo de Recálculo de Recursos de Áudio

**Objetivo:** O objetivo deste módulo é refinar e ajustar as recomendações musicais em tempo real, assegurando que continuem alinhadas às preferências e contextos em constante mudança do usuário.

**Fundamentação:** Recomendações musicais eficientes requerem mais do que a simples seleção de gêneros ou artistas. A verdadeira essência da personalização musical reside em nuances mais sutis, como as características ou recursos de áudio que ressoam com o estado de espírito e o contexto do ouvinte Abdul et al. (2018). A análise de recursos de áudio, como valência, dançabilidade e energia, e sua correlação com preferências e contextos específicos é fundamental para recomendações mais precisas e personalizadas.

Estudos prévios, como o estudo exploratório sobre o módulo de Cold-start (ASSUNÇÃO; PRATES; ZAINA, 2023), se concentraram na identificação e classificação dessas características em datasets offline. No entanto, o dinamismo do comportamento do usuário exige uma recalibração constante para manter as recomendações alinhadas às preferências em constante evolução.

**Comportamento:** O Módulo de Recálculo de Recursos de Áudio refina o processo inicial estabelecido pelo Módulo de Cold-Start, mantendo a relevância das recomendações perante as preferências evolutivas do usuário. Operando de forma dinâmica, este módulo ajusta os parâmetros das recomendações em tempo real, de acordo com as interações e avaliações do usuário na plataforma. A recalibração contínua garante que o sistema reflita prontamente as mudanças nas inclinações do usuário, proporcionando recomendações personalizadas e atualizadas com base nas interações mais recentes.

A funcionalidade central deste módulo é baseada no cálculo dos intervalos mínimo e máximo para cada recurso de áudio (ASSUNÇÃO; PRATES; ZAINA, 2023). Esses intervalos são determinados examinando a dispersão de cada característica em todo o conjunto de avaliações dos usuários, utilizando cálculos de quartis. Esta abordagem permite uma identificação rigorosa e sistemática dos intervalos de valores para cada recurso de áudio, semelhante ao procedimento empregado no Módulo de Cold-Start. No entanto, o diferencial deste módulo é a capacidade de executar tal procedimento em tempo real, a partir do conjunto de avaliações dos usuários fornecidas pelo Módulo de Feedback. Isso proporciona um mecanismo adaptativo para refinar as recomendações com base nas interações mais recentes do usuário.

Este módulo combina insights derivados de estudos offline com a flexibilidade e agilidade necessárias para responder às variações no comportamento do usuário em tempo real. Essa abordagem híbrida enriquece a experiência do usuário (BOZANTA; KUTLU, 2018; JUN et al., 2020), como também redefine os padrões de recomendações musicais personalizadas, alinhando as recomendações com o contexto atual e o gênero preferido do usuário, além dos parâmetros iniciais estabelecidos pelo Módulo de Cold-Start.

O Algoritmo 7 apresenta o funcionamento básico do Módulo de Recálculo de Recursos de Áudio, que se destina a recalibrar os parâmetros de recomendação em tempo real com base nas interações mais recentes do usuário. Para a implementação deste módulo, é importante a inicialização adequada através da função *InicializarModuloRecalculoRecursosAudio*, que pode conter configurações iniciais necessárias para o funcionamento correto do módulo. O núcleo da recalibração reside na função *RecalibrarRecursosAudio*, que é acionada pelo Módulo Gerenciador de Recomendações com uma lista de avaliações recentes. Cada avaliação contém informações cruciais como o gênero musical, o contexto em que a música foi ouvida, e os valores dos recursos de áudio da música avaliada.

A função *RecalibrarRecursosAudio* iterativamente processa cada avaliação, e para cada recurso de áudio, calcula os intervalos de valores (percentis 25 e 75) usando a função *CalcularPercentil*. Esses intervalos representam a faixa de valores na qual a maioria dos dados se encontra, proporcionando uma representação robusta do comportamento de dispersão do recurso de áudio. A função *CalcularPercentil* assume que os valores estão ordenados, permitindo o cálculo eficiente dos percentis. Posteriormente, a função *AtualizarIntervaloRecursoAudio* é chamada para atualizar os intervalos de recursos de áudio armazenados, que são categorizados por gênero e contexto. Esses intervalos recalibrados fornecerão a base para recomendações futuras, permitindo que o sistema ajuste dinamicamente as recomendações com base nas interações mais recentes do usuário.

Para a implementação deste módulo, é imperativo que o sistema tenha acesso a uma lista atualizada de avaliações do usuário, que pode ser obtida do Módulo de Feedback via o Módulo Gerenciador de Recomendações. Além disso, é necessário um mecanismo para calcular e armazenar os intervalos de recursos de áudio, garantindo que os dados sejam acessíveis e utilizáveis para a geração de recomendações em tempo real. O desempenho eficiente das funções de cálculo e atualização é fundamental para garantir que o sistema possa recalibrar prontamente os parâmetros de recomendação em resposta às interações do usuário, mantendo assim as recomendações alinhadas com as preferências em evolução do usuário.

#### 5.4.4 Módulo de Artistas Preferidos

**Objetivo:** O Módulo de Artistas Preferidos é projetado para capturar e utilizar as preferências do ouvinte em relação a artistas específicos, aprimorando as recomendações musicais com base nesses dados.

---

**Algoritmo 7:** Módulo de Recálculo de Recursos de Áudio

---

```

Estrutura Intervalo {
    String nomeRecurso; // nome do recurso de áudio, por exemplo, "tempo"
    Float valorMinimo;
    Float valorMaximo;
}
Estrutura IntervaloRecursoAudio {
    String genero;
    String contexto;
    Lista<Intervalo>intervalos; // Lista de intervalos para cada recurso de
    áudio
}
Lista<IntervaloRecursoAudio>intervalosRecursosAudio;
Função InicializarModuloRecalculoRecursosAudio()
| // Alguma inicialização necessária
Fim
Função RecalibrarRecursosAudio(avaliacoesRecentes)
|
|   foreach avaliacao in avaliacoesRecentes do
|       |
|       |   genero ← avaliacao.genero ;
|       |   contexto ← avaliacao.contexto ;
|       |   recursosAudio ← avaliacao.recursosAudio ;
|       |   foreach recursoAudio in recursosAudio do
|       |       |
|       |       |   intervalo ← CalcularPercentil(recursoAudio.valores) ;
|       |       |   AtualizarIntervaloRecursoAudio(parâmetros) ;
|       |       end
|       end
|   end
Fim
Função CalcularPercentil(valores)
|
|   // Assume que a lista de valores está ordenada
|   indice25 ← Tamanho(valores) *0.25 ;
|   indice75 ← Tamanho(valores) *0.75 ;
|   intervalo.valorMinimo ← valores[indice25] ;
|   intervalo.valorMaximo ← valores[indice75] ;
|   return intervalo ;
Fim
Função
AtualizarIntervaloRecursoAudio(genero, contexto, nomeRecurso, intervalo)
| // Atualiza o intervalo do recurso de áudio especificado
Fim

```

---

**Fundamentação:** A influência dos artistas na experiência musical dos ouvintes é um aspecto importante na personalização de recomendações musicais. Estudos mostram que a preferência por artistas específicos fornece insights profundos sobre os gostos e inclinações dos ouvintes (KIM, 2013; YOO, 2017). Esta preferência não é apenas um reflexo de gostos musicais, mas também um indicador de identificação cultural com os artistas. A relação do ouvinte com certos artistas pode ser interpretada como uma extensão de suas

próprias identidades e experiências de vida. Além disso, como destacado por Tsukuda e Goto (2017), as preferências por artistas específicos revelam padrões de gosto musical que transcendem a simples seleção de gêneros, mergulhando em aspectos mais pessoais e emocionais da experiência auditiva.

Além de identificar os artistas preferidos dos usuários, a exploração de artistas semelhantes emerge como uma estratégia eficaz para ampliar e enriquecer a experiência musical do usuário. Esta abordagem é apoiada pela pesquisa de Meinecke, Hakimi e Jänicke (2021), Pyo, Lee e Park (2022), que sugerem que a exposição a artistas similares pode não apenas aumentar a satisfação do usuário com o sistema de recomendação, mas também incentivá-lo a explorar novos territórios musicais alinhados com seus interesses existentes. Assim, a integração de um módulo focado nos artistas preferidos e na descoberta de artistas semelhantes na arquitetura de recomendação não é apenas uma resposta às preferências declaradas dos usuários, mas também uma estratégia para expandir seu horizonte musical de maneira intuitiva e engajadora.

**Comportamento:** O Módulo de Artistas Preferidos foi desenvolvido para garantir que as inclinações dos ouvintes em relação aos artistas (GREENBERG et al., 2021) pudessem ser capturadas de maneira abrangente e utilizadas para enriquecer suas recomendações. Por meio de um mecanismo de monitoramento contínuo, este módulo registra atentamente as avaliações atribuídas às músicas pelo ouvinte, catalogando o artista associado a cada uma.

O módulo, ao registrar tais interações, cria um ranking dos artistas que obtiveram o maior número de avaliações positivas. É essencial destacar que esta abordagem necessita levar em conta um volume significativo de avaliações do usuário para assegurar uma análise representativa. Após a identificação dos artistas preferidos, este módulo comunica com o Módulo Gerenciador de Recomendações, que integra-se a plataforma comercial de música (por exemplo, o Spotify) para buscar artistas semelhantes ao conjunto de artistas preferidos do usuário.

A inicialização deste módulo estabelece uma estrutura de dados adequada para armazenar e gerenciar os artistas preferidos do usuário. Este módulo possui duas funções *AtualizarAvaliacaoArtista* e *CalcularRankingArtistas* (ver Algoritmo 8), as quais são orquestradas pelo Módulo Gerenciador de Recomendações.

Quando um novo feedback é registrado pelo usuário, uma comunicação é estabelecida com o Gerenciador de Recomendações que, por sua vez, invoca a função *AtualizarAvaliacaoArtista*, transferindo o identificador do artista e a natureza da avaliação, facilitando assim a atualização precisa da contagem de avaliações positivas atribuídas ao artista em questão.

A função *CalcularRankingArtistas* é invocada periodicamente ou sob demanda pelo Módulo Gerenciador de Recomendações, fornecendo as avaliações acumuladas. Esta função processa as avaliações recebidas, recalculando o ranking dos artistas preferidos e



---

**Algoritmo 8:** Pseudocódigo para o Módulo de Artistas Preferidos

---

```

Estrutura Artista {
    String id; // Identificador único do artista na plataforma comercial
    String nome;
    Int avaliacoesPositivas;
}
Lista<Artista>artistasPreferidos;
Função InicializarModuloDeArtistasPreferidos()
    | // Inicializa a lista de artistas preferidos
Fim
Função AtualizarAvaliacaoArtista(idArtista, avaliacaoPositiva)
    | // Atualiza o contador de avaliações positivas do artista
    | // Se necessário, atualiza a lista de artistas preferidos
Fim
Função CalcularRankingArtistas(avaliacoes)
    | // Processa as avaliações para calcular o ranking
    | // Atualiza a lista de artistas preferidos
Fim
Função BuscarArtistasSimilares()
    | // Solicita a busca de artistas similares aos artistas
    | preferidos
Fim

```

---

mantendo a lista *artistasPreferidos* devidamente atualizada. Adicionalmente, a função *BuscarArtistasSimilares* é formulada para solicitar ao Módulo Gerenciador de Recomendações a execução de uma busca por artistas semelhantes aos preferidos, ampliando o escopo de recomendações fornecidas ao ouvinte. A implementação deste módulo requer uma interface de comunicação com as plataformas de música externas para a busca de artistas similares.

### 5.4.5 Módulo de Predição Adaptativa

**Objetivo:** O principal objetivo do Módulo de Predição Adaptativa é calcular recomendações musicais personalizadas em tempo real, empregando algoritmos de aprendizado de máquina para adaptar as sugestões às mudanças nas preferências e no contexto do usuário. Este módulo se concentra em analisar continuamente o feedback do usuário, ajustando as recomendações para refletir as preferências musicais atuais e oferecer uma experiência de escuta personalizada.

**Fundamentação:** A necessidade de personalização no consumo de música é cada vez mais evidente no cenário atual, onde o streaming digital predomina (TAKEUCHI; MORISHITA; SANO, 2022; FRID; PANARIELLO; NÚÑEZ-PACHECO, 2022). O Módulo de Predição Adaptativa busca atender esta necessidade ao incorporar técnicas de aprendizado de máquina, especialmente os que operam com aprendizado por fluxo de dados

como o *HoeffdingTreeClassifier*, que são cruciais para lidar com grandes volumes de dados e adaptar-se rapidamente a mudanças (DOMINGOS; HULTEN, 2000).

A capacidade de analisar rapidamente o feedback do usuário e ajustar as recomendações musicais de acordo é uma resposta direta à dinâmica atual do mercado de streaming, onde a personalização se tornou um fator chave para o engajamento e a satisfação do usuário. Além disso, a capacidade de treinar o modelo de forma dinâmica e em tempo real com base nas avaliações dos usuários é essencial para refletir continuamente as preferências evolutivas do usuário (LAMONT; WEBB, 2009; MILES et al., 2021).

Ao incorporar variáveis como características de áudio, contexto e gênero musical na construção do modelo preditivo, a precisão pode melhorar a probabilidade de um usuário apreciar uma faixa específica (PRENIQI; KALIMERI; SAITIS, 2023; IBRAHIM et al., 2020b; WANG et al., 2017) e isso pode proporcionar aos usuários playlists que estejam alinhadas com seu estado de espírito e preferências atuais.

**Comportamento:** A incorporação do feedback é um elemento central deste Módulo, desempenhando um papel fundamental na otimização contínua e na adaptação às predileções do usuário, assegurando assim a relevância das recomendações em um cenário musical dinâmico (WANG et al., 2017; VALL et al., 2019). Conforme articulado por Vall et al. (2019), sistemas de recomendação híbridos, que combinam filtragem colaborativa com abordagens baseadas em conteúdo, capitalizam o feedback obtido das sessões de audição do usuário para prever a sequência da playlist. De maneira concomitante, Wang et al. (2017) postula que o feedback é empregado para aprimorar a precisão e a pertinência das recomendações, assegurando que os usuários se deparem com composições musicais que estejam alinhadas aos seus anseios.

Em síntese, o Módulo de Predição Adaptativa na Arquitetura UConteXt Arch reflete a necessidade contemporânea de recomendações musicais personalizadas, baseada em pesquisas atuais e em práticas de design modular e adaptável, permitindo a integração de diferentes algoritmos de aprendizado por fluxo conforme a necessidade.

O Algoritmo 9 mostra que a centralidade operação do módulo repousa na função *PreverRecomendacoes*. Esta função recebe duas entradas vitais: uma lista de feedbacks, que são as avaliações dos usuários e um conjunto de músicas sobre as quais as previsões serão feitas. Para garantir a eficácia do processo de aprendizado é fundamental que os dados de feedback sejam bem estruturados e consistentes. A função *PrepararDados* é responsável por organizar esses dados de feedback em uma forma adequada para o treinamento do modelo. Posteriormente, o modelo é treinado dinamicamente em tempo real com os dados preparados através da chamada *modelo.Treinar(dadosTreinamento)*. Este treinamento em tempo real é importante para capturar a evolução constante das preferências dos usuários, permitindo que o modelo se adapte rapidamente às mudanças nas avaliações dos usuários.

Após o treinamento, o modelo é então aplicado ao conjunto de músicas fornecido,

---

**Algoritmo 9:** Módulo de Predição Adaptativa

---

```

Estrutura ModeloPredicao {
    // Supondo que o modelo seja algum objeto que pode ser treinado e usado
    // para fazer previsões
}
ModeloPredicao modelo;
Função InicializarModuloPredicao()
| // Inicializar o modelo e qualquer outra configuração necessária
Fim
Função PreverRecomendacoes(feedbacks, conjuntoMusicas)
|
| dadosTreinamento ← PrepararDados(feedbacks) ;
| modelo.Treinar(dadosTreinamento) ;
| recomendacoes ← AplicarModelo(conjuntoMusicas) ;
| return recomendacoes ;
Fim
Função PrepararDados(feedbacks)
|
| Dados dadosTreinamento ;
| foreach feedback in feedbacks do
| | // Processar feedbacks e adicionar ao conjunto de dados de
| | treinamento
| end
| return dadosTreinamento ;
Fim
Função AplicarModelo(conjuntoMusicas)
|
| Lista<Recomendacao>recomendacoes ;
| foreach musica in conjuntoMusicas do
| | gostara ← modelo.Prever(musica) ;
| | if gostara then
| | | // Criar uma nova recomendação para a música que o
| | | modelo previu que o usuário gostará
| | end
| end
| return recomendacoes ;
Fim

```

---

através da função *AplicarModelo*, para gerar previsões sobre quais músicas o usuário provavelmente apreciará, dada a sua história de avaliações. O resultado é uma lista de recomendações que é então retornada ao Módulo Gerenciador de Recomendações. Esta lista contém as músicas que, segundo o modelo, estão alinhadas com as preferências atuais do usuário.

Para a implementação deste módulo, é decisivo que o modelo de aprendizado de máquina escolhido seja capaz de lidar com aprendizado em tempo real ou aprendizado online, para assimilar e reagir às novas informações conforme são recebidas. Além disso, o modelo deve ser capaz de processar eficientemente grandes volumes de dados, dada a natureza dinâmica e em tempo real do sistema.

A flexibilidade é outro atributo desejável, permitindo a integração de diferentes algoritmos de aprendizado de máquina conforme necessário, para atender a diferentes cenários ou melhorar a precisão das previsões. Este design modular e flexível garante que o módulo de predição adaptativa possa evoluir junto com os avanços na área de aprendizado de máquina, mantendo-se relevante e eficaz na entrega de recomendações musicais personalizadas que ressoam com as preferências e estados de espírito em constante mudança dos usuários.

### 5.4.6 Módulo de Filtragem de Músicas

**Objetivo:** O objetivo do Módulo de Filtragem de Músicas na Arquitetura UConteXt Arch é refinar a seleção de músicas recomendadas, garantindo que elas estejam alinhadas com as preferências específicas do usuário e excluindo faixas que possam ser desagradáveis ou irrelevantes para o seu gosto e contexto atual.

**Fundamentação:** A personalização nas recomendações musicais não se limita a sugerir músicas que se alinham às preferências dos usuários, mas também envolve a remoção proativa de faixas que podem não ser do agrado do usuário. Este aspecto da personalização é importante, pois o vasto volume de conteúdo disponível nas plataformas de streaming pode ser grande para os usuários, e a capacidade de filtrar eficientemente este conteúdo é um diferencial importante (SUN, 2022b). Sistemas de recomendação avançados empregam uma mistura de abordagens, incluindo a recomendação baseada em conteúdo, a filtragem colaborativa e métodos híbridos, para criar listas de reprodução que não apenas correspondam, mas também aprimorem as preferências do usuário (ABDUL et al., 2018). Esta abordagem multifacetada é necessária para entender e responder às nuances das preferências musicais, que são influenciadas por uma série de fatores, incluindo o gosto pessoal, o contexto e até mesmo o estado emocional do momento.

Além disso, a eficácia da filtragem de músicas é aprimorada pela capacidade de processar e analisar feedback detalhado do usuário. Isso envolve não apenas identificar as faixas que os usuários gostam, mas também as que eles não gostam ou acham menos atraentes. A tecnologia moderna, especialmente as técnicas avançadas de aprendizado de máquina e análise de dados, torna possível analisar grandes conjuntos de dados de feedback do usuário para identificar padrões e tendências nas preferências musicais (MURCIEGO et al., 2021; PARK; LEE, 2022). Essa análise detalhada permite que o Módulo de Filtragem de Músicas faça seleções mais precisas e contextuais, eliminando efetivamente as músicas que não se alinham com os interesses atuais do usuário, garantindo assim uma experiência de escuta mais satisfatória e personalizada.

**Comportamento:** Dentro deste contexto, emerge o Módulo de Filtragem de Músicas na Arquitetura UConteXt Arch, uma componente designada para aprimorar a experiência musical do usuário através de uma seleção precisa. A versatilidade do módulo é manifestada na sua capacidade de aceitar e processar múltiplas listas de recomendações

(ZIEGLER et al., 2005), característica esta que amplia a adaptabilidade de sistemas ancorados na Arquitetura UConteXt Arch. Este processo de consolidação, além de assegurar a singularidade das faixas, mantém uma coerência contextual com os desejos iniciais do usuário (FELICIONI; DACREMA; CREMONESI, 2021).

Adicionalmente, o módulo projetado para eliminar redundâncias e evitar experiências negativas (PARK; LEE, 2022), removendo faixas repetidas e promovendo assim, uma experiência musical mais diversificada e enriquecedora, tendo em vista que repetições excessivas podem atenuar o prazer auditivo.

O Algoritmo 10 fornecido para o Módulo de Filtragem de Músicas ilustra um procedimento estruturado de filtragem e consolidação de diversas listas de músicas, visando aprimorar a experiência musical do usuário. A inicialização do módulo é destacada na função *InicializarModuloFiltragemMusicas*, que pode ser expandida conforme necessário para acomodar qualquer configuração inicial exigida. O cerne do módulo é representado pela função *FiltrarMusicas*, que aceita múltiplas listas de músicas e informações de previsão provenientes do Módulo de Predição Adaptativa ou do Módulo Gerenciador de Recomendações como entrada.

---

**Algoritmo 10:** Módulo de Filtragem de Músicas

---

```

Estrutura Musica {
    String id; // Identificador único da música
    // ... outros atributos relevantes (por exemplo, gênero, contexto,
    características de áudio, etc.)
}
Estrutura ListaMusicas {
    Lista<Musica>musicas;
}
Função InicializarModuloFiltragemMusicas()
| // Alguma inicialização necessária
Fim
Função FiltrarMusicas(Lista<ListaMusicas> listasMusicas)
| ListaMusicas listaMusicasUnicas;
| // Unir todas as listas de músicas em uma lista, removendo
| duplicatas
| foreach listaMusicas in listasMusicas do
| | foreach musica in listaMusicas.musicas do
| | | if listaMusicasUnicas.musicas.Contem(musica) == Falso then
| | | | listaMusicasUnicas.musicas.Adicionar(musica);
| | | end
| | end
| end
| return listaMusicasUnicas ;
Fim

```

---

O primeiro procedimento do processo de filtragem é a deduplicação que é executado

para consolidar todas as listas de músicas em uma lista única, removendo quaisquer duplicatas. Este procedimento é vital para garantir que o usuário não seja afetado com repetições. O pseudocódigo faz uso de estruturas de dados básicas como listas e loops de controle para iterar através das listas de músicas, verificando e removendo duplicatas.

### 5.4.7 Módulo Gerenciador de Recomendações

**Objetivo:** O Módulo Gerenciador de Recomendações é o núcleo da Arquitetura UConteXt Arch, responsável por coordenar as interações entre diferentes módulos e centralizar a tomada de decisões nas recomendações musicais. Ele visa melhorar a eficiência e a precisão das recomendações fornecidas ao usuário.

**Fundamentação:** Centralizar a tomada de decisão em sistemas de recomendação é fundamental para garantir recomendações eficientes e personalizadas (MANDL et al., 2010; CHEN et al., 2013; CENA et al., 2020). Chen et al. (2013) enfatizam que os sistemas de recomendação visam ajudar os usuários a fazer boas escolhas e decisões, fornecendo sugestões personalizadas. Eles argumentam que, embora pesquisas anteriores tenham se concentrado em técnicas e algoritmos de recomendação, menos atenção tem sido dada aos processos de tomada de decisão adotados pelos usuários e apoiados pelo sistema. Isto sugere que a centralização da tomada de decisões pode aumentar a eficácia dos sistemas de recomendação. Além disso, Cena et al. (2020) destacam que os sistemas de recomendação podem ser usados para apoiar processos de tomada de decisão, não apenas para decisões simples de baixo risco, mas também para decisões mais complexas de alto risco.

**Comportamento:** O Módulo Gerenciador de Recomendações interage diretamente com módulos como Cold-Start, Integração com Plataformas de Música, Filtragem de Músicas, Banco de Dados Central, Recálculo de Recursos de Áudio e Predição Adaptativa. Ele gere a interação entre esses módulos para formular recomendações musicais alinhadas com as preferências e o contexto do usuário. Dependendo se o usuário é novo ou já possui um histórico de interações, o módulo adota diferentes abordagens para a formulação de recomendações. Para usuários novos, ele utiliza parâmetros iniciais do módulo Cold-Start, enquanto para usuários com histórico, ele se baseia em feedbacks e parâmetros recalculados de recursos de áudio. O módulo também coordena a busca por faixas em plataformas de música e a filtragem de recomendações para garantir relevância e diversidade, além de colaborar com o Módulo de Predição Adaptativa para refinar as sugestões.

A ligação com o Módulo de Integração com Plataformas de Música é um elo importante no processo de recomendação. O Gerenciador se vale deste módulo para buscar faixas alinhadas aos parâmetros fornecidos, seja do Módulo do Cold-start ou os parâmetros advindos do Módulo de Recálculo de Recursos de Áudio. Isso assegura que as recomendações finais estejam em harmonia com a oferta disponível na plataforma musical selecionada (JANSSON, 2021; FERWERDA et al., 2019; BOURREAU; GAUDIN, 2018).

A compreensão mais profunda do papel central do Módulo Gerenciador de Recomendações na coordenação e interação com outros módulos é ampliada ao se analisar o relacionamento com o Módulo de Filtragem de Músicas e o Módulo de Predição Adaptativa. A filtragem de recomendações nos sistemas de recomendação é um passo necessário para lidar com a sobrecarga de informações (LU et al., 2015). Gharahighehi e Vens (2021) discutem a diversificação em sistemas de recomendação de notícias baseados em sessões. Esta referência explora os desafios enfrentados nas recomendações de notícias para usuários anônimos e destaca as limitações dos métodos típicos de filtragem colaborativa. Embora não esteja diretamente relacionado com a filtragem de recomendações, apresenta uma perspectiva alternativa sobre a eficácia dos métodos de filtragem colaborativa no contexto da sobrecarga de informação.

O Módulo Gerenciador de Recomendações, ao transmitir dados brutos para filtragem, espera que o ruído seja reduzido e o conteúdo mais relevante seja priorizado. A decisão de depender de um módulo especializado para esta tarefa é baseada no entendimento de que a relevância e precisão são fatores críticos para o sucesso dos sistemas de recomendação, conforme discutido por Sun (2022b).

No que concerne ao Módulo de Predição Adaptativa, a interação é profundamente estratégica. Uma vez que o Módulo Gerenciador de Recomendações possui as listas refinadas, busca a competência do Módulo de Predição Adaptativa para identificar possíveis outliers ou faixas que, embora alinhadas com os critérios estabelecidos, podem não se adequar perfeitamente ao gosto do usuário no contexto atual. A incorporação de aprendizado de máquina em sistemas de recomendação permite uma adaptação mais rápida e precisa às nuances do comportamento do usuário (WU, 2022). O Gerenciador fornece o histórico de avaliações e feedbacks do usuário para o Módulo de Predição Adaptativa, que, por sua vez, analisa esses dados e retorna com uma lista de faixas que possam não ser do agrado do usuário. Isso permite que o sistema evite desapontamentos e melhore constantemente a precisão de suas recomendações.

O Algoritmo 11 apresentado, a função *GerarRecomendacoes* é a principal operação executada pelo Módulo Gerenciador de Recomendações, que é ativada com a solicitação de recomendações de músicas por parte de um usuário. Esta função é desenhada para gerir interações entre diferentes módulos da arquitetura proposta, conforme o estado e o perfil do usuário. Os requisitos para implementar este algoritmo incluem a disponibilidade de módulos auxiliares, como *Cold-start*, *Integração com Plataformas de Música*, *Filtragem de Músicas*, *Banco de Dados Central*, *Recálculo de Recursos de Áudio*, e *Predição Adaptativa*, bem como as estruturas de dados correspondentes para representar usuários, músicas, feedbacks, entre outros elementos necessários.

Inicialmente, o módulo busca verificar se o usuário é novo ou se não possui feedbacks suficientes para permitir a personalização das recomendações. Se uma dessas condições for verdadeira, então solicita os parâmetros iniciais do módulo *Cold-start*, que são baseados

---

**Algoritmo 11:** Módulo Gerenciador de Recomendações

---

```

Função InicializarModuloGerenciadorRecomendacoes()
| // Inicializar o módulo e qualquer outra configuração necessária
Fim
Função GerarRecomendacoes(usuario, contexto, popularidade)
| if usuario.isNovo() ou
|   usuario.Feedbacks.Contagem() < QNT_MIN_FEED then
|   | parametrosIniciais ←
|   |   SolicitarParametrosIniciais(contexto, usuario.GeneroFavorito) ;
|   | listaMusicasGeral ←
|   |   BuscarMusicas(parametrosIniciais, plataforma) ;
|   | listaMusicasGenero ←
|   |   BuscarMusicas(usuario.GeneroFavorito, plataforma) ;
|   | listaMusicasFiltradas ←
|   |   FiltrarMusicas([listaMusicasGeral, listaMusicasGenero]) ;
|   | return listaMusicasFiltradas ;
| else
|   | avaliacoes ← SolicitarFeedbacks(usuario) ;
|   | parametrosRecalculados ←
|   |   SolicitarRecalculoRecursosAudio(avaliacoes) ;
|   | listaMusicasGeral ←
|   |   BuscarMusicas(parametrosRecalculados, popularidade) ;
|   | listaMusicasArtistas ←
|   |   SolicitarMusicasArtistasPreferidos(usuario) ;
|   | listaMusicasGenero ←
|   |   SolicitarMusicasGenero(usuario.GeneroFavorito) ;
|   | // listaMusicasGeral, listaMusicasArtistas, listaMusicasGenero
|   | listaMusicasFiltradas ← FiltrarMusicas([todas as listas]) ;
|   | listaMusicasRecomendadas ←
|   |   PreverRecomendacoes(feedbacks, listaMusicasFiltradas) ;
|   | return listaMusicasRecomendadas ;
| end
Fim

```

---

no contexto atual e no gênero musical favorito do usuário. Utilizando estes parâmetros, o módulo solicita duas listas de músicas ao módulo de Integração com Plataformas de Música: uma lista geral baseada nos parâmetros iniciais e uma lista específica do gênero musical favorito do usuário. Posteriormente, estas listas são unificadas e filtradas para remover duplicatas pelo módulo de Filtragem de Músicas, sendo então retornadas para serem exibidas na interface do usuário.

Por outro lado, se o usuário não é novo e possui feedbacks suficientes, o módulo adota uma abordagem mais personalizada. Primeiramente, solicita os feedbacks do usuário ao módulo *Banco de Dados Central*. Com base nestes feedbacks, solicita ao módulo de *Recálculo de Recursos de Áudio* para atualizar os parâmetros de recursos de áudio. Em seguida, solicita três listas de músicas ao módulo de *Integração com Plataformas de Música*: uma



lista geral baseada nos parâmetros recalculados, uma lista de músicas de artistas preferidos do usuário e uma lista específica do gênero musical favorito do usuário. Similar à abordagem para usuários novos, estas listas são unificadas e filtradas pelo módulo de Filtragem de Músicas para remover duplicatas. Entretanto, ao invés de retornar as músicas filtradas diretamente, o algoritmo encaminha estas músicas e os feedbacks do usuário ao módulo de *Predição Adaptativa* para prever as recomendações finais. O módulo de *Predição Adaptativa*, então, retorna uma lista de músicas recomendadas que é finalmente retornada para ser exibida na interface do usuário.

Esta estruturação no algoritmo oferece um procedimento detalhado e modular, permitindo a interação com diversos módulos que compõem a arquitetura UConteXt Arch. Para a implementação prática deste algoritmo, é importante garantir que os módulos auxiliares estejam corretamente implementados e integrados e que as estruturas de dados e as interfaces de comunicação entre os módulos estejam bem definidas, facilitando a transmissão de informações entre os módulos e a execução eficiente das operações descritas.

## 5.5 Implementação da arquitetura UConteXt Arch

A transição da arquitetura UConteXt Arch, exposta nas seções anteriores, para uma implementação prática, é um passo essencial para validar as ideias teóricas e avaliar a eficácia da arquitetura proposta em um ambiente real. A materialização prática dessa arquitetura é exemplificada pelo aplicativo MixFy, que foi criado para servir como a interface direta com os usuários, proporcionando uma plataforma na qual eles podem interagir com o sistema de recomendação musical. Este capítulo tem como objetivo descrever detalhadamente o processo de implementação, destacando como a arquitetura UConteXt Arch foi concretizada tanto no aplicativo MixFy quanto no servidor associado, elucidando as interações complexas entre as diversas camadas e módulos da arquitetura.

A integração do MixFy com a plataforma Spotify foi uma decisão estratégica, dado que a implementação do módulo de cold-start foi fundamentada em um dataset do Spotify com de playlists criadas por usuário. Esta integração não só valida a aptidão da arquitetura UConteXt Arch para interagir com plataformas de música comerciais, mas também destaca a flexibilidade inerente à arquitetura, insinuando a possibilidade de acoplar outras plataformas musicais mediante procedimentos análogos.

Os tópicos a seguir, apresentam uma visão abrangente e detalhada do processo de implementação, destacando os desafios enfrentados e decisões tomadas. Imagens da interface do MixFy e discussões sobre as decisões de implementação são compartilhados ao longo das seções, proporcionando uma visão técnica e prática da concretização da UConteXt Arch no ambiente real do MixFy.

### 5.5.1 Ambiente de implementação

A implementação da arquitetura UConteXt Arch foi segmentada em dois ambientes principais: o servidor, que hospeda a camada de serviço, e o aplicativo móvel MixFy, que serve como a interface de usuário para interação com o sistema. O servidor foi construído utilizando a linguagem de programação Python, juntamente com o framework Django, que proporciona uma estrutura robusta e confiável para o desenvolvimento rápido e seguro de aplicações web. Este servidor foi hospedado na Render Cloud, uma plataforma de hospedagem que oferece recursos escaláveis e monitoramento contínuo, garantindo assim a disponibilidade e a eficiência do serviço. O acesso ao servidor é realizado através do endpoint: <https://mixfyapi.onrender.com/api>, que foi configurado para atender as requisições do aplicativo MixFy.

O banco de dados adotado para a gestão e armazenamento de dados foi o PostgreSQL<sup>4</sup>, conhecido por sua confiabilidade, integridade de dados e conformidade com padrões SQL (Structured Query Language). Este banco de dados desempenha um papel crucial na persistência das informações necessárias para a operação eficiente da arquitetura UConteXt Arch, incluindo os dados dos usuários, feedbacks, e os parâmetros de recursos de áudio que orientam as recomendações de música.

Por outro lado, o aplicativo MixFy foi desenvolvido utilizando o framework Flutter. A escolha do Flutter foi estratégica, pois permite a criação de aplicativos tanto para Android quanto para iOS a partir de uma única base de código, facilitando assim a manutenção e a expansão da aplicação. Além disso, esta escolha permitiu alcançar um maior número de usuários, independentemente da plataforma móvel que utilizam, criando assim uma base mais ampla para avaliações subsequentes.

A integração com o Spotify foi realizada através da Web API fornecida pela plataforma. Esta integração permitiu o acesso a uma vasta gama de informações musicais que são cruciais para a funcionalidade da arquitetura UConteXt Arch. Foram utilizadas diversas endpoints da API do Spotify, incluindo "Get Artist", "Get Artist's Related Artists", "Get Available Genre Seeds", "Get Recommendations" e "Get Track's Audio Features". A endpoint "Get Recommendations" foi de particular importância, pois permitiu a passagem de diversos parâmetros - seja do módulo de cold-start, do módulo de recálculo de recursos de áudio, gênero, artista, entre outros - para obter recomendações musicais personalizadas. Enquanto a endpoint "Get Track's Audio Features" foi utilizada para identificar os recursos de áudio de um conjunto de músicas, sendo este processo limitado a 100 músicas por requisição. Esta integração foi fundamental para a realização das funcionalidades propostas, e demonstrou a flexibilidade da arquitetura UConteXt Arch em se integrar com plataformas de música comerciais.

---

<sup>4</sup> <https://www.postgresql.org/>

## 5.5.2 Implementação da Camada de Interface

A **Estrutura Geral do Aplicativo MixFy** foi desenvolvido em torno do padrão *Model-View-Controller (MVC)*, uma escolha que promove uma separação organizada entre a lógica de negócio, a interface do usuário e o modelo de dados. O padrão MVC também alinha-se bem com a estrutura modular da arquitetura UConteXt Arch, proporcionando uma coesão arquitetônica entre o aplicativo e o backend.

A escolha do framework Flutter<sup>5</sup> para o desenvolvimento foi motivada por sua capacidade de compilar para ambos os sistemas operacionais móveis, Android e iOS, a partir de uma base de código única. O gerenciamento de estado no MixFy foi orquestrado usando o Provider<sup>6</sup>, uma biblioteca popular no ecossistema Flutter que permite um gerenciamento de estado reativo. O Provider facilita o fluxo de dados entre diferentes partes da aplicação, garantindo que a UI seja atualizada de maneira eficiente em resposta às mudanças no estado do aplicativo.

O **Design de Interface** do MixFy foi deliberadamente projetada para alinhar-se com a aparência de plataformas de música bem estabelecidas como Spotify e Deezer. A escolha do esquema de cores preto e branco visa proporcionar uma transição cognitiva suave para os usuários que já estão familiarizados com essas plataformas. As Figuras 10 e 10 oferecem uma representação visual das várias interfaces do usuário dentro do MixFy, ilustrando desde a tela de login até a interface de avaliação do usuário.

A tela de seleção de gêneros musicais é a primeira interação significativa que o usuário tem com o MixFy, conforme ilustrado na Figura 9c. Nesta tela, é apresentada uma lista horizontal de gêneros musicais, cada um representado visualmente por um ícone e um título. Os usuários podem selecionar até três gêneros musicais que preferem, fornecendo ao sistema uma indicação inicial de suas preferências musicais. Esta etapa é fundamental, pois estabelece a base para as recomendações iniciais de música que são geradas pelo sistema.

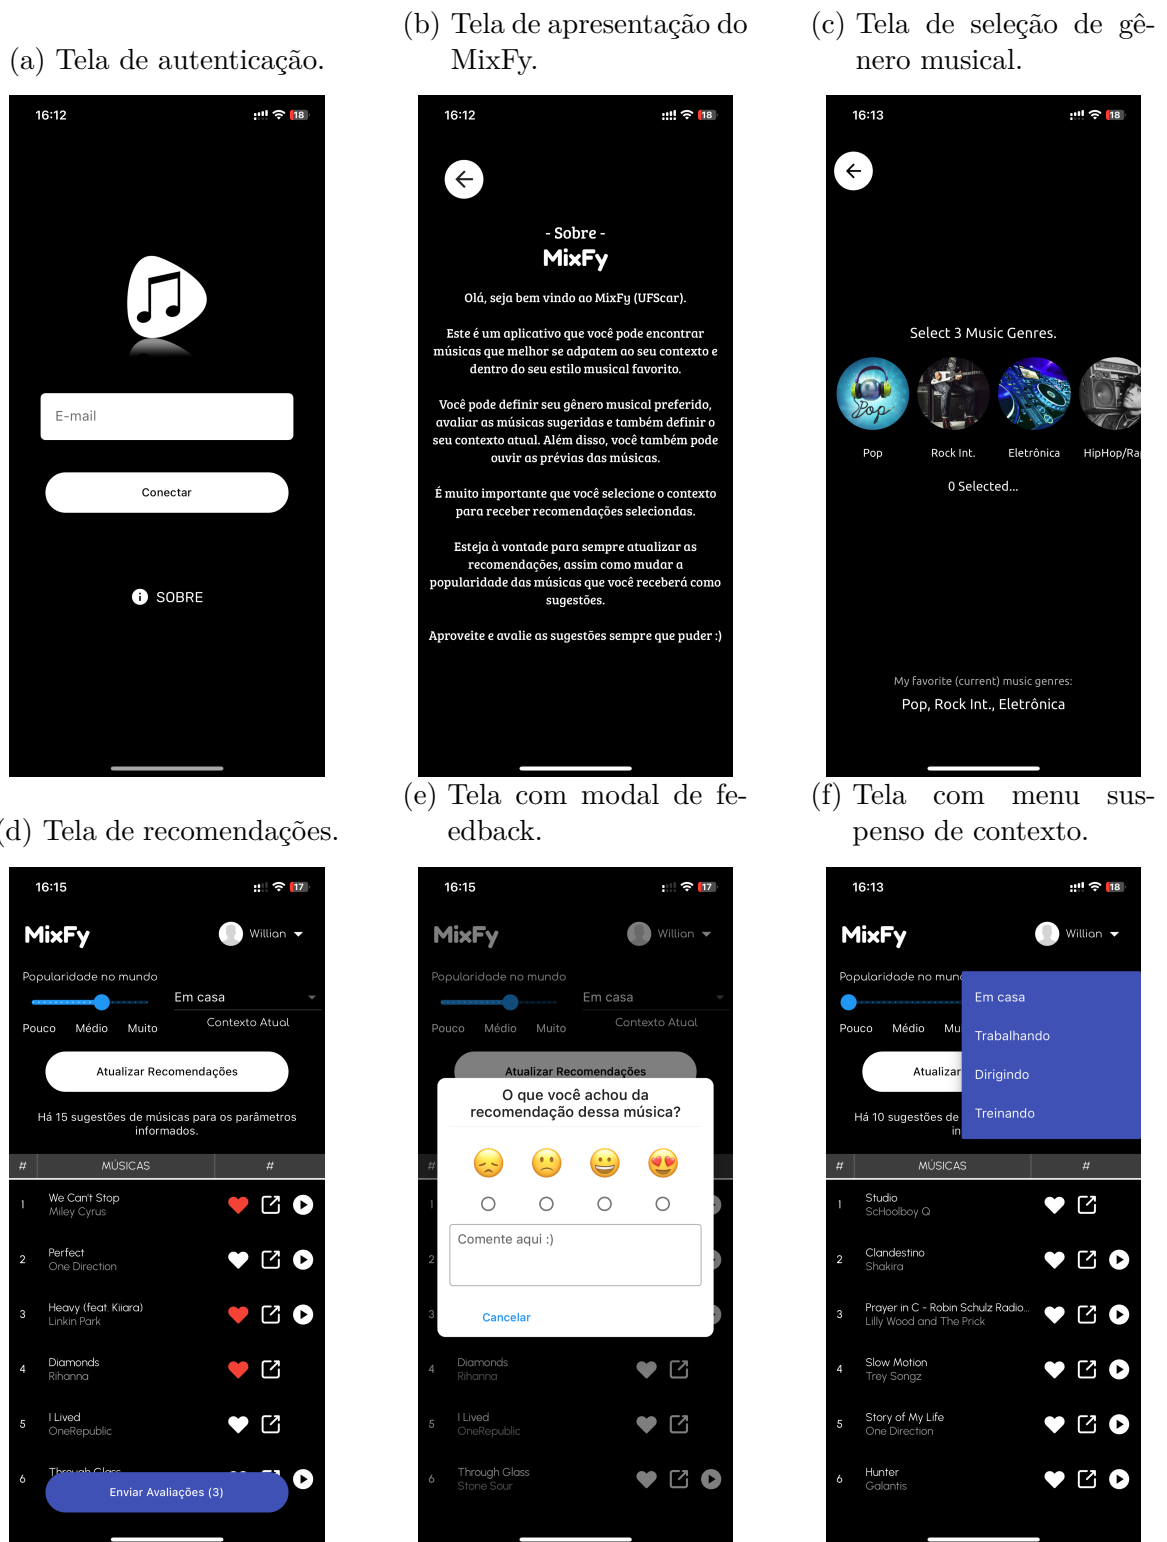
A seleção de gêneros musicais desempenha um papel significativo na operação da Camada de Middleware. As preferências de gênero selecionadas pelo usuário são transmitidas ao servidor e utilizadas pelo módulo Cold-Start para gerar um conjunto inicial de recomendações de música. Além disso, as preferências de gênero também podem ser utilizadas pelo módulo de Recalibração de Recursos de Áudio para ajustar os parâmetros de recursos de áudio com base nos gêneros preferidos do usuário.

Há também um outro aspecto distintivo da interface do MixFy que é o slider de popularidade e o menu suspenso para a seleção do contexto atual do usuário, conforme ilustrado na Figura 9d. O slider de popularidade permite que os usuários ajustem a popularidade das músicas recomendadas numa escala de 0 a 100, proporcionando uma maneira intuitiva de refinar as recomendações de acordo com as preferências pessoais.

<sup>5</sup> <https://flutter.dev/>

<sup>6</sup> <https://pub.dev/packages/provider>


Figura 9 – Interfaces do aplicativo MixFy.



Este elemento de interface não apenas oferece uma personalização direta, mas também captura uma métrica importante que é utilizada pela Camada de Middleware para ajustar as recomendações.

O menu suspenso de contexto oferece uma seleção entre quatro cenários comuns: em casa, trabalhando, dirigindo ou treinando. Ao selecionar um contexto, o usuário informa

Figura 10 – Interface de avaliação UX Curves (MixFy).



ao sistema sobre seu ambiente atual, o que, por sua vez, é utilizado para ajustar as recomendações de música para se alinharem com o cenário selecionado. Esta interação direta entre a interface do usuário e a camada de middleware é fundamental para a operação do sistema de recomendação, permitindo que o sistema responda dinamicamente às mudanças no contexto do usuário.

Além dos recursos de ajuste da popularidade e seleção de contexto, o MixFy incorpora um modal de feedback interativo, conforme mostrado na Figura 9e, que é um componente chave para capturar a experiência do usuário em tempo real. Este modal surge após a interação do usuário com uma música recomendada, oferecendo opções de avaliação, que vão de descontentamento a satisfação. O usuário pode expressar sua reação imediata à recomendação musical através de emojis representativos, permitindo uma resposta rápida e intuitiva que reflete sua satisfação atual. Além disso, o campo de comentário fornece uma oportunidade para o usuário elaborar sobre sua avaliação, compartilhando entendimentos mais profundos sobre sua experiência, seja destacando elementos específicos que apreciaram na faixa ou aspectos que acreditam necessitar de melhoria. Este mecanismo de feedback detalhado não só enriquece a base de dados do sistema com qualificações qualitativas e quantitativas, mas também serve como um instrumento valioso para a Camada de Middleware. Ao processar essas informações, a camada pode refinar ainda mais o algoritmo de recomendação, ajustando as futuras seleções musicais para alinhar-se mais estreitamente com as preferências individuais e o contexto do usuário.

A **Integração com o Servidor** foi realizada através de uma API REST, hospedada na infraestrutura da Render Cloud<sup>7</sup>. Este endpoint RESTful, acessível através do URL

<sup>7</sup> <https://render.com/>

<https://mixfyapi.onrender.com/api/>, serve como uma ponte de comunicação vital entre o aplicativo e o servidor (camada de interface e camada de serviços), facilitando a troca de dados necessária para fornecer recomendações musicais personalizadas. A autenticação no MixFy foi estrategicamente simplificada, exigindo apenas um e-mail dos usuários autorizados, o que não apenas simplifica o processo de login, mas também garante que apenas indivíduos autorizados tenham acesso à plataforma durante as fases de avaliação.

A integração entre a interface do usuário e a camada de middleware é facilitada pelo servidor. As seleções de popularidade e contexto feitas pelos usuários no MixFy são transmitidas ao servidor através de chamadas de API RESTful. Estes dados são então utilizados pela camada de middleware para ajustar os parâmetros do sistema de recomendação. Por exemplo, o módulo de Recalibração de Recursos de Áudio na camada de middleware pode ajustar os parâmetros de recursos de áudio com base no contexto selecionado pelo usuário, enquanto o módulo de Personalização de Popularidade pode refinar as recomendações de música com base na preferência de popularidade indicada pelo usuário.

A **Integração com o Spotify** é uma parte importante da implementação, pois o MixFy depende dos dados e funcionalidades fornecidos pela API do Spotify. No lado do servidor, várias endpoints da API do Spotify foram utilizadas para obter informações de artistas, gêneros, recomendações musicais e características de áudio das faixas. No lado do aplicativo, embora não haja uma integração direta com a API do Spotify, a URI fornecida pelo Spotify foi utilizada para redirecionar os usuários para o aplicativo Spotify, onde eles podem ouvir as músicas completas.

O **Feedback do Usuário** é capturado através de uma interface intuitiva que inclui ícones de coração para avaliações de músicas e um modal que permite uma avaliação mais detalhada através de uma escala de emojis de 4 pontos. Além disso, a tela UX Curves oferece uma representação visual da experiência do usuário ao longo do tempo, permitindo avaliações adicionais. Este feedback é importante para o aprendizado contínuo e aprimoramento do sistema de recomendação, sendo uma peça-chave para o módulo de predição adaptativa.

Esses detalhamentos visam apresentar com rigor e profundidade a implementação da camada de interface no contexto da arquitetura UConteXt Arch, delineando como o MixFy foi construído para facilitar a interação do usuário e coleta de feedback, enquanto integra-se com o servidor e o Spotify.

### 5.5.3 Considerações técnicas sobre a implementação da Camada de Serviços, Middleware e Dados

A aplicação MixFy, sendo uma instância que adota a arquitetura UConteXt Arch, tomou a decisão acertada de implementar o algoritmo HoeffdingTreeClassifier (DOMIN-

GOS; HULTEN, 2000) em seu Módulo de Predição Adaptativa, alinhando-se precisamente com a descrição modular e adaptável fornecida para o módulo na arquitetura. A escolha deste algoritmo, conhecido por sua eficiência em lidar com grandes volumes de dados em tempo real, é emblemática do compromisso do MixFy em otimizar a experiência de escuta dos usuários através da personalização.

Ao considerar as últimas 100 avaliações de músicas feitas pelos usuários, o MixFy não apenas se alinha com a ênfase da UConteXt Arch no treinamento dinâmico baseado no feedback dos usuários, mas também capitaliza sobre a natureza em tempo real do HoeffdingTreeClassifier. Este algoritmo permite uma adaptação rápida às mudanças nas preferências dos usuários, conforme novos dados são fornecidos através das avaliações.

Esta implementação específica reflete uma compreensão profunda da necessidade de manter o sistema atualizado com a evolução contínua do gosto musical dos usuários, garantindo que as recomendações geradas permaneçam relevantes e em sintonia com os desejos atuais dos usuários. Portanto, a escolha do algoritmo e a estratégia de considerar as avaliações recentes demonstram uma aplicação prática dos princípios delineados para o Módulo de Predição Adaptativa na arquitetura UConteXt Arch.

Na implementação do Módulo de Feedback, foi mantido um alinhamento rigoroso com o comportamento proposto na arquitetura UConteXt Arch, visando capturar e processar as avaliações dos usuários e direcioná-las para a camada de serviços para o refinamento contínuo do sistema de recomendação. Entretanto, algumas decisões técnicas foram necessárias para adequar a implementação à forma como o Spotify opera. Um aspecto importante foi a maneira como as informações de feedback dos usuários foram manuseadas em conjunto com os dados de recursos de áudio das músicas avaliadas.

Na implementação, a lista de feedback do usuário é recebida, contendo os IDs das músicas que foram avaliadas. Esses IDs são então extraídos da lista de feedbacks, e uma consulta é realizada ao Spotify para recuperar os recursos de áudio de cada música avaliada. Essa etapa adicional foi fundamental para garantir que, ao armazenar o feedback do usuário, os recursos de áudio correspondentes a cada música fossem armazenados juntamente.

Este procedimento é imperativo pois o Módulo de Predição Adaptativa depende da disponibilidade de uma lista de feedback que contenha não apenas as avaliações dos usuários, mas também os recursos de áudio associados para efetuar o treinamento e a previsão em tempo real. Esta técnica de implementação, embora desviando ligeiramente da estrutura originalmente proposta, foi uma resposta pragmática à necessidade de integrar dados cruciais do Spotify, assegurando assim que o sistema MixFy continua a operar de maneira otimizada e alinhada com as exigências do Módulo de Predição Adaptativa, maximizando a personalização e relevância das recomendações musicais fornecidas aos usuários.

Na concepção da aplicação MixFy, uma decisão deliberada foi tomada para limitar a análise aos três gêneros musicais preferidos do usuário, embora a arquitetura UConteXt

Arch não especifique um número determinado de gêneros a serem considerados. Esta limitação foi estabelecida visando manter um foco mais apurado nas preferências predominantes do usuário, o que, por sua vez, é conjecturado para facilitar a geração de recomendações mais precisas e personalizadas.

Na camada de interface, isso se refletiu na limitação da seleção de gêneros musicais a três, uma abordagem que foi replicada no middleware através do módulo de gêneros musicais, integrando-se assim com a camada de serviços. Esta decisão se alinha com a meta de simplificar a interação do usuário e de minimizar a sobrecarga cognitiva, ao mesmo tempo em que maximiza a relevância das recomendações musicais geradas. Além disso, a restrição a três gêneros principais pode ser vista como uma maneira pragmática de gerenciar a complexidade inerente ao processamento e análise de preferências musicais multifacetadas, alinhando-se assim com a ênfase da arquitetura UConteXt Arch na eficiência e na personalização centrada no usuário.

A implementação também enfrentou desafios relacionados à correspondência entre gêneros musicais locais e os gêneros reconhecidos pelo Spotify. Um exemplo notável foi a necessidade de mapear o gênero "Rock brasileiro" para o equivalente mais genérico "Rock", dado que o Spotify não tinha uma correspondência direta para o gênero local. Essa adaptação foi importante para garantir a relevância das recomendações musicais geradas.

Além disso, foi observado que as músicas retornadas pelo Spotify não possuíam um gênero musical associado diretamente, sendo essa informação vinculada ao artista da música. Isso exigiu um processo adicional de identificação do artista da música, consulta ao Spotify para recuperar o gênero associado ao artista e, por fim, vincular essa informação à música em questão. No que tange ao módulo de artistas preferidos, optou-se por considerar apenas os dois artistas mais bem avaliados pelo usuário. Essa decisão foi alinhada com a intenção de manter a relevância e a precisão das recomendações, bem como com a eficiência operacional do sistema, ao limitar o escopo de análise aos artistas que são de maior interesse para o usuário. Estas adaptações e decisões técnicas, embora derivadas da estrutura original proposta pela arquitetura UConteXt Arch, demonstram uma aplicação pragmática e focada no usuário da arquitetura, sempre visando maximizar a relevância e a personalização das recomendações musicais.

## 5.6 Mapeamento dos aspectos desejáveis na arquitetura

A proposta da UConteXt Arch desenvolvida com o objetivo de atender ao conjunto de aspectos identificados como cruciais na revisão da literatura apresentada na Seção 3.8.2. Cada módulo da arquitetura foi estruturado para endereçar especificamente os desafios e necessidades articuladas na literatura, proporcionando uma arquitetura bem fundamentada para aprimorar a eficácia e a eficiência dos sistemas de recomendação



musical. A seguir, delineamos como cada módulo da UConteXt Arch se correlaciona com os aspectos discutidos na literatura.

O Módulo Gêneros Musicais responde diretamente ao aspecto de "**Personalidade e preferências do usuário**" discutido por Ferwerda e Schedl (2014). As preferências por gêneros musicais são indicativos cruciais da personalidade e gostos individuais, e este módulo busca capturar e refletir estas preferências na recomendação musical, promovendo assim uma experiência mais personalizada e satisfatória (HAN et al., 2010; FERWERDA; SCHEDL, 2014).

A popularidade, conforme discutido por Cheng e Shen (2014), é um aspecto que pode influenciar a escolha musical e a incorporação da popularidade das faixas musicais pode melhorar significativamente o desempenho. Este módulo busca balancear a popularidade com as preferências individuais, proporcionando um equilíbrio entre o que é popularmente aceito e o que é individualmente preferido.

O Módulo Contexto Atual se alinha com a discussão sobre "**Atividade do usuário**" apresentadas por Teng, Kuo e Yang (2013), Jiang e He (2016), Lee et al. (2017), que reconhecem a importância de incorporar o contexto atual do usuário nas recomendações musicais para torná-las mais relevantes e menos cognitivamente demandantes. Este módulo é uma resposta direta à necessidade identificada na literatura de alinhar as recomendações com o estado e a atividade atual do usuário, proporcionando assim recomendações que são não apenas musicalmente satisfatórias, mas também contextualmente relevantes.

O **feedback** do usuário é a voz direta do usuário refletida no sistema. É através do feedback, seja explícito ou implícito, que o sistema aprende, adapta-se e evolui para atender melhor às necessidades e expectativas dos usuários (OKADA et al., 2013; WANG; WANG; CHOU, 2018). Sendo assim, o módulo de Feedback da arquitetura busca abordar a importância identificada na literatura de capturar e analisar o feedback do usuário para aprimorar a precisão e a relevância das recomendações, promovendo uma interação mais significativa e enriquecedora entre o usuário e o sistema.

O Módulo Cold-start está diretamente relacionado ao aspecto de **cold-start** apresentado na revisão da literatura que foram sustentados por Chen, Chen e Wang (2015), Magara et al. (2016), Chang et al. (2019). Este módulo desenvolve estratégias para proporcionar recomendações iniciais que consideram o contexto até que tenham uma quantidade suficiente de informação sobre as preferências do usuário.

O **aprendizado** contínuo é dito como um aspecto importante para sistemas de recomendação (MAGARA et al., 2016; CHANG et al., 2019). O Módulo Recálculo de Recursos de Áudio, através da análise e recálculo de características das faixas musicais, contribui para a adaptação contínua das recomendações, permitindo que o sistema evolua com as mudanças nas preferências musicais dos usuários e nas tendências musicais emergentes.

O Módulo Artistas Preferidos reflete a discussão sobre as **preferências dos usuários**

por certos artistas e busca honrar estas preferências na recomendação musical. Este módulo ajuda a promover uma experiência musical mais personalizada e satisfatória, respeitando e refletindo as afinidades musicais dos usuários.

Por outro lado, o Módulo Gerenciador de Recomendações não poder ser visto somente como um coordenador de interações entre os diversos módulos. Este módulo apesar de coordenar, tem uma relação intrínseca com vários aspectos identificados na revisão da literatura e um alto desafio em traduzir os *insights* derivados destes aspectos para produzir tomadas de decisões a respeito das recomendações musicais. Além disso, o Módulo Gerenciador de Recomendações é projetado para otimizar a eficiência do sistema, centralizando a tomada de decisões relativas às recomendações. Ao fazer isso, ajuda a reduzir o **esforço cognitivo** necessário por parte dos usuários para encontrar músicas que correspondam às suas preferências e contextos atuais. Em vez de terem que navegar por vastas coleções de músicas, os usuários recebem recomendações personalizadas, diminuindo assim a carga cognitiva associada à busca e seleção de músicas.

A correspondência entre as preferências do usuário e as músicas disponíveis nas plataformas é essencial para personalizar recomendações. O Módulo Integração com Plataformas de Música garante que as recomendações se transformem efetivamente em seleções musicais nas plataformas preferidas dos usuários, criando assim uma experiência fluida e agradável. Além disso, o módulo de integração ajuda a diminuir o problema do cold-start ao permitir acesso a um vasto catálogo de músicas nas plataformas, proporcionando uma base inicial para recomendações, mesmo para novos usuários com histórico de interação limitado.

Já o Módulo de Predição Adaptativa impulsiona a evolução contínua do sistema. Este módulo é onde os dados e **feedback** dos usuários são traduzidos em **aprendizado**, onde o sistema aprende, adapta-se e evolui para refletir melhor as complexidades e nuances das preferências e comportamentos dos usuários.

A filtragem de música garante que as recomendações finais estejam não apenas alinhadas com as preferências dos usuários, mas também livres de redundâncias e dissonâncias reduzindo o **esforço do cognitivo** do usuário em realizar essa tarefa manualmente. O módulo Módulo Filtragem de Música atende também ao aspecto de "**Personalidade e preferências do usuário**", garantindo que as recomendações estejam alinhadas com os gostos musicais dos usuários, e também ao aspecto de "**Feedback**", ajustando as recomendações com base nas interações dos usuários.

---

## Capítulo 6

# Do contexto do usuário às listas de reprodução personalizadas

---

*Este capítulo focaliza na avaliação do módulo de recomendação dentro do ciclo de design. A funcionalidade e a eficácia da arquitetura são testadas através da instância prática do aplicativo MixFy. O módulo de recomendação passou por três iterações de avaliação. A primeira iteração testou a funcionalidade básica, a segunda iteração focou na usabilidade e experiência do usuário, e a terceira iteração refinou o módulo com base nos resultados obtidos, ajustando algoritmos e interfaces de acordo com o feedback dos usuários.*

Neste capítulo, apresenta-se a avaliação da abordagem de recomendação presente no módulo de recomendação da arquitetura. O objetivo desta avaliação é avaliar a eficácia e a comunicabilidade do sistema em relação as recomendações, além de medir a aceitação dos usuários sob a tecnologia. Todos os procedimentos nesta avaliação foram aprovados pelos comitês éticos apropriados, garantindo que as considerações éticas foram devidamente abordadas.

A metodologia de avaliação, incluindo o Método de Inspeção Semiótica Intermediado (MISI) e o Modelo de Aceitação de Tecnologia (TAM), foi projetada para fornecer percepções abrangentes sobre a usabilidade do sistema e a aceitação do usuário. O MISI foi escolhido por sua capacidade de examinar criticamente se o sistema comunica efetivamente suas intenções e princípios de interação, oferecendo assim uma medida confiável da comunicabilidade do sistema. Por outro lado, o TAM foi selecionado devido à sua eficiência comprovada na medição da aceitação do usuário e uso potencial de uma tecnologia específica, fornecendo informações valiosas sobre a prontidão do usuário para adotar o

sistema.

Em relação à coleta de dados para essa avaliação, foram convidados oito participantes com diferentes origens por meio de redes sociais e listas de e-mail. Esses participantes, constituídos por um número igual de homens e mulheres com idades entre 18 e 35 anos, eram principalmente estudantes de graduação de várias áreas. Para capturar dados de diferentes contextos, cada participante foi atribuído a um dos contextos definidos (trabalhando, treinando, dirigindo e estando em casa), com dois participantes representando cada contexto. A decisão de usar esse grupo diversificado teve como objetivo incorporar uma ampla gama de experiências e preferências na avaliação, melhorando assim a confiabilidade e a generalização dos resultados.

## 6.1 Método de Inspeção Semiótica Intermediado

A Engenharia Semiótica é uma teoria (SOUZA, 2005) que percebe a interface do sistema como uma forma de comunicação indireta do projetista para o usuário. Através da interação usuário-sistema (comunicação direta), a compreensão do projetista sobre os usuários, sua intenção e os princípios interativos subjacentes são transmitidos (comunicação indireta). Assim, a interface é percebida como uma metamsagem do projetista para o usuário.

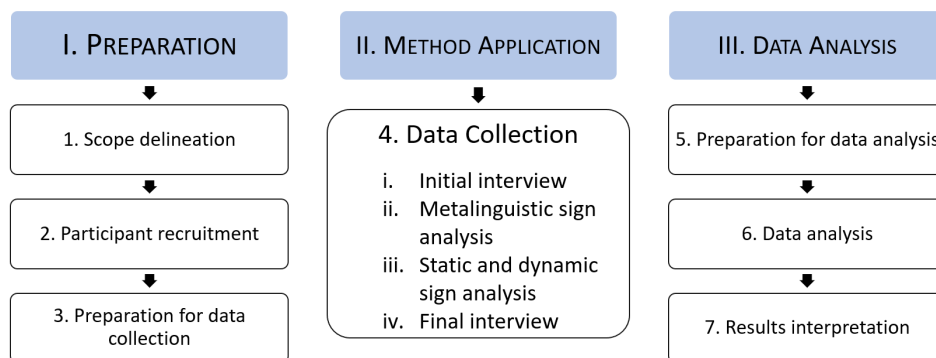
A metalinguagem do projetista é composta por signos, que a Engenharia Semiótica classifica em três tipos: metalinguísticos, estáticos e dinâmicos (SOUZA et al., 2010; SOUZA et al., 2006). Os signos metalinguísticos explicam outros signos na interface do sistema (por exemplo, dicas, ajuda). Os signos estáticos representam o estado do sistema (por exemplo, botão, opção de menu). Os signos dinâmicos representam o comportamento do sistema desencadeado pela interação do usuário (por exemplo, a abertura de uma janela modal após clicar em um botão).

A qualidade da comunicação do projetista para o usuário é avaliada por meio da comunicabilidade do sistema, que é a capacidade do sistema de transmitir aos usuários a intenção do projetista e os princípios interativos subjacentes (SOUZA, 2005). Entre os métodos existentes para avaliar a comunicabilidade, está o Método de Inspeção Semiótica Intermediado (MISI) (OLIVEIRA; LUZ; PRATES, 2008; OLIVEIRA; PRATES, 2018), que é baseado no Método de Inspeção Semiótica (MIS) (SOUZA et al., 2010; SOUZA et al., 2006), mas adaptado para se concentrar na perspectiva dos usuários sobre a comunicabilidade do sistema.

Em resumo, o MISI permite ao avaliador orientar a inspeção dos participantes sobre os signos metalinguísticos, estáticos e dinâmicos do sistema (sem exigir que os participantes entendam os conceitos). Os participantes exploram os signos do sistema conforme instruído pelo avaliador, que coleta dados sobre a percepção dos participantes sobre a comunicabilidade do sistema através de entrevistas. O MISI é organizado em 3 etapas

(preparação, coleta de dados e análise) e 7 estágios. A Figura 11 apresenta uma visão geral das 3 etapas e dos estágios associados a cada uma das etapas.

Figura 11 – Visão geral do Método de Inspeção Semiótica Intermediado (MISI)



Fonte: (OLIVEIRA; PRATES, 2018)

### 6.1.1 Aplicação do MISI

Neste capítulo, descreve-se como a avaliação com o MISI foi conduzida. Para tanto, para cada uma das 3 etapas, as decisões e etapas realizadas são descritas.

O passo de preparação envolve 3 etapas:

- **Delineação do escopo** - O escopo deste estudo visa explorar a proposta da abordagem de recomendação considerando o contexto atual do usuário e o gênero musical de interesse. Além disso, o trabalho visa investigar o impacto da aprendizagem nos resultados das recomendações. Nesse contexto, o foco está em como o sistema comunica suas adaptações e aprendizados ao usuário ao longo do tempo, melhorando as recomendações com base nas avaliações dos usuários das recomendações recebidas anteriormente.
- **Recrutamento de participantes** - Foram recrutadas pessoas que têm o hábito de ouvir música diariamente, em um dos contextos: no trabalho, em casa, durante o treino ou ao dirigir. O MISI é um método qualitativo focado na análise aprofundada e, portanto, é aplicado com um pequeno número de participantes (OLIVEIRA; PRATES, 2018) (outros estudos aplicaram o MISI com apenas 3 participantes (OLIVEIRA; LUZ; PRATES, 2008)). Neste estudo, a amostra consistiu em 8 participantes convidados de redes sociais e listas de email, 4 participantes masculinos e 4 femininos, com idades entre 18 e 35 anos. Todos os participantes eram estudantes universitários de diferentes origens.
- **Preparação para a coleta de dados** - Foi preparado um *Roteiro de Avaliação* contendo todas as etapas de avaliação para orientar o avaliador. Os participantes assinaram o *Termo de Consentimento Livre e Esclarecido (TCLE)*, explicando a avaliação

e seus direitos, e preencheram um *Questionário de Perfil* destinado a entender com que frequência e em quais situações eles ouvem plataformas de recomendação de música, seu principal dispositivo de escuta, e seus conhecimentos sobre contextos e gêneros musicais.

Na etapa inicial, um sistema de ajuda foi incorporado à plataforma, destinado à facilitação da inspeção de *sinais metalinguísticos* pelos participantes. Esta funcionalidade, disponibilizada diretamente na aplicação em formato digital, foi pensada para proporcionar suporte efetivo durante a interação dos usuários. Paralelamente, um roteiro estruturado para a inspeção de *sinais estáticos e dinâmicos* foi elaborado, onde se definiram especificamente as telas e tarefas a serem examinadas pelos participantes.

Selecionaram-se três tarefas com a finalidade de guiar os participantes pelo sistema. Tarefa 1: ("*Buscar recomendações de músicas para um dado [contexto] e popularidade*"); Tarefa 2: ("*Definir um [contexto atual] e avaliar 40 (quarenta) canções recomendadas para esse [contexto]. Avaliar 20 (vinte) canções que se consideram adequadas e 20 que se consideram inadequadas para o contexto definido.*"); e Tarefa 3: ("*Reavaliar outras 10 canções, 5 que se consideram adequadas e 5 que se consideram inadequadas para o mesmo [contexto].*"). Os elementos indicados entre colchetes foram definidos de maneira individualizada para cada participante.

Finalmente, foram preparados os roteiros para orientar as entrevistas sobre o entendimento e a experiência dos usuários ao longo da coleta de dados. Assim, foram preparadas as perguntas no final da análise de sinais metalinguísticos, da análise de sinais estáticos e dinâmicos, e do roteiro final da entrevista.

A segunda etapa do MISI envolveu as atividades de **coleta de dados**. Nossa coleta de dados foi conduzida online através do Google Meet de 2 de fevereiro a 3 de março de 2023. A interação dos participantes foi registrada em vídeo e áudio. Foram utilizados os seguintes instrumentos para a coleta de dados: gravação de ações do usuário ao usar o aplicativo móvel desenvolvido, gravação de discursos dos participantes enquanto usavam a ferramenta, anotações dos pesquisadores e questionário de perfil demográfico.

Durante a coleta de dados, os objetivos da pesquisa foram apresentados e os participantes foram convidados a ler e assinar o termo de consentimento. Seguiu-se o roteiro da entrevista inicial, versando sobre o perfil dos participantes, além dos roteiros para a inspeção de sinais metalinguísticos e sinais estáticos e dinâmicos. Em cada etapa da análise dos participantes, questionaram-se as expectativas sobre as ações que poderiam realizar e se havia algum aspecto incompreendido. A fase foi concluída com uma entrevista final, focando em aspectos de consolidação de metamensagem e a experiência do uso do sistema.

O último passo do MISI envolveu a **análise dos dados**. Concluída a coleta, todas as gravações foram baixadas, os vídeos das gravações foram assistidos pelo menos duas

vezes e todas as entrevistas foram transcritas. O estudo gerou um total de 3 horas e 52 minutos de gravação. Com auxílio do software Atlas-ti<sup>1</sup>, os dados foram organizados.

Com base nas informações obtidas por meio de questionários, entrevistas e interações, realizaram-se análises inter-sujeito e intra-sujeito. A primeira serviu para comparar e contrastar os dados coletados, enquanto a segunda permitiu a verificação de variações no comportamento de um único participante ao longo do tempo, possibilitando a identificação de mudanças na maneira como o usuário interage com o sistema. A análise foi conduzida pelo primeiro autor e discutida com os demais pesquisadores envolvidos. Como resultado, foram identificados os principais aspectos da experiência com o MixFy e reconstruída a perspectiva da metamensagem.

## 6.2 O Modelo de Aceitação de Tecnologia (TAM)

O TAM é um modelo teórico proposto por Davis (1989) que visa explicar e prever a aceitação do usuário de sistemas de informação. Em sua essência, a utilidade percebida e a facilidade de uso são definidas pelo TAM como dimensões essenciais que determinam a decisão de um indivíduo de usar uma nova tecnologia. A utilidade percebida refere-se ao grau em que um usuário acredita que o uso de um determinado sistema aumentaria o desempenho de suas tarefas. Por outro lado, a facilidade de uso percebida refere-se à extensão em que uma pessoa acredita que o uso do sistema será desprovido de esforço.

O funcionamento do TAM se baseia na ideia de que o uso real do sistema é influenciado pela intenção comportamental de usar. Essa intenção é determinada pela utilidade percebida e pela facilidade de uso. Significativamente, a facilidade de uso percebida também afeta a utilidade percebida. Isso significa que um sistema é mais provável de ser percebido como válido se for mais fácil de usar (DAVIS, 1989). Normalmente, o TAM é aplicado a partir de um questionário que contém as perguntas apresentadas por dimensão, ou seja, utilidade percebida, facilidade de uso percebida e intenção de usar. Cada questão reuniu o grau de aceitação dos usuários em relação ao objeto avaliado. As respostas coletadas são então analisadas para prever se os usuários provavelmente aceitarão e usarão o sistema.

Neste estudo, optou-se pela utilização da versão original do TAM, conhecida como TAM 1, inicialmente proposta por Davis (1989). A adoção modelo TAM1 ao invés de outras extensões do TAM, foi uma decisão metodológica deliberada, baseada na natureza específica e nos requisitos desta pesquisa. O TAM 1, sendo o modelo original e mais simplificado, proporciona uma análise clara e concentrada das duas variáveis mais impactantes na aceitação de tecnologia: a utilidade percebida e a facilidade de uso percebida. Embora outras extensões do TAM ofereçam um espectro mais amplo de variáveis e um entendimento mais detalhado dos processos cognitivos e influências externas que afetam a aceitação do usuário, sua complexidade adicional pode não ser necessária para todos os

---

<sup>1</sup> <https://atlasti.com>

estudos de aceitação de tecnologia. Para esta tese, o foco está em capturar um retrato preciso e direto do comportamento de aceitação dos usuários em relação ao sistema de recomendação de música proposto, sem a necessidade de desvendar as camadas adicionais de influência. Além disso, a utilização do TAM 1 é justificada por seu reconhecido poder preditivo e sua ampla aplicabilidade em variados contextos tecnológicos, conforme demonstrado em estudos anteriores (TEIXEIRA; ZAINA, 2022; ROSLY; KHALID, 2018).

### 6.2.1 Aplicando o TAM

Elaborou-se um instrumento no Google Forms, baseado nas questões do Modelo de Aceitação de Tecnologia (TAM), para coletar a aceitação dos participantes à abordagem proposta. Seis itens foram estabelecidos para mensurar cada construto, isto é, utilidade percebida, facilidade de uso percebida e intenção de uso. Os itens selecionados foram previamente adotados e validados para uso no TAM (DAVIS, 1989; VENKATESH et al., 2003). As questões do TAM foram ajustadas para se ajustarem ao contexto de um aplicativo de recomendação de música.

As questões de utilidade percebida se centraram em como o aplicativo MixFy auxilia na descoberta de música, recomendações e aprendizado das preferências do usuário. As perguntas sobre facilidade de uso percebida focaram na interação dos participantes com o aplicativo MixFy, na sua amigabilidade e na facilidade com que os usuários se tornam proficientes. As questões de intenção de uso procuraram avaliar a probabilidade de os participantes continuarem a usar o aplicativo MixFy em diversos cenários, como compartilhamento de localização ou avaliação constante de recomendações.

Os participantes responderam às questões em uma escala Likert de quatro pontos, com 1 indicando 'Discordo Fortemente' e 4 sendo 'Concordo Fortemente'. Garland (1991), Johns (2005) argumentam que uma escala pequena sem um ponto central (neutro ou não sei) favorece uma resposta mais precisa do participante, pois o respondente frequentemente usa o ponto neutro para evitar um possível conflito de opinião com o pesquisador.

Ao concluir o MISI, os participantes responderam ao questionário do TAM para avaliar sua percepção do aplicativo MixFy. A cada participante foi enviado um link para o questionário por e-mail, garantindo que suas respostas fossem capturadas com precisão e pudessem ser corretamente atribuídas.

## 6.3 Resultados

Esta seção apresenta os resultados da implementação da abordagem para recomendação de músicas dependente do contexto. A estrutura desta seção abrange três subseções essenciais: Análise MISI: Falhas Semióticas e Experiência do Usuário, Análise TAM: Percepções e Intenções do Usuário, e Análise Cruzada dos Achados do MISI e TAM. Nestas



subseções, os resultados baseados em uma avaliação temática das respostas dos participantes e uma inspeção semiótica intermediária do sistema são divulgados.

### 6.3.1 MISI: Falhas semióticas e experiência do usuário

Em decorrência de nossa análise temática, identificaram-se 3 categorias relevantes acerca da experiência dos participantes com o MixFy. A primeira categoria foi a **novidade nas recomendações**. Os participantes se mostraram motivados durante a interação com a plataforma pelas sugestões recebidas para músicas desconhecidas que se adequavam bem ao seu estilo musical preferido. Um dos participantes relatou: "*Isso me fez querer usar mais o aplicativo no meu dia a dia para que possa me recomendar mais músicas que eu ainda não conheço.*"(P2).

A segunda categoria foi as **atualizações contínuas**. Sempre que os participantes procuravam por novas recomendações e avaliavam as sugestões recebidas, notavam que a lista era atualizada. O participante 6 (P6) disse, "*Algumas músicas foram repetidas, mas toda vez que eu envio uma avaliação, a próxima sugestão volta mais refinada e assertiva.*". Outro comentário foi, "*Percebi que as recomendações estavam ficando cada vez melhores. Elas pertencem cada vez mais ao meu gênero musical favorito.*"(P3). Todos os participantes relataram, de forma geral, perceber uma atualização constante nas listas sugeridas.

Por fim, a terceira categoria foi o **interesse em avaliar**. Os participantes P1, P2, P5, P6 e P8 fizeram comentários explícitos quando perceberam que as atualizações constantes das listas sugeridas estavam diretamente ligadas às suas avaliações. Além disso, relataram que consideravam os emojis adequados para expressar sua apreciação pela recomendação sugerida. O participante P5 comentou: "*Nesta última tarefa, foi difícil selecionar cinco músicas que eu não gostei porque as sugestões de músicas foram muito precisas. Acredito que seja por causa das minhas avaliações*". Da mesma forma, o participante P2 comentou: "*Eu estava ansioso para reavaliar as músicas para ver o que o aplicativo recomendaria.*".

Utilizando o MISI, a metamsagem foi reconstruída de duas maneiras. Primeiramente, com a reconstrução da metamsagem de cada participante na inspeção da documentação e na inspeção dos signos (estáticos e dinâmicos). Depois, consolidaram-se as metamsagens individuais dos participantes e como resultado gerou-se uma única metamsagem reconstruída.

Os resultados indicaram que a percepção dos participantes sobre a metamsagem pretendida estava de acordo com objetivos do estudo. Os participantes, em geral, compreenderam que o sistema era destinado para pessoas que procuram por novas músicas que se encaixem em seu contexto atual sem necessidade de busca manual. Uma hipótese para a fácil compreensão dos participantes pode ser que eles já estavam familiarizados com a ideia de recomendações e uma vez que o contexto é explicitado na interface puderam compreender a ideia.

A metamensagem identificada na etapa de inspeção dos signos de metacomunicação sempre estava consistente com aquela identificada na etapa de inspeção dos signos estáticos e dinâmicos. Todos os participantes entenderam claramente que o sistema foi projetado para ajudá-los a encontrar automaticamente músicas que se ajustam ao seu contexto atual. Eles também conseguiram selecionar efetivamente um contexto e identificar que as músicas recomendadas eram adequadas a esse contexto específico. Os participantes puderam compreender a associação entre os contextos e as músicas recomendadas, bem como o impacto de suas avaliações nas recomendações do sistema. Com base em sua compreensão, forneceram insights sobre como utilizariam o sistema diariamente e ofereceram sugestões para melhorá-lo.

O MISI é um método que se concentra na avaliação da comunicabilidade do sistema. Embora a metamensagem geral tenha sido bem transmitida aos usuários, os resultados apontaram para algumas quebras de comunicação específicas que impactaram o uso do sistema pelos participantes e sua experiência.

Uma das maiores dificuldades dos participantes foi entender a funcionalidade de popularidade. A popularidade de uma música é uma métrica que varia de 0 a 100 que indica a sua popularidade geral no mundo. A popularidade de uma música é calculada com base no número de vezes que foi reproduzida e quão recentes são essas reproduções. No MixFy, existe um controle deslizante associado à popularidade (veja a Figura 9-a) destinado para que os usuários selecionem a faixa de popularidade das músicas a serem consideradas na recomendação. No entanto, o significado pretendido deste elemento não estava claro para os participantes. Uma solução seria alterar o termo utilizado na interface para "Popularidade mundial", e provavelmente incluir um signo metalinguístico que explicaria seu significado para os usuários (sob demanda).

Além disso, o MixFy permite que o participante ouça apenas uma prévia de uma música selecionada. A música inteira geralmente poderia ser ouvida diretamente no Spotify. Assim, no MixFy foi destacado dois ícones, um para a prévia interna e outra para ouvir a música no Spotify. No entanto, o ícone para ouvir no Spotify só aparecia quando a URL de prévia da música não estava disponível para o sistema.

A inclusão da funcionalidade de pré-visualização foi uma decisão de design motivada pela característica particular do MixFy que não constitui uma plataforma autônoma de recomendação musical, mas se conecta a plataformas comerciais de grande utilização. Um exemplo disso é o Spotify, que, no entanto, não fornece à nossa aplicação a URL externa que possibilitaria a reprodução de uma prévia de música. Assim sendo, decidiu-se oferecer aos participantes a oportunidade de ouvir a prévia no MixFy, caso disponível, e, na ausência desta, a opção de escutar a música integralmente no Spotify.

Apesar de todos os participantes terem conseguido ouvir a música antes de realizar uma avaliação, os participantes P1, P3 e P8 relataram que preferiam ouvir a música inteira diretamente no Spotify e que o MixFy poderia oferecer ambas as opções simultaneamente.

Em particular, o participante P3 considerou ideal que o MixFy permitisse clicar no nome da música e iniciar a reprodução, ao invés de incluir um ícone de reprodução.

De outra forma, o participante P6 relatou: "*O MixFy poderia evitar que a busca por recomendações ocorresse enquanto ainda há avaliações que ainda não foram enviadas.*". Este comentário se deu porque P6 avaliou um conjunto de músicas e depois clicou no botão para receber novas sugestões de músicas sem enviar as avaliações que já havia feito. Assim, ele perdeu todas as avaliações que haviam sido feitas anteriormente. Para corrigir este problema, sugere-se bloquear o botão para buscar recomendações enquanto os usuários estiverem avaliando. Quanto à abordagem de recomendação, recebemos alguns comentários.

Apenas os participantes P4 e P8 relataram que sentiram falta de músicas mais populares ("*Encontrei poucas músicas que estão entre as 50 mais.*") e músicas pertencentes a gêneros mais regionais. Entende-se que ao melhorar a apresentação do termo popularidade, os participantes terão uma melhor compreensão do controle deslizante de popularidade. Como resultado, poderão indicar, usando o controle deslizante, que querem receber recomendações para músicas recentes e populares (ou seja, que foram tocadas muitas vezes). Quanto ao problema relacionado à necessidade de músicas com gêneros locais na lista de músicas recomendadas, podemos resolvê-lo com novos estudos que nos permitirão incluir uma lista mais extensa de gêneros permitidos em nossa abordagem de recomendação.

### 6.3.2 TAM - Percepções e intenções do usuário

Foram conduzidas três categorias distintas de análises com o intuito de avaliar de forma integral os dados coletados a partir do TAM: coeficiente de Cronbach, média, desvio padrão e análise de correlação. Tais análises distintas possibilitaram a avaliação da confiabilidade do TAM, os aspectos quantitativos das respostas e a relação entre as variáveis distintas.

A fase inicial da investigação dos dados coletados se concentrou na confiabilidade interna do questionário aplicado, a qual foi averiguada por meio do coeficiente de Cronbach. Esse índice é amplamente adotado para mensurar a consistência das respostas aos itens de um instrumento de pesquisa, sendo valores acima de 0,7 geralmente considerados aceitáveis (TABER, 2018). No caso do constructo de utilidade percebida identificado na Tabela 20 entre Q1 e Q6, foi obtido um coeficiente de Cronbach de 0,713, o que denota adequada consistência para esses itens. Quanto às questões que dizem respeito à facilidade de uso percebida (Q7 a Q12) e à intenção de uso (Q13 a Q18), os coeficientes obtidos foram de 0,810 e 0,764, respectivamente, indicando uma confiabilidade interna robusta para esses segmentos do questionário. Quando todas as questões foram analisadas, o questionário do TAM apresentou um coeficiente de Cronbach de 0,829, o que sugere notável confiabilidade interna para o instrumento de pesquisa empregado neste estudo. Após a confirmação da

Tabela 20 – Média, desvio padrão e coeficiente alfa de Cronbach por questão e construto (utilidade percebida, facilidade de uso percebida, intenção de uso).

Questões			Construtos				Alfa de Cronbach
	Média	Desvio Padrão	Média	Desvio Padrão	Alfa de Cronbach	Construtor	
Q1	3.6	0.52	3.44	0.68	0.713	Utilidade Percebida	0.829
Q2	3.8	0.46					
Q3	3.4	0.52					
Q4	3.5	0.53					
Q5	3.9	0.35					
Q6	2.5	0.76					
Q7	3.8	0.46	3.63	0.49	0.810	Facilidade de Uso Percebida	
Q8	3.6	0.52					
Q9	3.5	0.53					
Q10	3.8	0.46					
Q11	3.4	0.52					
Q12	3.8	0.46					
Q13	3.0	0.76	3.38	0.76	0.764	Intenção de Uso	
Q14	3.6	0.74					
Q15	3.5	0.76					
Q16	3.3	0.46					
Q17	3.4	1.06					
Q18	3.5	0.76					

consistência do questionário, procedeu-se à investigação da média e do desvio padrão das respostas para cada pergunta, bem como para cada constructo do TAM.

Foram avaliadas as três dimensões do TAM: utilidade percebida, facilidade de uso percebida e intenção de uso. Cada dimensão foi analisada considerando suas respectivas seis questões e as respostas dos participantes disponíveis em uma escala Likert de 4 pontos. O constructo de utilidade percebida apresentou uma média geral de 3,44 em um valor máximo de 4 (ver Tabela 20). Esta média sugere que o MixFy é visto pelos participantes como uma ferramenta útil para encontrar e recomendar música com base em suas preferências pessoais e contextuais. A funcionalidade do sistema que os usuários perceberam como mais útil no constructo de utilidade percebida foi Q5 ("MixFy permite avaliar as recomendações oferecidas constantemente"), pois apresentou a pontuação mais alta (ou seja, 3,5) e menor desvio padrão. No entanto, a questão Q6, que avalia a capacidade do MixFy de evitar recomendações fora do estilo musical preferido, teve uma pontuação média de 2,5, indicando que esta característica do MixFy possivelmente

necessita de melhorias.

O constructo de facilidade de uso percebida apresentou uma média de 3,63, o que indica que os participantes consideram o MixFy fácil de usar e entender, já que o baixo valor do desvio padrão reforça essa percepção. As questões Q7, Q10 e Q12 obtiveram a maior média e se relacionaram com a flexibilidade e facilidade de uso do MixFy.

Finalmente, a intenção de uso teve uma média geral de 3,38 (ver Tabela 20). Esta média indica que os participantes estão inclinados a continuar usando o MixFy no futuro. No entanto, esta dimensão mostrou maior variabilidade de resposta, indicando diferenças na disposição dos participantes em continuar usando o MixFy. A questão Q17, que perguntava sobre a disposição dos participantes em compartilhar sua localização, teve o maior desvio padrão. Este desvio padrão sugere que não há consenso nas respostas dos participantes sobre o compartilhamento de sua localização.

Com o objetivo de compreender melhor as relações entre os constructos do TAM, foi conduzida uma análise de correlação, adotando-se o Coeficiente de Correlação de Pearson (R) e o Coeficiente de Determinação ( $R^2$ ), veja Tabela 21 (a) e (b), respectivamente. Esta abordagem identifica e quantifica as relações entre a utilidade percebida, a facilidade de uso percebida e a intenção de uso.

Tabela 21 – Coeficientes de Correlação de Pearson.

(a) Coeficientes de Correlação de Pearson (R)				(b) Coeficiente de Correlação de Pearson ( $R^2$ )			
	PU	PEU	IU		PU	PEU	IU
PU	1	0.27	0.68	PU	100%	7%	46%
PEU	0.27	1	0.71	PEU	7%	100%	51%
IU	0.68	0.71	1	IU	46%	51%	100%

Na Tabela 21a, o coeficiente R, que mede a correlação entre os constructos, apresentou um valor de 0,27 na relação entre Utilidade Percebida (UP) e Facilidade de Uso Percebida (FUP). Esta baixa correlação positiva sugere que as percepções de utilidade e facilidade de uso do aplicativo MixFy estão levemente associadas. A Tabela 21a também mostra que a correlação entre utilidade percebida (UP) e Intenção de Uso (IU) resultou em um coeficiente R de 0,68, indicando uma correlação de magnitude média a alta. Este valor do coeficiente sugere que a utilidade percebida influencia significativamente a intenção de uso. A relação entre facilidade de uso percebida (FUP) e intenção de uso (IU) apresentou um coeficiente R de 0,71, demonstrando uma forte correlação positiva. Ou seja, a facilidade de uso percebida do MixFy está fortemente relacionada à intenção de usá-lo.

Ao examinar o coeficiente  $R^2$ , que é ilustrado na Tabela 21b, e que denota a porção da variação em uma variável dependente previsível a partir da variável independente, nota-se que 7% da variação na utilidade percebida (UP) pode ser explicada pela facilidade de uso percebida (FUP). Tal variação evidencia que aprimoramentos na utilidade percebida não necessariamente resultam em melhorias na facilidade de uso percebida e reciprocamente.

Paralelamente, verifica-se que a utilidade percebida (UP) é capaz de esclarecer 46% da variação na intenção de uso (IU), enquanto a facilidade de uso percebida (FUP) explica 51% da variação na intenção de uso (IU).

As descobertas indicam que, apesar da predominância de uma percepção favorável em relação ao MixFy e da manifesta intenção de continuar utilizando-o no futuro por parte dos usuários, ainda há espaço para refinamentos, sobretudo no que tange ao incremento da utilidade percebida e da facilidade de uso. Estas conclusões também reforçam a relevância de incorporar o feedback dos usuários no processo de elaboração do design e nas funcionalidades do aplicativo.

## 6.4 Discussão

Os resultados do Método de Inspeção Semiótica Intermediado (MISI) e do Modelo de Aceitação de Tecnologia (TAM) fornecem insights complementares sobre a percepção dos usuários em relação à abordagem MixFy e revelam várias vantagens positivas que distinguem o MixFy de outros sistemas de recomendação de música, bem como oferecem um caminho para melhorias futuras.

O TAM destacou que os usuários percebem o MixFy como uma ferramenta útil para descobrir música (média de 3,44). Em particular, os usuários reconheceram a capacidade do MixFy de permitir avaliações constantes. Esta capacidade valida a abordagem de interação do MixFy, enfatizando o feedback do usuário e adaptando as recomendações de acordo. No entanto, o MISI identificou algumas áreas de potenciais melhorias, como a característica de popularidade e a capacidade do MixFy de evitar recomendações fora do estilo musical preferido do usuário. Estes problemas podem afetar a utilidade percebida do MixFy, sugerindo que melhorias nestes aspectos podem aumentar a utilidade percebida.

No TAM, os usuários demonstraram uma intenção geral de continuar usando o MixFy (média de 3,38). Este valor sugere que os usuários veem valor contínuo no uso do MixFy e estão satisfeitos com a experiência geral proporcionada pela plataforma. No entanto, o MISI destacou que alguns usuários preferem ouvir a música inteira no Spotify, e a sugestão de tornar mais fácil ouvir a música diretamente no Spotify pode melhorar a intenção de uso.

Através do TAM, é evidenciado que existe uma relação robusta entre a utilidade percebida e a facilidade de uso, ambas associadas à intenção de uso. Tal correlação indica que aperfeiçoamentos sugeridos pelo MISI, como o incremento na explicitação da função de popularidade e a oferta de uma experiência de audição mais fluida, têm potencial para influenciar de maneira considerável a intenção dos usuários em utilizar o MixFy.

A forte correlação entre utilidade percebida e intenção de uso ( $R=0,68$ ) reforça o valor do MixFy para os usuários. Esta forte relação pode diferenciar o MixFy de outros sistemas de recomendação que não conseguem um equilíbrio igual entre utilidade e intenção de uso.

A correlação positiva entre a facilidade de uso percebida e a intenção de uso ( $R=0,71$ ) sugere que o MixFy consegue um equilíbrio entre ser uma ferramenta poderosa e ser fácil de usar. Essa correlação pode também diferenciar o MixFy de outras ferramentas de recomendação musical que podem ser poderosas, mas difíceis de usar.

A análise combinada dos resultados de MISI e TAM sugere que o MixFy alivia significativamente o problema do início frio e o esforço cognitivo do usuário. Os resultados do TAM indicam que os usuários percebem o MixFy como uma ferramenta útil para descoberta de música já a partir do primeiro uso, sugerindo que o MixFy pode fornecer recomendações valiosas mesmo para novos usuários. Além disso, a possibilidade de avaliar constantemente as recomendações (Q5 do TAM) foi muito valorizada pelos usuários, indicando que o MixFy é eficaz na coleta de feedback do usuário e na adaptação de suas recomendações de acordo. Esta possibilidade é crucial para superar o problema do início frio, pois permite ao MixFy "aprender" rapidamente sobre as preferências do usuário e melhorar suas recomendações.

Em relação ao esforço cognitivo, os resultados do TAM mostram que os usuários consideram o MixFy fácil de usar (média de 3,63), o que sugere que o sistema pode minimizar o esforço cognitivo exigido dos usuários. Além disso, os resultados do MISI indicam que os usuários entendem claramente a comunicação do sistema, sugerindo que o MixFy apresenta as informações de forma compreensível e intuitiva.

Adicionalmente, a intenção de uso no TAM teve uma média de 3,38, indicando que os usuários estão inclinados a continuar usando o MixFy no futuro. Este valor médio sugere que o esforço cognitivo requerido para usar o MixFy é aceitável para os usuários, reforçando a capacidade do sistema de lidar com este problema.

## 6.5 Considerações finais

Neste estudo, propôs-se e avaliou-se o MixFy, uma abordagem para recomendação de música baseada no contexto atual do usuário (trabalhando, praticando exercícios, dirigindo ou em casa). Com o objetivo principal de aumentar a satisfação do usuário e melhorar a qualidade das recomendações, a abordagem foi avaliada com dois métodos complementares: o Método Inspeção Semiótica Intermediado (MISI), que permite avaliar de forma crítica se o sistema comunica efetivamente suas intenções e princípios de interação, e o Modelo de Aceitação Tecnológica (TAM), que fornece uma medida eficiente da aceitação do usuário e do uso potencial do MixFy.

Para contornar o problema de cold-start na abordagem proposta, foi necessário, inicialmente, estudar a natureza das playlists que os usuários elaboram diariamente para contextos específicos. Em consequência desse estudo, identificou-se um conjunto de valores mínimos e máximos para cada recurso de áudio que reflete a música que os usuários podem apreciar no contexto definido. Desenvolveu-se um aplicativo móvel para a imple-

mentação da abordagem MixFy. O aplicativo foi integrado à API do Spotify, propiciando uma vasta biblioteca de músicas e acesso aos recursos de áudio de cada faixa.

Os resultados obtidos por meio do MISI revelaram que o sistema apresenta alta comunicabilidade, ou seja, é capaz de transmitir com êxito sua metagemensagem aos participantes. Foram identificadas algumas falhas de comunicação, porém estas estão, em sua maioria, relacionadas a sinais estáticos e podem ser facilmente resolvidas. Adicionalmente, por meio da análise, foram identificadas três categorias que os participantes consideraram relevantes para sistemas de recomendação de música: a novidade das recomendações, atualizações contínuas e o interesse dos usuários em avaliar.

A análise feita através do TAM revelou uma forte correlação entre a facilidade de uso percebida e a intenção de uso, bem como uma correlação de magnitude média a alta entre a utilidade percebida e a intenção de uso. Tais descobertas apoiam a eficácia da abordagem MixFy.

Em resumo, a abordagem proposta pode melhorar significativamente a qualidade das recomendações musicais e aumentar a satisfação do usuário em sistemas de recomendação de música. A eficácia do MISI e do TAM em proporcionar uma avaliação abrangente enfatiza o valor desses instrumentos na análise da experiência do usuário em aplicações análogas.



---

## Capítulo 7

# Avaliando a Arquitetura UConteXt Arch a partir da Experiência do Usuário

---

*Este estudo conclui o ciclo de design e avaliação da eficácia da arquitetura. A análise da interação dos usuários com o aplicativo MixFy, assim como os dados coletados pelo UX Curves e pelo questionário TAM, fornecem um feedback importante. Este feedback confirma a viabilidade da arquitetura proposta e sugere direções para futuras melhorias. O processo de avaliação descrito neste capítulo envolveu duas iterações significativas. A primeira iteração consistiu na utilização prática do MixFy pelos usuários, coletando dados iniciais sobre a eficácia da arquitetura. A segunda iteração utilizou esses dados para realizar melhorias e avaliar novamente, resultando na versão final da arquitetura.*

A avaliação de sistemas interativos é uma prática consolidada e fundamental na literatura (ARDÉVOL et al., 2013; COLLAZOS; SALTIVERI; HUITR, 2014; PRIBEANU, 2017). Dentro do escopo desta pesquisa, a aplicação MixFy é considerado como uma instância concreta da arquitetura UConteXt Arch subjacente. A validação da arquitetura é realizada por meio da análise da interação dos usuários com o aplicativo, refletindo a aplicabilidade prática do modelo proposto.

A investigação inicial envolvendo 8 participantes apresentada no Capítulo 6 proporcionou compreensões iniciais sobre a interação do usuário com a arquitetura. Entretanto, estudos adicionais são necessários para uma compreensão mais abrangente, conforme destacado por Esteve, Forkey e Clark (2021). Os autores apontam que um espectro mais

amplo de experiências de usuários é essencial para uma avaliação mais abrangente de qualquer sistema interativo.

## 7.1 Avaliações de UX ao longo do tempo

Até poucos anos atrás, os estudos da UX se concentraram principalmente nas avaliações de curto prazo e nos aspectos relacionados à adoção inicial do design de novos produtos (MARTI; IACONO, 2016). Recentemente, um número crescente de estudos começou a se concentrar na avaliação das mudanças na experiência de uma pessoa na interação com um produto ao longo do tempo (WILAMOWITZ-MOELLENDORFF; HASSENZAHL; PLATZ, 2006; MENDOZA; NOVICK, 2005; KARAPANOS et al., 2010). Conseqüentemente, novos métodos e modelos foram definidos para entender como a relação entre o usuário e o produto evolui ao longo de longos períodos de tempo. Karapanos et al. (2009) desenvolveram a "Curva UX", um método que visa auxiliar os usuários a relatar retrospectivamente como e por que sua experiência com um produto mudou ao longo do tempo. Mahlke e Thüring (2007) desenvolveram um modelo que define três componentes da experiência do usuário: percepção de qualidades instrumentais (usabilidade e utilidade), reações emocionais e percepção de qualidades não-instrumentais (apelo e atratividade). Aplicando este modelo, os autores forneceram evidências de que qualidades instrumentais e não instrumentais influenciam as reações emocionais no uso de sistemas interativos.

Entretanto, a maioria dos atuais métodos de avaliação UX ainda se concentra em episódios de comportamento único e avaliações momentâneas. Vermeeren et al. (2010) relatam que apenas 36% dos métodos se concentram em períodos de experiência de longo prazo. Embora medir os primeiros encontros e experiências momentâneas seja importante para coletar feedback dos usuários em particular nas primeiras fases de prototipagem do processo de desenvolvimento (VERMEEREN et al., 2010), pesquisas recentes demonstraram que diferentes aspectos da experiência do usuário mudam com o tempo (FENKO; SCHIFFERSTEIN; HEKKERT, 2010; KARAPANOS et al., 2009).

Roto et al. (2015) realizou um estudo e definiu a experiência em quatro: experiência antecipada, experiência momentânea, experiência episódica e experiência lembrada (acumulada). UX antecipado refere-se às expectativas que uma pessoa tem antes do primeiro encontro com o produto. UX momentâneo refere-se a episódios de interação individual e à mudança percebida no uso. UX Episódico refere-se a um episódio de uso extrapolado a partir de um evento de interação mais amplo. UX lembrado refere-se à memória do usuário após ter usado o sistema por um tempo.

Marti e Iacono (2016) realizaram um estudo de médio prazo comparando os quatro tipos de UX: **Antecipado**, **Momentânea**, **Episódico** e Experiência **Lembrada (ou Acumulada)**. O estudo comparou a experiência de dez usuários de um pedômetro/aplicativo de ajuste que conta etapas e calorias queimadas durante todo o dia. Os

resultados mostram que a experiência de uso mudou ao longo do tempo, diminuindo significativamente antes, durante e após a interação. O julgamento avaliativo relacionado à satisfação geral com o produto, foi em grande parte formado com base em uma expectativa inicial elevada sobre aspectos pragmáticos (isto é, utilidade e usabilidade) antes e durante os primeiros encontros. Após quatro semanas de uso, os problemas relacionados à usabilidade, confiabilidade dos dados e drenagem da bateria se tornaram um aspecto dominante de quão bom o produto foi percebido. As qualidades hedônicas e a atratividade também foram afetadas negativamente.

## 7.2 Método UX Curves e TAM

Durante um período de interação de cinco dias, o estudo aplicou o método UX Curves, conforme descrito por Kujala et al. (2011). O método UX Curves é uma técnica de avaliação da experiência do usuário que permite a análise longitudinal e detalhada das percepções e sentimentos dos usuários ao longo do tempo. Especificamente, este método envolve solicitar aos usuários que traçam curvas representando suas experiências positivas e negativas com um produto ou serviço, com momentos significativos marcados ao longo destas curvas. Em cada ponto significativo identificado nas curvas, os usuários tinham a oportunidade de adicionar comentários explicativos. Essa abordagem possibilitou um entendimento mais profundo do contexto de uso em que a arquitetura estava sendo utilizada, oferecendo compreensões valiosas sobre as mudanças na percepção do usuário ao longo do tempo.

Após os cinco dias de interação, o questionário TAM foi aplicado para avaliar a aceitabilidade da tecnologia. O objetivo desta avaliação era entender como os usuários percebiam a arquitetura UConteXt Arch, baseando-se em suas experiências com o aplicativo. Desta forma, o questionário TAM não só coleta as impressões finais dos usuários sobre o aplicativo MixFy, mas também fornece compreensões sobre a eficácia da arquitetura subjacente em atender às necessidades e expectativas do usuário.

A seguir serão apresentados as etapas de planejamento e condução da avaliação, bem como os resultados e discussões.

## 7.3 Planejamento da avaliação

Esta seção detalha o planejamento metodológico que orientou a avaliação da arquitetura UConteXt Arch, utilizando a instância prática representada pela aplicação MixFy em um contexto de uso real. O **escopo** do estudo foi estruturado com o intuito de avaliar a efetividade da arquitetura em um ambiente aplicado. O direcionamento foi fundamentado em estudos (FLORES-MARTÍN et al., 2022; COBALEDA et al., 2016; ALI et al., 2020), que enfatizam a importância de validar arquiteturas em ambientes reais para uma compre-

ensão aprofundada de sua eficácia, permitindo um exame criterioso da sua aplicabilidade e adaptabilidade.

O **recrutamento** dos participantes, conduzido durante um período de duas semanas, resultou na seleção de 44 alunos de graduação, compreendendo 17 mulheres e 27 homens, com uma distribuição que refletiu a diversidade de contextos usuais de escuta musical: em casa, trabalhando, dirigindo e praticando atividades físicas. Os critérios de inclusão foram estabelecidos para assegurar que os sujeitos fossem usuários habituais de sistemas de streaming de música, proporcionando assim uma avaliação fundamentada em experiências cotidianas com tecnologias de recomendação musical.

Para a **coleta de dados**, foram selecionados métodos capazes de capturar tanto a evolução temporal da experiência do usuário quanto suas impressões consolidadas após a interação com o sistema. O método UX Curves, conforme descrito por Kujala et al. (2011), foi escolhido pela sua capacidade de registrar a trajetória da experiência do usuário, fornecendo compreensões sobre a interação dinâmica com a arquitetura ao longo do tempo. Este método é particularmente relevante para identificar como os usuários se adaptam e respondem aos componentes da arquitetura, como a personalização das recomendações e a resposta ao contexto do usuário.

Paralelamente, o TAM foi empregado como um instrumento de avaliação conclusiva, conforme estabelecido por Davis (1989). Este método oferece uma avaliação da aceitação da tecnologia, medindo dimensões como a utilidade percebida e a facilidade de uso, que são indicativos diretos da eficiência dos mecanismos de interface e integração presentes na arquitetura UConteXt Arch. Ao se aplicar o TAM após um período de interação intensiva, espera-se capturar uma visão cumulativa e integrada das percepções dos participantes.

O instrumento do TAM, implementado por meio do Google Forms, incluiu 18 questões distribuídas equitativamente entre as dimensões da utilidade percebida, facilidade de uso e intenção de uso. As perguntas foram elaboradas para refletir aspectos específicos da arquitetura, como a eficácia da descoberta de novas músicas e a precisão das recomendações, visando entender a aceitação da arquitetura por parte dos usuários.

Ao integrar estes métodos de coleta de dados, a pesquisa visa fornecer uma análise abrangente da experiência do usuário com a arquitetura UConteXt Arch, através da aplicação MixFy. Esta abordagem multifacetada permite uma compreensão aprofundada não somente da relação do usuário com o sistema ao longo do tempo, mas também de suas percepções gerais após um período de uso substancial.

## 7.4 Condução da avaliação

No período de maio a junho de 2023, foi executada a fase empírica deste estudo, que requereu dos participantes uma interação contínua com instância prática da arquitetura. A fim de assegurar consistência metodológica e controlar variáveis externas, definiu-se

que a avaliação transcorresse ao longo de cinco dias consecutivos, permitindo flexibilidade para acomodar a disponibilidade de cada participante. Esta escolha foi embasada na literatura, que ressalta a importância da consistência e da continuidade na coleta de dados em estudos longitudinais (SIDEN et al., 2010; LAFIT et al., 2020).

A avaliação foi desenvolvida nos ambientes naturais dos participantes, distanciando-se de contextos controlados de laboratório. Durante o período de avaliação, os participantes empregaram o método UX Curves para registrar diariamente a sua experiência, identificando momentos de destaque na interação (positivos ou negativos) e fornecendo comentários descritivos para cada ponto marcado no gráfico.

Seguindo a fase de uso intensivo, os participantes foram solicitados a completar o questionário TAM, o qual objetivou captar as percepções acumuladas e avaliar a aceitabilidade da tecnologia (UConteXt Arch). As respostas ao questionário foram coletadas utilizando uma escala Likert de quatro pontos, intencionalmente excluindo o ponto neutro para encorajar uma decisão mais definida por parte dos respondentes, seguindo as orientações de Garland (1991) e Johns (2005).

## 7.5 Resultados

Esta seção divulga os resultados coletados durante a avaliação da arquitetura UConteXt Arch, operacionalizada pela aplicação MixFy. Os dados foram reunidos empregando duas metodologias distintas: TAM e UX Curves. O propósito desta análise sistemática foi extrair percepções aprofundadas sobre a facilidade de uso, utilidade percebida e intenção de uso. As subseções a seguir detalham os resultados de cada metodologia, estabelecendo uma correlação entre os dados coletados e o funcionamento da arquitetura no contexto prático, além de identificar possíveis pontos de aprimoramento para a arquitetura proposta.

### 7.5.1 TAM: Perspectivas e motivações dos usuários

Neste estudo, a avaliação dos dados obtidos pelo TAM focou não apenas na aplicação MixFy, mas em como os usuários percebem a arquitetura UConteXt Arch subjacente. Uma abordagem analítica abrangente foi adotada, envolvendo a confiabilidade do instrumento via coeficiente de Cronbach, análise quantitativa das médias e desvios padrão, análise de correlação e regressão para entender as relações preditivas entre as variáveis. Essa combinação de técnicas proporcionou compreensões detalhadas sobre a utilidade, facilidade de uso e intenção de uso contínuo da arquitetura.

Tabela 22 – Média, desvio padrão e coeficiente alfa de Cronbach por questão e construto (utilidade percebida, facilidade de uso percebida, intenção de uso).

Questões			Construtos				Alfa de Cronbach
	Média	Desvio Padrão	Média	Desvio Padrão	Alfa de Cronbach	Construtor	
Q1	3.5	0.63	3.48	0.63	0.744	Utilidade Percebida	0.901
Q2	3.5	0.66					
Q3	3.4	0.61					
Q4	3.5	0.63					
Q5	3.4	0.66					
Q6	3.6	0.62					
Q7	3.5	0.63	3.52	0.60	0.734	Facilidade de Uso Percebida	
Q8	3.6	0.58					
Q9	3.4	0.66					
Q10	3.6	0.58					
Q11	3.5	0.59					
Q12	3.4	0.59					
Q13	3.5	0.59	3.59	0.58	0.738	Intenção de Uso	
Q14	3.7	0.71					
Q15	3.5	0.55					
Q16	3.6	0.58					
Q17	3.6	0.54					
Q18	3.6	0.54					

### 7.5.1.1 Análise descritiva e correlacional

A validação da confiabilidade interna do questionário foi realizada pelo coeficiente alfa de Cronbach. Coeficientes superiores a 0,7 são considerados indicativos de boa consistência (TABER, 2018). Os valores foram superiores a 0,7 para todos os constructos, como pode ser visto na Tabela 22, sugerindo uma percepção da arquitetura de maneira consistente.

O constructo de utilidade percebida, conforme especificado na Tabela 22 de Q1 a Q6, o alfa de Cronbach registrado foi de 0,744, sinalizando uma consistência interna satisfatória. Para as questões relacionadas à facilidade de uso percebida (Q7 a Q12) e intenção de uso (Q13 a Q18), os coeficientes determinados foram de 0,734 e 0,738, respectivamente, reforçando uma confiabilidade sólida para estas seções. Analisando o questionário TAM como um todo, o coeficiente alfa de Cronbach alcançou 0,901, indicando uma robustez notável na confiabilidade do instrumento. Após esta validação, a análise prosseguiu para o estudo das médias e desvios padrão das respostas de cada item e constructo do TAM.

Os três domínios do TAM foram examinadas à partir de suas seis questões correspondentes, com as respostas dos participantes mensuradas por uma escala Likert de quatro pontos. O domínio de utilidade percebida registrou uma média global de 3,48 (conforme a Tabela 22). Este valor médio indica que o MixFy é percebido pelos respondentes como um instrumento valioso na detecção e sugestão de músicas alinhadas às suas inclinações pessoais e contextuais. Conseqüentemente, isso reforça a eficácia dos módulos de Contexto e Preferências Musicais e de Recomendações, como evidenciado pelas questões Q1 a Q6. Por exemplo, a alta pontuação em Q6 ressalta a eficiência do módulo de Predição Adaptativa da arquitetura em aprimorar a precisão das recomendações musicais.

O domínio da facilidade de uso percebida obteve uma média de 3,52. Esse resultado sugere uma forte inclinação dos participantes em considerar a ferramenta intuitiva e compreensível. Isto também mostra que a Camada de Interface implementada foi intuitiva para os usuários, destacando o êxito da integração da Camada de Interface com os módulos de Filtragem de Músicas e de Integração com Plataformas Comerciais de Música. A limitada dispersão do desvio padrão amplifica essa interpretação. As questões Q6, Q8 e Q10 destacaram-se com médias mais altas, mas foram os itens Q8 e Q10, com desvio padrão de 0,58, que corroboram a ideia de que os usuários consideram a ferramenta fácil de usar.

Para a intenção de uso, as questões Q13 a Q18 refletiram uma média de 3,59, mostrando uma tendência positiva dos usuários em adotar continuamente o aplicativo, sugerindo que a experiência proporcionada pela proposta da Camada de Serviços e as funcionalidades de Recomendações foram bem recebidas e valorizadas. A questão Q14 obteve a média mais alta (3,7), apontando para uma alta valorização do processo de feedback e aprendizado contínuo.

Aprofundando a investigação, buscou-se explanar as relações intercorrentes entre os constructos do TAM. Para isso, realizou-se a análise do Coeficiente de Correlação de Pearson (R) e do Coeficiente de Determinação ( $R^2$ ) - detalhados nas Tabelas 23a e 23b. Com essa estratégia, foi possível identificar e quantificar os nexos entre utilidade percebida, facilidade de uso percebida e intenção de uso.

Tabela 23 – Coeficientes de Correlação de Pearson.

(a) Coeficientes de Correlação de Pearson (R)				(b) Coeficiente de Correlação de Pearson ( $R^2$ )			
	UP	FUP	IU		UP	FUP	IU
UP	1	0.78	0.92	UP	100%	61%	85%
FUP	0.78	1	0.93	FUP	61%	100%	87%
IU	0.92	0.93	1	IU	85%	87%	100%

A análise de correlação (veja a Tabela 23a) revelou relações fortes entre os construtos do TAM e os elementos da arquitetura. Por exemplo, a correlação positiva entre utilidade e facilidade de uso (coeficiente R de 0,78) reflete a interação entre a Camada de Serviços e

a Interface do Usuário. Além disso, altos coeficientes R (0,92 e 0,93) para as relações entre utilidade e intenção de uso, e facilidade e intenção de uso, respectivamente, enfatizam a influência direta da percepção da utilidade e da facilidade de uso da arquitetura sobre a vontade do usuário em continuar utilizando o sistema.

Aprofundando-se na interpretação dos dados, o coeficiente  $R^2$  (Tabela 23b) revelou que a facilidade de uso percebida (FUP) justifica 61% da variação observada na utilidade percebida (UP). Este dado sugere que intervenções focadas na utilidade podem significativamente se traduzir em melhorias percebidas na facilidade de uso, embora não garantam essa correlação de forma absoluta. Além disso, enquanto a utilidade percebida esclarece impressionantes 85% da variação na intenção de uso, a facilidade de uso responde por 93% dessa variação. Diante destes achados, fica claro que, mesmo com uma inclinação predominante favorável, há margem para otimizações, especialmente no aprimoramento da utilidade e facilidade percebidas.

Nos resultados do estudo inicial (Capítulo 6), foram destacadas métricas como o coeficiente R na relação entre a utilidade percebida (UP) e a facilidade de uso percebida (FUP) sendo 0,27, e na correlação entre UP e a intenção de uso (IU) sendo 0,68. Já no estudo atual, o coeficiente R para a relação entre UP e FUP foi de 0,78, enquanto para UP e IU foi de 0,92.

É importante destacar que o contexto e as características de cada estudo são únicos e fatores como ajustes na arquitetura e na demografia dos usuários podem influenciar os resultados. Também vale ressaltar que, neste segundo estudo, algumas questões do TAM sofreram ajustes de escrita. Além disso, a familiarização dos usuários com o aplicativo também pode ter influenciado suas percepções ao longo do tempo.

Ambos os estudos destacam a necessidade contínua de aprimoramento do aplicativo e da integração do feedback dos usuários em seu desenvolvimento.

### 7.5.1.2 Análise preditiva

Esta seção investiga as relações causais entre os construtores do Modelo de Aceitação de Tecnologia (TAM) e os itens específicos do questionário. Essa análise é importante porque fornece compreensões sobre as interações entre as variáveis observáveis e os construtores latentes, revelando os fatores determinantes da aceitação do usuário. Utilizando análise de regressão, essa seção decodifica a magnitude e direção das relações, evidenciadas pelos valores de  $R^2$  e coeficientes de caminho (beta).

Essas métricas são importantes para avaliar o impacto de cada construtor e item na formação das percepções e intenções do usuário, refletindo o funcionamento da Camada de Interface e a integração com o Módulo de Feedback na Camada de Middleware. Complementando a representação numérica (veja Tabela 24), a Figura 12 oferece uma perspectiva integrada do modelo TAM, destacando todas as suas interconexões e complexidades.



Tabela 24 – Parâmetros da Análise de Regressão para Construtores do TAM.

(a) Utilidade Percebida.

Questões	$R^2$	$\beta$	$\epsilon$
<b>Q1</b>	0.280	2.129	0.527
<b>Q2</b>	0.420	2.471	0.448
<b>Q3</b>	0.438	2.730	0.477
<b>Q4</b>	0.436	2.659	0.467
<b>Q5</b>	0.456	2.585	0.435
<b>Q6</b>	0.641	3.240	0.374
<b>Q7</b>	0.224	1.909	0.548
<b>Q8</b>	0.162	1.745	0.612
<b>Q9</b>	0.420	2.479	0.450
<b>Q10</b>	0.303	2.403	0.563
<b>Q11</b>	0.231	2.061	0.580
<b>Q12</b>	0.261	2.203	0.572

(b) Facilidade de Uso Percebida.

Questões	$R^2$	$\beta$	$\epsilon$
<b>Q1</b>	0.150	1.467	0.539
<b>Q2</b>	0.284	1.913	0.469
<b>Q3</b>	0.252	1.949	0.518
<b>Q4</b>	0.329	2.174	0.479
<b>Q5</b>	0.242	1.770	0.484
<b>Q6</b>	0.386	2.365	0.461
<b>Q7</b>	0.385	2.355	0.459
<b>Q8</b>	0.317	2.298	0.520
<b>Q9</b>	0.597	2.781	0.353
<b>Q10</b>	0.445	2.740	0.472
<b>Q11</b>	0.440	2.677	0.466
<b>Q11</b>	0.406	2.587	0.482

A Tabela 24a apresenta os parâmetros de regressão associados ao construtor "Utilidade Percebida"(UP). Ao examinar o coeficiente de determinação  $R^2$ , observa-se que a questão Q6, que se relaciona com o Módulo de Predição Adaptativa, apresenta o valor mais alto (0,641), indicando que aproximadamente 64,1% da variação na resposta pode ser explicada pelo modelo para essa questão específica. Em contraste, a questão Q8, que se relaciona com os Módulos de Contexto e Popularidade, com um  $R^2$  de 0,162, é o preditor menos explicativo, abordando apenas 16,2% da variação. Isso sugere que a questão Q6, relacionada ao Módulo de Predição Adaptativa, pode estar mais alinhada com a essência da "Utilidade Percebida" em comparação com a questão Q8.

No que diz respeito ao coeficiente Beta, a questão Q6 novamente se destaca com um valor de 3,240, sendo a mais inclinada, sugerindo uma forte relação positiva entre a questão e UP. Em contrapartida, a questão Q8, que se relaciona com os Módulos de Contexto e Popularidade, com um Beta de 1,745, possui a relação mais tênue. O erro padrão  $\epsilon$  é um indicador de variação dos valores previstos. Valores maiores, como 0,612 para a questão Q8, indicam maior variação, enquanto valores menores, como 0,353 para a questão Q9, relacionada ao Módulo de Feedback, sugerem previsões mais precisas.

Os resultados indicam que o Módulo de Predição Adaptativa está desempenhando seu papel efetivamente, conforme percebido pelos usuários. Eles reconhecem e valorizam como o sistema aprende com suas interações e preferências, resultando em sugestões de música altamente relevantes. Isso sugere que o Módulo de Recomendação está conseguindo capturar as preferências do usuário.

Por outro lado, a questão Q8 com o  $R^2$  baixo de 0,162, parece sugerir que o Módulo de Contexto e Popularidade não está alinhado fortemente com as expectativas dos usuários.

Entretanto, isso pode ter ocorrido pelo fato de que os usuários não entenderam a utilidade dos elementos de interface para selecionar a popularidade ou o contexto atual. A justificativa para isso é que a questão 3 obteve um  $R^2$  de 0,438 indicando que os usuários consideram que as músicas sugeridas estão de acordo com o seu contexto atual. Logo, o valor de Q8 baixo aponta para uma oportunidade de melhoria na camada de interface, em especial aos elementos de captura de contexto e popularidade.

Analisando o construtor "Facilidade de Uso Percebida"(FUP), observa-se padrões distintos em comparação com a "Utilidade Percebida". Ao avaliar o coeficiente de determinação  $R^2$ , a questão Q9, que se relaciona com o Módulo de Feedback, chama a atenção com um valor de 0,597, o que implica que cerca de 59,7% da variação na resposta para essa questão é explicada pelo modelo. Em contraste, a questão Q1, que se relaciona com os Módulo de Artistas Preferidos e Gêneros Musicais, com um  $R^2$  de apenas 0,150, sugere que apenas 15% da variação é justificada, tornando-se o preditor menos explicativo para FUP.

Em relação ao coeficiente Beta, a questão Q9 se sobressai novamente com um valor de 2,781, indicando uma forte relação positiva entre essa questão e FUP. Em contraste, a questão Q1, com seu Beta de 1,467, tem a associação mais fraca com FUP. Observando o erro padrão  $\epsilon$ , as variações são consistentes, mas é notável que a questão Q9 tem um valor mais baixo de 0,353, denotando previsões mais precisas, enquanto a questão Q1, com um erro de 0,539, sugere uma variação maior nos valores previstos.

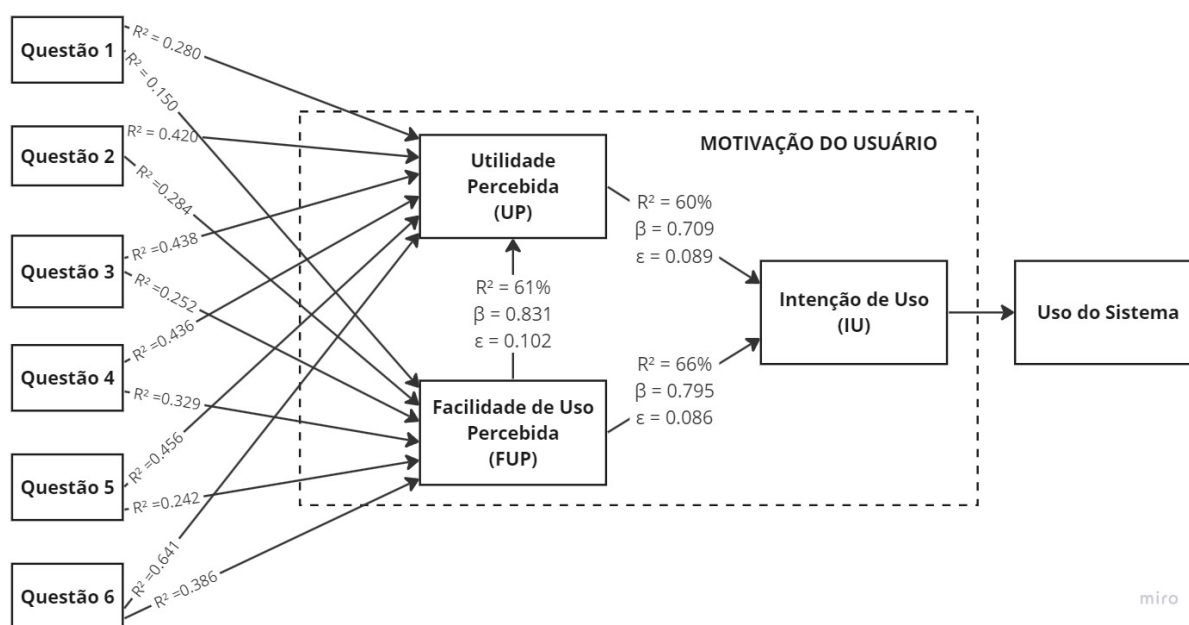
A "Facilidade de Uso Percebida", destacada pela questão Q9 sugere que o Módulo de Feedback está bem projetado, permitindo que os usuários forneçam avaliações de forma intuitiva. A alta precisão das previsões indicadas pelo baixo  $\epsilon$  confirma a facilidade com que os usuários podem interagir com este aspecto do sistema. Isso não apenas reforça a usabilidade da interface, mas também garante que o feedback do usuário seja capturado e utilizado para melhorar continuamente as recomendações.

Contudo, a questão Q1, no que concerne à 'Facilidade de Uso Percebida', ligada ao Módulo de Artistas Preferidos e ao Módulo de Gêneros Musicais, sugere que estes aspectos da arquitetura podem não estar tão evidentes ou sendo percebidos pelos usuários quando desejado. Isso aponta para uma oportunidade de aprimoramento, potencialmente revisando como essas preferências são capturadas e apresentadas ao usuário, para garantir que essa funcionalidade fundamental seja fácil de usar e contribua efetivamente para a experiência geral do usuário.

O Modelo de Aceitação de Tecnologia (TAM) representado na Figura 12 ilustra a influência das primeiras seis questões em relação aos construtores de "Utilidade Percebida" e "Facilidade de Uso Percebida". Estas questões, conforme discutido anteriormente, têm variados graus de explicação para a percepção de utilidade e facilidade de uso, com os valores de  $R^2$  reforçando a discussão apresentada nas tabelas precedentes.

O destaque das relações entre "Facilidade de Uso Percebida" e "Utilidade Percebida",

Figura 12 – Modelo de Regressão do TAM: Relações entre Questões e Construtores.



e ambas com a "Intenção de Uso", realça a eficácia dos componentes da UConteXt Arch. Observa-se que quando os usuários percebem o sistema como fácil de usar, a utilidade do mesmo é ampliada, com um  $R^2$  de 61%, implicando que a interface do usuário e os mecanismos de interação estão alinhados com uma experiência de usuário positiva. Além disso, a forte influência da "Utilidade Percebida" e da "Facilidade de Uso Percebida" na "Intenção de Uso", com  $R^2$  de 60% e 66% respectivamente, sublinha a importância de uma arquitetura que não só funcione bem tecnicamente, mas que também seja compreensível e acessível aos usuários. Os valores de  $\beta$  e  $\epsilon$  destacam a força e precisão dessas relações.

### 7.5.2 UX Curves: Análise da jornada do usuário

Nesta análise, as mudanças nas percepções dos usuários são exploradas em relação aos componentes estruturais da arquitetura UConteXt Arch durante cinco dias. O uso de métricas estatísticas descritivas, conforme ilustrado na Tabela 25, fornece um quadro quantitativo das reações e adaptações dos usuários aos elementos arquiteturais ao longo do tempo.

A Tabela 25 apresenta uma análise estatística descritiva dos dados obtidos por meio do UX Curves. Esta análise se debruça sobre estatísticas centrais e de dispersão, assim como valores extremos e contagens de percepções positivas e negativas. A média das percepções aumentou consistentemente ao longo dos cinco dias. No Dia 1, a média era de -0.8, indicando uma percepção geral negativa. No entanto, até o Dia 5, essa média subiu para 1.7, sugerindo uma melhoria progressiva na percepção dos usuários. A mediana também demonstra uma tendência ascendente semelhante, passando de -1.3 no Dia 1 para 2.1 no Dia 5.

Tabela 25 – Análise Estatística Descritiva dos Dados do UX Curves

Estatísticas	Dia 1	Dia 2	Dia 3	Dia 4	Dia 5
Média	-0.8	0.1	1.1	1.4	1.7
Mediana	-1.3	-0.1	1.4	1.5	2.1
Moda	-1.5	-2.0	2.3	1.0	3.5
Desvio Padrão	2.9	2.4	2.2	2.2	2.3
Maior Valor	5.5	5.6	6.4	6.4	6.1
Menor Valor	-6,5	-4,9	-3,7	-3,5	-4,7
Positivas (Quantidade)	21	22	32	34	35
Negativas (Quantidade)	23	22	12	10	9

O aumento progressivo nas médias diárias, reflete a eficácia com que os módulos da Camada de Middleware e Serviços estão atendendo às expectativas dos usuários. Especificamente, a melhoria na média indica um ajuste progressivo no Módulo de Contexto e Preferências Musicais, e no Módulo de Cold-Start, que parece estar se tornando mais eficiente à medida que os usuários continuam a interagir com o sistema.

A moda, que representa o valor mais frequentemente observado, mostra variações interessantes. Por exemplo, no Dia 2, o valor mais comum foi -2.0, enquanto no Dia 3, a moda foi 2.3. Isso destaca a presença de experiências de usuário heterogêneas que podem ser atribuídas às complexidades inerentes ao Módulo de Recomendação. O desvio padrão, uma medida de dispersão dos dados, permaneceu relativamente estável, variando entre 2.2 e 2.9 ao longo dos dias. Isso sugere que a dispersão geral das percepções dos usuários não teve mudanças drásticas durante o período observado.


Em relação aos valores extremos, nota-se que o maior valor observado foi 6.4 nos Dias 3 e 4, o que poderia coincidir com a descoberta de uma nova funcionalidade ou a adaptação bem-sucedida das recomendações musicais, evidenciando a importância do Módulo de Predição Adaptativa na otimização contínua das sugestões de músicas baseadas no feedback e nas preferências dos usuários. O menor valor registrado foi de -6.5 no Dia 1.

A contagem de percepções positivas aumentou ao longo dos dias, começando com 21 no Dia 1 e chegando a 35 no Dia 5. Paralelamente, as percepções negativas diminuíram de 23 no Dia 1 para 9 no Dia 5. O aumento das percepções positivas e a diminuição das negativas sugerem uma aceitação crescente das operações da Camada de Serviços. Isso é particularmente relevante para o Gerenciador de Recomendações, que coordena essas operações e integra informações de outros módulos, e para o Módulo de Predição Adaptativa, que é essencial para a personalização das recomendações.

Estes resultados refletem uma tendência de melhoria na experiência do usuário ao longo do tempo, o que pode ser atribuído à eficácia da arquitetura UConteXt Arch. O aumento na média e na mediana, juntamente com a redução de percepções negativas e o crescimento das positivas, apontam para uma experiência do usuário aprimorada. A

estabilidade do desvio padrão e as variações na moda indicam áreas de robustez e também oportunidades de refinamento nas camadas de middleware e serviços.

Figura 13 – Método Elbow Curve.



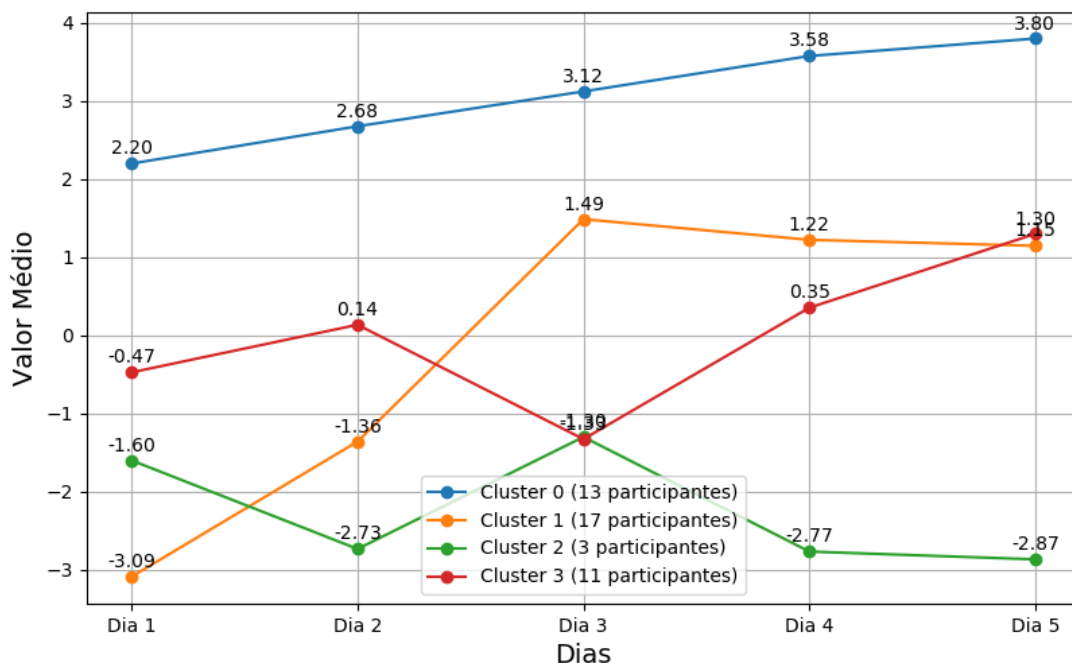
Fonte: Elaborado pelo autor

Após a análise inicial da Tabela 25 que indica uma melhoria na percepção dos usuários ao longo dos dias, é natural questionar se há padrões subjacentes ou segmentações entre esses usuários que poderiam oferecer compreensões mais profundas. A segmentação de usuários ou clustering, é uma técnica importante em ciência de dados para identificar grupos dentro de um conjunto de dados com base em características similares (JEYASINGH; APPAVOO, 2012; UTIMULA et al., 2021). Justifica-se o emprego desta técnica ao entender que, ao agrupar os usuários de acordo com suas percepções e comportamentos, é possível desenvolver estratégias mais personalizadas de melhoria de UX, além de identificar segmentos de usuários com necessidades específicas.

Uma das técnicas mais populares e eficazes para determinar o número ideal de clusters é o Método Elbow Curve (SYAKUR et al., 2018). O gráfico apresentado na Figura 13 representa a soma das distâncias quadradas intra-cluster (WCSS) em relação ao número de clusters. Observa-se uma queda acentuada da WCSS até o quarto cluster, após o qual a taxa de declínio suaviza significativamente. Isso sugere que adicionar mais clusters após o quarto resulta em um ganho marginal na explicação da variância. Assim, com base no Método Elbow Curve apresentado, determinou-se que quatro clusters seria o número ideal para este conjunto de dados, proporcionando um equilíbrio entre a precisão do modelo e a sua interpretabilidade.

A Figura 14 apresenta a trajetória média dos quatro clusters distintos ao longo de cinco dias. A análise dos clusters é fundamental para compreender como diferentes segmentos de usuários evoluem em suas percepções ou comportamentos em relação à arquitetura proposta.

Figura 14 – Média dos Clusters ao Longo dos Dias.



Fonte: Elaborado pelo autor

O Cluster 0 (13 participantes), inicia com um valor médio de 2.20 no Dia 1, apresentando um aumento constante e significativo ao longo dos cinco dias, alcançando um valor médio de 3.80 no Dia 5. Esse cluster representa um grupo de usuários que tem uma experiência consistentemente positiva e melhorada ao longo do tempo. Isso demonstra uma satisfação consistentemente alta e crescente, o que pode ser interpretado como uma validação do Módulo de Predição Adaptativa e do Gerenciador de Recomendações, ambos fundamentais para o ajuste contínuo das recomendações musicais à preferência do usuário. O aumento constante da satisfação desse grupo sugere que os aspectos dinâmicos da arquitetura estão funcionando como previsto.

No Cluster 1 (17 participantes), os participantes começam com um valor médio negativo de -3.60 no Dia 1. Contudo, observa-se uma tendência ascendente até o Dia 3, onde alcançam um pico de 1.49. Posteriormente, há um declínio nos Dias 4 e 5, terminando com um valor médio de 1.15. Esse grupo indica um conjunto de usuários que, apesar de inicialmente insatisfeitos, encontraram melhorias em sua experiência, mas não de forma tão consistente quanto o Cluster 0. Isso pode refletir uma interação menos ideal com o Módulo de Cold-Start, onde os usuários, após um período inicial de adaptação, podem encontrar dificuldades persistentes ou novos desafios que a arquitetura precisa abordar para manter a satisfação a longo prazo.


O Cluster 2 (3 participantes), tem a trajetória mais preocupante. Começa com um valor médio de -1.60 no Dia 1 e, uma queda no Dia 2, regressa a uma tendência descendente, atingindo -2.87 no Dia 5. Esse cluster representa um grupo de usuários cuja experiência

não apenas começou negativamente, mas também não mostrou melhorias significativas ao longo do tempo. Essa observação é crítica, pois indica a necessidade de um exame mais aprofundado dos módulos de middleware, como o Módulo de Gêneros Musicais e o Módulo de Artistas Preferidos, para identificar possíveis áreas de melhoria que possam elevar a percepção deste segmento de usuários.

Por outro lado, o Cluster 3 (11 participantes), é o grupo com a trajetória mais estável, iniciando com um valor de -0.47 no Dia 1 e terminando com 1.30 no Dia 5. Embora esse grupo mostre uma leve tendência positiva, a variação é marginal em comparação com os outros clusters. Isso sugere que os módulos de Recálculo de Recursos de Áudio e o Módulo de Contexto Atual podem estar proporcionando uma experiência consistente, embora sem melhorias significativas ou deterioração ao longo do tempo.

Ao examinar essas trajetórias, torna-se evidente que enquanto alguns grupos de usuários se adaptam e evoluem positivamente (Clusters 0, 1 e 3), outros (Cluster 2) não conseguem encontrar a mesma satisfação, sugerindo a necessidade de uma atenção diferenciada para este segmento. Essa segmentação permite uma avaliação mais precisa do impacto dos módulos da arquitetura UConteXt Arch na experiência do usuário, oferecendo uma base sólida para aperfeiçoar a arquitetura e direcionar estratégias de engajamento e retenção de usuários.

Figura 15 – Variação e Tendência Central das Avaliações Diárias.



Fonte: Elaborado pelo autor

Para ampliar a compreensão das percepções dos usuários, não apenas em relação a satisfação dos usuários com as recomendações de música fornecidas pelo durante o uso do MixFy, mas também avaliar a eficácia da UConteXt Arch, a Figura 15 mostra os boxplots que representam a distribuição das avaliações diárias, de "Dia 1" a "Dia 5". Esta representação ilustra a distribuição das avaliações ao longo do período proporcionando uma perspectiva detalhada sobre a dispersão e a tendência central dos dados.

Observa-se uma dispersão notável nas avaliações do Dia 1, sugerindo uma inicial interação menos favorável com os módulos, particularmente com o Módulo de Cold-Start,

que pode necessitar de um processo de adaptação mais suave para novos usuários. Em contraste, a melhoria nas avaliações subsequente reflete positivamente na eficácia dos módulos de Recomendação e Predição Adaptativa, indicando uma resposta mais positiva às recomendações musicais adaptativas.

Os Dias 2 e 3 apresentam padrões de avaliação similares, possivelmente indicando uma resposta estável ao Módulo de Contexto e Preferências Musicais, sugerindo que os usuários estão encontrando um equilíbrio na personalização das recomendações fornecidas pela arquitetura. A uniformidade desses dias pode ser um sinal de que os módulos da arquitetura está consolidando sua capacidade de capturar e aplicar as preferências dos usuários.

O Dia 4 é marcado por uma polarização nas avaliações, com outliers positivos e negativos. Esta divisão pode ser atribuída a uma resposta heterogênea ao ajuste do Módulo de Predição Adaptativa ou a alterações nas estratégias de recomendação implementadas nos módulos de serviço. Esses outliers podem destacar usuários específicos cujas expectativas podem não estar alinhadas com as recomendações oferecidas.


O Dia 5 demonstra uma tendência central elevada com uma mediana mais alta, sugerindo que a arquitetura está atingindo um desempenho melhor no que diz respeito à satisfação geral do usuário. No entanto, a presença de um outlier negativo requer uma investigação detalhada, talvez indicando uma área onde o Módulo de Recomendações possa ser ainda mais aprimorado para atender às necessidades de todos os segmentos de usuários.

Os outliers persistentes, particularmente os inferiores observados nos Dias 4 e 5, podem ser reflexo das experiências dos participantes do Cluster 2, que mostraram uma tendência de satisfação diferente. Este padrão de outliers aponta para a possibilidade de que estes usuários possam ter interações distintas com a arquitetura, talvez devido a preferências ou contextos únicos não totalmente capturados pelos módulos atuais. Esta observação é crucial, pois destaca a necessidade de uma análise mais aprofundada do Módulo de Contexto e Preferências Musicais, e talvez uma personalização mais granular dentro do Módulo de Recomendações para acomodar tais variações na experiência do usuário.

A Figura 16 proporcionam uma visão agregada da distribuição de frequências, possibilitando uma compreensão mais clara das tendências centrais e das variações em relação às recomendações geradas pelos módulos da arquitetura UConteXt Arch. A análise do histograma do 'Dia 1' revela uma gama de percepções, desde avaliações negativas a positivas. A concentração de avaliações na marca de 2, seguida pela marca de 4, indica que a experiência dos usuários foi predominantemente positiva. Isso sugere que pode ter sido motivadas pela atuação do Módulo de Recomendações, Módulo de Contexto e Preferências Musicais, embora com espaço para melhorias, visto que a experiência não foi uniformemente. A presença de avaliações neutras sugere que a integração da arquitetura com as preferências dos usuários funciona em um nível aceitável, enquanto as avaliações



Figura 16 – Frequência das Avaliações Diárias por Intervalo.



Fonte: Elaborado pelo autor

negativas destacadas na marca de -4 apontam para a necessidade de investigar e otimizar aspectos específicos do Módulo de Cold-Start.

No 'Dia 2', a homogeneidade nas avaliações pode refletir uma maior familiaridade dos usuários com a arquitetura, indicando que o Módulo de Recomendação em conjunto com o de Predição Adaptativa estão ajustando as recomendações de maneira eficaz com o passar do tempo. O equilíbrio entre as experiências positivas e negativas moderadas reforça a importância de um Módulo de Recomendações que possa se adaptar às variações nas preferências dos usuários de forma dinâmica.

O histograma do 'Dia 3' mostra um pico claro nas avaliações em torno do valor 2, ressaltando a eficácia contínua do Módulo de Recomendações e Recálculo de Recursos de Áudio em proporcionar satisfação. A diminuição nas avaliações neutras e a persistência de avaliações positivas e negativas extremas, embora em baixa frequência, podem indicar momentos específicos de interação dos usuários com o Módulo de Artistas Preferidos ou Gêneros Musicais, que merecem atenção para refinamento.

O 'Dia 4' apresenta um padrão interessante, com um pico nas avaliações positivas moderadas e uma diminuição nas avaliações extremamente negativas. Isso pode sugerir que o Módulo de Recálculo de Recursos de Áudio e o Módulo de Contexto Atual estão progressivamente alinhando as recomendações com as preferências e contextos dos usuários, resultando em uma experiência mais satisfatória.

No 'Dia 5', como ilustrado pela Figura 16, a distribuição das avaliações continua a evoluir. A presença de avaliações predominantemente centradas ao redor dos valores 2 e 4 indica uma experiência geral positiva entre os usuários, o que pode ser atribuído ao comportamento em geral de todos os módulos da camada de serviços. A frequência de avaliações neutras, embora menor em comparação com os dias anteriores, sugere que ainda há um grupo de usuários em uma zona de conforto, possivelmente devido à eficácia consistente do Módulo de Contexto e Preferências Musicais em proporcionar recomendações adequadas. Entretanto, a existência de avaliações negativas, embora em menor número, sinaliza oportunidades para investigar e melhorar aspectos específicos da arquitetura, como o ajuste dos contextos e gêneros musicais.

Esses padrões nos histogramas são reflexos diretos da interação dos usuários com a arquitetura UConteXt Arch e indicam conformidade com a proposta, bem como oportunidades para melhoria contínua. A estabilidade nas avaliações positivas moderadas e a redução nas avaliações negativas ao longo do tempo sugerem uma adaptação e otimização dos módulos de recomendação da arquitetura, enquanto as variações diárias e a presença de outliers apontam para a necessidade de uma análise mais granular dos componentes da arquitetura para garantir uma experiência de usuário consistentemente positiva.

### 7.5.3 Considerações finais

Os comentários dos usuários revelam uma jornada notável de adaptação e aprimoramento na interação com a arquitetura UConteXt Arch. No início, muitos participantes expressaram sentimentos de insatisfação, como observado no comentário "*poucas músicas boas*". Essa percepção inicial alinha-se com as baixas médias de satisfação observadas nos primeiros dias. Entretanto, conforme os dias avançam, os comentários refletem uma melhoria progressiva na experiência do usuário, exemplificado por declarações como "*melhorou bastante do meu gosto*" e "*encontrei uma antiga do meu gosto*". Essa evolução na percepção dos usuários é demonstrada pelo aumento gradual nas avaliações médias e pela redução das percepções negativas, sugerindo que a arquitetura se ajusta eficazmente às preferências dos usuários ao longo do tempo.

A diversidade nas experiências diárias dos usuários é um aspecto distintivo ilustrado pelos comentários. Em dias específicos, alguns usuários relataram experiências menos satisfatórias, como indicado pelo comentário "*hoje não foi tão bom*". Esta variação diária, refletida na presença de outliers nos boxplots e na variabilidade nas modas, destaca a complexidade do Módulo de Recomendação e a necessidade de ajustes contínuos para alinhar as recomendações com as preferências em constante mudança dos usuários. Ao mesmo tempo, comentários positivos como "*hoje acertou bem*" no quinto dia ressaltam o potencial da arquitetura em proporcionar experiências satisfatórias, alinhando-se com a tendência de melhoria observada nos histogramas e na análise dos clusters.

Os comentários dos usuários oferecem compreensões importantes para futuras melhorias na arquitetura UConteXt Arch. Embora muitos participantes tenham demonstrado uma experiência positiva ao longo do tempo, as observações pontuais de insatisfação ressaltam áreas que podem ser aprimoradas. Por exemplo, a menção a “*poucas músicas boas*” no início sugere a necessidade de otimizar o Módulo de Cold-Start para oferecer seleções iniciais mais alinhadas com as preferências dos usuários. Além disso, a variação nas experiências diárias aponta para a importância de um ajuste mais dinâmico e sensível ao contexto no Módulo de Recomendação. Assim, esses comentários não só validam os achados quantitativos da pesquisa, mas também proporcionam uma direção clara para a evolução contínua da arquitetura, visando uma personalização mais profunda e uma experiência de usuário consistentemente positiva.

---

## Capítulo 8

# Considerações finais e Trabalhos futuros

---

### 8.1 Considerações finais

A presente tese de doutorado centrou-se em um problema de pesquisa fundamental no âmbito dos sistemas de recomendação musical: a integração efetiva do contexto de interação e da experiência do usuário nas recomendações musicais. Esta lacuna, amplamente reconhecida na literatura (VELANKAR; KULKARNI, 2023; ASSUNCAO; PICCOLO; ZAINA, 2022), foi abordada através da arquitetura UConteXt Arch, uma proposta que transcende a mera agregação de dados objetivos de escuta, um limite destacado por Zhang et al. (2021) e Schedl et al. (2018).

A arquitetura UConteXt Arch foi desenvolvida e avaliada com um foco específico na melhoria da experiência do usuário, indo além das limitações dos métodos tradicionais de recomendação. Através dos estudos conduzidos, demonstrou-se que a arquitetura consegue responder às preferências dinâmicas dos usuários sem desconsiderar o contexto de interação e a experiência do usuário, uma capacidade frequentemente negligenciada em sistemas existentes, conforme apontado por Liu et al. (2022) e Xie et al. (2021).

Conforme elucidado no Capítulo 4, os sistemas Spotify e Deezer exibiram falhas notáveis em comunicabilidade e na adequação às expectativas do usuário, com problemas como a falta de aprendizado e personalização nas recomendações. Isso foi evidenciado pelas análises do MAC e do SAM, onde os aspectos desejáveis em sistemas de recomendação, como aprendizado e feedback, foram frequentemente negligenciados, resultando em experiências de usuário que não correspondiam plenamente às suas necessidades.

Em contrapartida, os resultados dos Capítulos 6 e 7 indicam uma melhoria substancial

com a implementação da UConteXt Arch. Através de ferramentas de avaliação como o Modelo de Aceitação de Tecnologia (TAM), o Método de Inspeção Semiótica Intermediado (MISI) e as Curvas de Experiência do Usuário (UX Curves), foi constatado um alto nível de satisfação dos usuários com o MixFy. As análises revelaram uma tendência de melhoria contínua na experiência do usuário, com um aumento progressivo em avaliações positivas e uma diminuição nas negativas ao longo do tempo. Especificamente, o TAM mostrou uma forte correlação entre a percepção de utilidade, facilidade de uso e a intenção de uso contínuo do MixFy, refletindo uma aceitação e satisfação significativas dos usuários. Além disso, o MISI identificou uma alta comunicabilidade e compreensão clara dos usuários sobre a função e os benefícios do sistema. As UX Curves ilustraram uma evolução na experiência do usuário, com melhorias perceptíveis e consistentes na percepção das recomendações musicais ao longo do tempo, evidenciando a capacidade da UConteXt Arch de se adaptar de forma dinâmica e eficiente às preferências e contextos dos usuários.

Essas descobertas contrastam marcadamente com as limitações identificadas nos sistemas do Spotify e Deezer, destacando a eficiência da UConteXt Arch em oferecer uma experiência de usuário mais adaptável, personalizada e satisfatória. Assim, a arquitetura UConteXt Arch demonstra ser uma solução capaz de enfrentar os desafios dos sistemas de recomendação musical existentes, alinhando-se mais estreitamente com as necessidades e preferências em constante mudança dos usuários.

A análise longitudinal com o método UX Curves foi particularmente significativa, ilustrando como a experiência do usuário melhora progressivamente com a interação contínua com o sistema. Esta capacidade de adaptação e aprendizado contínuo da UConteXt Arch representa um avanço importante em relação aos sistemas atuais, que muitas vezes falham em acomodar a evolução das preferências do usuário.

Os resultados do TAM enfatizaram ainda mais a aceitação positiva dos usuários em relação à utilidade e facilidade de uso da UConteXt Arch. Esta constatação é especialmente notável, considerando que um dos principais desafios enfrentados pelos sistemas de recomendação é equilibrar a precisão das recomendações com a usabilidade.

Ao comparar os resultados obtidos com a literatura existente, percebe-se que a UConteXt Arch representa um avanço significativo no estado da arte em sistemas de recomendação musical. Esta arquitetura não só aborda o problema de pesquisa identificado, mas também supera várias limitações dos métodos existentes (por exemplo o cold-start). A integração do contexto de interação e da experiência do usuário em recomendações musicais é uma contribuição importante da presente tese e reflete um passo importante em direção a sistemas de recomendação mais adaptáveis, personalizados e centrados no usuário.

## 8.2 Limitações

Uma limitação significativa desta pesquisa reside na seleção de participantes e na diversidade de cenários contemplados. Embora o estudo tenha incluído diferentes contextos de uso (em casa, trabalhando, dirigindo, treinando), a diversidade de participantes, especialmente em termos de origens culturais e preferências musicais diversas, permaneceu limitada. A inclusão de uma amostra mais ampla e variada de usuários, provenientes de diferentes contextos culturais e geográficos, poderia ter enriquecido as compreensões sobre as preferências musicais e a interação com o sistema em uma gama mais ampla de cenários. Além disso, a investigação poderia ter se beneficiado da inclusão de outros contextos relevantes de uso, como durante atividades de lazer ou estudos, para compreender melhor as particularidades das preferências musicais em diferentes situações da vida cotidiana.

A pesquisa focou em uma seleção limitada de gêneros musicais e contextos de uso, o que pode ter restringido a capacidade do sistema de atender a uma gama mais ampla de preferências e necessidades dos usuários. Expandir o estudo para incluir um espectro mais amplo de gêneros musicais e contextos poderia proporcionar uma compreensão mais abrangente das complexidades envolvidas nas recomendações musicais. Isso não apenas aumentaria a relevância das recomendações para uma variedade maior de usuários, mas também ajudaria a explorar como diferentes gêneros e contextos interagem e influenciam as preferências musicais.

Outra limitação importante do estudo é a metodologia empregada na coleta e análise de dados. Embora métodos como o TAM e o UX Curves tenham sido utilizados, a abordagem poderia ter se beneficiado da incorporação de métodos adicionais, como análises qualitativas aprofundadas, entrevistas e estudos de caso. Esses métodos poderiam oferecer uma compreensão mais rica das experiências subjetivas dos usuários, suas motivações e como eles interagem com o sistema em diferentes contextos. Além disso, uma análise mais detalhada dos dados coletados, utilizando técnicas avançadas de aprendizado de máquina e análise estatística, poderia revelar padrões e tendências mais aprimoradas do comportamento dos usuários.

Por fim, A utilização da autoavaliação dos usuários para identificar seu contexto atual é uma limitação que pode afetar a precisão das recomendações musicais. A dificuldade dos usuários em identificar seu próprio estado ou contexto pode resultar em entradas imprecisas. Explorar métodos alternativos para identificação de contexto poderia aprimorar a eficácia do módulo de cold-start e a relevância das recomendações musicais.

## 8.3 Trabalhos futuros

O fechamento desta tese deixa claro que a arquitetura UConteXt Arch estabelece uma nova abordagem para o desenvolvimento de sistemas de recomendação musical centrados

no usuário. A pesquisa abre caminho para futuras explorações e melhorias, visando uma interação mais rica, personalizada e significativa entre usuários e música em diversos contextos.

Tendo em vista a limitação na variedade de gêneros musicais considerados nesta pesquisa, um direcionamento importante para trabalhos futuros é a expansão de gêneros musicais. Isso incluiria a incorporação de gêneros menos convencionais e regionais, permitindo assim um espectro mais amplo de personalização das recomendações musicais

Além dos gêneros musicais, pretende-se realizar a inclusão de outros contextos de uso. Isso envolveria a análise de como diferentes cenários influenciam as preferências musicais. Para abordar a subjetividade na identificação dos contextos dos usuários, os trabalhos futuros podem se concentrar no desenvolvimento de métodos de identificação automática de contexto.

Outras avaliações longitudinais e diversificadas para validar e aprimorar ainda mais a arquitetura UConteXt Arch também são pretendidas. Essas avaliações poderiam incluir um período de uso mais extenso e uma amostra de participantes mais diversificada, abrangendo diferentes faixas etárias, culturas e contextos geográficos. Além disso, a integração de metodologias de avaliação complementares, como análises de interação em tempo real e feedback contextualizado, proporcionaria uma compreensão mais profunda da experiência do usuário.

Por fim, em retrospectiva a arquitetura UConteXt Arch, conforme delineada e avaliada ao longo desta tese, revelou uma evolução em sua natureza conceitual e aplicável. Embora inicialmente concebida como uma arquitetura destinada a guiar o design e a implementação de sistemas de recomendação musical sensíveis ao contexto e à experiência do usuário, a UConteXt Arch desenvolveu-se de maneira a manifestar qualidades típicas de um framework. Isso se reflete na flexibilidade dos seus componentes, na capacidade de serem adaptados e reutilizados em diferentes contextos e na facilidade de integração com sistemas existentes. Portanto, é importante reconhecer que, embora não tenha sido originalmente projetada como um framework, a UConteXt Arch está convergindo para esta classificação, o que realça seu potencial como uma solução abrangente e modular no campo dos sistemas de recomendação musical. Esta percepção abre novas avenidas para pesquisa futura, onde a UConteXt Arch poderia ser refinada e formalizada como um framework completo, oferecendo diretrizes estruturadas e componentes prontos para uso, facilitando a inovação e a customização nas práticas de recomendação musical.

---

## Referências

---

ABDUL, A. et al. An emotion-aware personalized music recommendation system using a convolutional neural networks approach. **Applied Sciences**, Multidisciplinary Digital Publishing Institute, v. 8, n. 7, p. 1103, 2018.

ABOWD, G. D. et al. Towards a better understanding of context and context-awareness. In: SPRINGER. **International symposium on handheld and ubiquitous computing**. [S.l.], 1999. p. 304–307.

ADOMAVICIUS, G.; TUZHILIN, A. Context-aware recommender systems. In: **Recommender systems handbook**. [S.l.]: Springer, 2011. p. 217–253.

AFCHAR, D. et al. Explainability in music recommender systems. **AI Magazine**, v. 43, n. 2, p. 190–208, 2022.

ALEGRE, U.; AUGUSTO, J. C.; CLARK, T. Engineering context-aware systems and applications: A survey. **Journal of Systems and Software**, Elsevier, v. 117, p. 55–83, 2016.

ALI, M. M. V. M. et al. Demonstration of communication-based three-layer control architecture for providing network services to distribution system operators. **International Transactions on Electrical Energy Systems**, v. 30, 2020.

ALI, O. et al. A comprehensive review of internet of things: technology stack, middlewares, and fog/edge computing interface. **Sensors**, v. 22, p. 995, 2022.

ANDERSON, I. et al. “just the way you are”: linking music listening on spotify and personality. **Social Psychological and Personality Science**, v. 12, p. 561–572, 2020.

ANDJELKOVIC, I.; PARRA, D.; O’DONOVAN, J. Moodplay: Interactive music recommendation based on artists’ mood similarity. **International Journal of Human-Computer Studies**, Elsevier, v. 121, p. 142–159, 2019.

ANWAAR, F. et al. Hrs-ce: a hybrid framework to integrate content embeddings in recommender systems for cold start items. **Journal of Computational Science**, v. 29, p. 9–18, 2018.

APPLE. **Apple Music**. 2021. Disponível em: <<https://www.apple.com/br/apple-music/>>.



- ARDÉVOL, L. M. et al. **User experience methodology for the design and evaluation of interactive systems**. Tese (Doutorado) — Universitat de Lleida, 2013.
- ASABERE, N. Y. Towards a viewpoint of context-aware recommender systems (cars) and services. **International Journal of Computer Science and Telecommunications**, Citeseer, v. 4, n. 1, p. 10–29, 2013.
- ASSUNCAO, W. G.; NERIS, V. An algorithm for music recommendation based on the user's musical preferences and desired emotions. In: **Proceedings of the 17th International Conference on Mobile and Ubiquitous Multimedia**. [S.l.: s.n.], 2018. p. 205–213.
- ASSUNCAO, W. G.; PICCOLO, L. S.; ZAINA, L. A. Considering emotions and contextual factors in music recommendation: a systematic literature review. **Multimedia Tools and Applications**, Springer, p. 1–41, 2022.
- ASSUNÇÃO, W. G.; PRATES, R. O.; ZAINA, L. A. M. Managing cold-start issues in music recommendation systems: An approach based on user experience. In: **Companion Proceedings of the 2023 ACM SIGCHI Symposium on Engineering Interactive Computing Systems**. [S.l.: s.n.], 2023. p. 31–37.
- ASSUNÇÃO, W. G. de; NERIS, V. P. de A. m-motion: a mobile application for music recommendation that considers the desired emotion of the user. In: **Proceedings of the 18th Brazilian Symposium on Human Factors in Computing Systems**. [S.l.: s.n.], 2019. p. 1–11.
- ASSUNÇÃO, W. G. de; ZAINA, L. A. M. Evaluating user experience in music discovery on deezer and spotify. In: **Proceedings of the 21st Brazilian Symposium on Human Factors in Computing Systems**. [S.l.: s.n.], 2022. p. 1–11.
- AYATA, D.; YASLAN, Y.; KAMASAK, M. E. Emotion based music recommendation system using wearable physiological sensors. **IEEE transactions on consumer electronics**, IEEE, v. 64, n. 2, p. 196–203, 2018.
- BANDEIRA-DE-MELLO, R. Softwares em pesquisa qualitativa. **Pesquisa qualitativa em estudos organizacionais: paradigmas, estratégias e métodos**. São Paulo: Saraiva, v. 481, p. 241–266, 2006.
- BARNAWAL, P. et al. Evaluation of design feedback modality in design for manufacturability. **Journal of Mechanical Design**, v. 139, 2017.
- BARRETT, K.; POWER, R. State of the art: Context management. **M-Zones Research Programme**, Citeseer, n. 1, p. 69, 2003.
- BAUER, J. S.; JELLENEK, A. L.; KIENZT, J. A. Reflektor: An exploration of collaborative music playlist creation for social context. In: **Proceedings of the 2018 ACM Conference on Supporting Groupwork**. [S.l.: s.n.], 2018. p. 27–38.
- BEEL, J. et al. paper recommender systems: A literature survey. **International Journal on Digital Libraries**, Springer, v. 17, n. 4, p. 305–338, 2016.
- BEEL, J. et al. Research paper recommender system evaluation: a quantitative literature survey. In: **Proceedings of the International Workshop on Reproducibility and Replication in Recommender Systems Evaluation**. [S.l.: s.n.], 2013. p. 15–22.

- BIBRI, S. E. The human face of ambient intelligence. **Atlantis Ambient and Pervasive Intelligence**. Atlantis Press, Springer, 2015.
- BIBRI, S. E.; KROGSTIE, J. The core enabling technologies of big data analytics and context-aware computing for smart sustainable cities: a review and synthesis. **Journal of Big Data**, Springer, v. 4, n. 1, p. 1–50, 2017.
- BIZZACO, Q. K. M.; LACOMA, T. **Apple Music vs. Spotify**. 2021. Disponível em: <<https://www.digitaltrends.com/music/apple-music-vs-spotify/>>.
- BOLLEN, D. et al. Understanding choice overload in recommender systems. In: **Proceedings of the fourth ACM conference on Recommender systems**. [S.l.: s.n.], 2010. p. 63–70.
- BOUCHARD, C.; BONGARD-BLANCHY, K. Dimensions of user experience-from the product design perspective. **Journal d'Interaction Personne-Système**, Episciences.org, v. 3, 2015.
- BOURREAU, M.; GAUDIN, G. Streaming platform and strategic recommendation bias. CESifo working paper, 2018.
- BOZANTA, A.; KUTLU, B. Developing a contextually personalized hybrid recommender system. **Mobile Information Systems**, v. 2018, p. 1–13, 2018.
- BRADLEY, M.; LANG, P. J. Measuring emotion: the self-assessment manikin and the semantic differential. **J. Behav. Ther. & Exp. Psychiat.**, Elsevier Science Ltda, v. 25, n. 1, p. 49–59, 1994.
- BRADLEY, N. A.; DUNLOP, M. D. Toward a multidisciplinary model of context to support context-aware computing. **Human-Computer Interaction**, Taylor & Francis, v. 20, n. 4, p. 403–446, 2005.
- BRAUNHOFER, M.; KAMINSKAS, M.; RICCI, F. Location-aware music recommendation. **International Journal of Multimedia Information Retrieval**, Springer, v. 2, n. 1, p. 31–44, 2013.
- BROOKE, J. et al. Sus-a quick and dirty usability scale. **Usability evaluation in industry**, London–, v. 189, n. 194, p. 4–7, 1996.
- BU, X.; LUO, K.; ZENG, Y. The impact of personalized recommendation on digital satisfaction of users. **Lecture Notes in Education Psychology and Public Media**, v. 3, p. 222–232, 2023.
- BUCHINGER, D.; CAVALCANTI, G.; HOUNSELL, M. Academic search mechanisms: a quantitative analysis. **Brazilian Journal of Applied Computation**, v. 6, n. 1, p. 108–120, 2014.
- BURKHARDT, M. et al. The evolution of facebook's graph api. **AoIR Selected Papers of Internet Research**, 2020.
- CAMERON, D. J. et al. Perception of rhythmic similarity is asymmetrical, and is influenced by musical training, expressive performance, and musical context. **Timing and Time Perception**, v. 5, p. 211–227, 2017.

- ÇANO, E. et al. Mood-based on-car music recommendations. In: SPRINGER. **International Conference on Industrial Networks and Intelligent Systems**. [S.l.], 2016. p. 154–163.
- CAO, M. et al. A novel hybrid collaborative filtering approach to recommendation using reviews:the product attribute perspective (s). **International Conferences on Software Engineering and Knowledge Engineering**, 2018.
- CASEY, M. A. et al. Content-based music information retrieval: Current directions and future challenges. **Proceedings of the IEEE**, IEEE, v. 96, n. 4, p. 668–696, 2008.
- CENA, F. et al. Generating recommendations from multiple data sources: a methodological framework for system design and its application. **IEEE Access**, v. 8, p. 183430–183447, 2020.
- CHANG, J.-W. et al. Music recommender using deep embedding-based features and behavior-based reinforcement learning. **Multimedia Tools and Applications**, Springer, p. 1–28, 2019.
- CHEN, C.-M. et al. Music recommendation based on multiple contextual similarity information. In: IEEE. **2013 IEEE/WIC/ACM International Joint Conferences on Web Intelligence (WI) and Intelligent Agent Technologies (IAT)**. [S.l.], 2013. v. 1, p. 65–72.
- CHEN, C.-M. et al. Using emotional context from article for contextual music recommendation. In: **Proceedings of the 21st ACM international conference on Multimedia**. [S.l.: s.n.], 2013. p. 649–652.
- CHEN, C.-W. et al. Recsys challenge 2018: Automatic music playlist continuation. In: **Proceedings of the 12th ACM Conference on Recommender Systems**. New York, NY, USA: Association for Computing Machinery, 2018. (RecSys '18), p. 527–528. ISBN 9781450359016. Disponível em: <<https://doi.org/10.1145/3240323.3240342>>.
- CHEN, G.; KOTZ, D. A survey of context-aware mobile computing research. 2000.
- CHEN, L.; CHEN, G.; WANG, F. Recommender systems based on user reviews: the state of the art. **User Modeling and User-Adapted Interaction**, Springer, v. 25, n. 2, p. 99–154, 2015.
- CHEN, L. et al. Human decision making and recommender systems. **ACM Transactions on Interactive Intelligent Systems**, v. 3, p. 1–7, 2013.
- CHENG, Z.; SHEN, J. Just-for-me: An adaptive personalization system for location-aware social music recommendation. In: **Proceedings of international conference on multimedia retrieval**. [S.l.: s.n.], 2014. p. 185–192.
- CHIU, M.-C.; KO, L.-W. Develop a personalized intelligent music selection system based on heart rate variability and machine learning. **Multimedia Tools and Applications**, Springer, v. 76, n. 14, p. 15607–15639, 2017.
- COBALEDA, L. et al. Reference software architecture for improving modifiability of personalised web applications - a controlled experiment. **International Journal of Web Engineering and Technology**, v. 11, p. 351, 2016.

- COLLAZOS, C. A.; SALTIVERI, A. G.; HUITR, J. A. S. Evaluating interactive systems from an emotional perspective. **Revista Guillermo De Ockham**, v. 12, p. 43, 2014.
- CORBIN, J. M.; STRAUSS, A. Grounded theory research: Procedures, canons, and evaluative criteria. **Qualitative sociology**, Springer, v. 13, n. 1, p. 3–21, 1990.
- CRILLY, N.; MOULTRIE, J.; CLARKSON, P. J. Seeing things: consumer response to the visual domain in product design. **Design studies**, Elsevier, v. 25, n. 6, p. 547–577, 2004.
- DALY, I. et al. Neural and physiological data from participants listening to affective music. **Scientific Data**, v. 7, 2020.
- DAVIS, F. D. Perceived usefulness, perceived ease of use, and user acceptance of information technology. **MIS quarterly**, JSTOR, p. 319–340, 1989.
- DEEZER. **ONDE A MÚSICA VIVE**. 2021. Disponível em: <<https://www.deezer.com/br/company>>.
- DELDJOO, Y.; SCHEDL, M.; KNEES, P. Content-based music recommendation: Evolution, state of the art, and challenges. **arXiv preprint arXiv:2107.11803**, 2021.
- DENG, J. J.; LEUNG, C. Emotion-based music recommendation using audio features and user playlist. In: IEEE. **2012 6th International Conference on New Trends in Information Science, Service Science and Data Mining (ISSDM2012)**. [S.l.], 2012. p. 796–801.
- DENG, J. J. et al. Emotional states associated with music: Classification, prediction of changes, and consideration in recommendation. **ACM Transactions on Interactive Intelligent Systems (TiiS)**, ACM New York, NY, USA, v. 5, n. 1, p. 1–36, 2015.
- DEY, A. K. Understanding and using context. **Personal and ubiquitous computing**, Springer, v. 5, p. 4–7, 2001.
- DIAS, R.; FONSECA, M. J.; CUNHA, R. A user-centered music recommendation approach for daily activities. In: **CBRecSys@ RecSys**. [S.l.: s.n.], 2014. p. 26–33.
- DOMINGOS, P.; HULTEN, G. Mining high-speed data streams. In: **Proceedings of the sixth ACM SIGKDD international conference on Knowledge discovery and data mining**. [S.l.: s.n.], 2000. p. 71–80.
- DOURISH, P. What we talk about when we talk about context. **Personal and ubiquitous computing**, Springer, v. 8, p. 19–30, 2004.
- ESTEVE, S.; FORKEY, D.; CLARK, S. Human factors testing sample size requirements: is it time to reevaluate? **Proceedings of the International Symposium on Human Factors and Ergonomics in Health Care**, v. 10, p. 243–246, 2021.
- FELICIONI, N.; DACREMA, M. F.; CREMONESI, P. A methodology for the offline evaluation of recommender systems in a user interface with multiple carousels. **Adjunct Proceedings of the 29th ACM Conference on User Modeling, Adaptation and Personalization**, 2021.

- FENKO, A.; SCHIFFERSTEIN, H. N.; HEKKERT, P. Shifts in sensory dominance between various stages of user–product interactions. **Applied ergonomics**, Elsevier, v. 41, n. 1, p. 34–40, 2010.
- FERNANDO, G.; BAIZAL, Z. K. A.; DHARAYANI, R. Music recommendation using conversational recommender system with explanation facility. In: **2021 International Conference on Data Science and Its Applications (ICoDSA)**. [S.l.: s.n.], 2021. p. 141–145.
- FERWERDA, B. **Improving the user experience of music recommender systems through personality and cultural information**. Tese (Doutorado) — B. Ferwerda, 2016.
- FERWERDA, B.; SCHEDL, M. Enhancing music recommender systems with personality information and emotional states: A proposal. In: **Umap workshops**. [S.l.: s.n.], 2014. p. 1–9.
- FERWERDA, B.; SCHEDL, M.; TKALCIC, M. Personality & emotional states: Understanding users’ music listening needs. In: **UMAP Workshops**. [S.l.: s.n.], 2015.
- FERWERDA, B. et al. Exploring music diversity needs across countries. In: **Proceedings of the 2016 Conference on User Modeling Adaptation and Personalization**. [S.l.: s.n.], 2016. p. 287–288.
- FERWERDA, B. et al. Personality and taxonomy preferences, and the influence of category choice on the user experience for music streaming services. **Multimedia tools and applications**, Springer, v. 78, n. 14, p. 20157–20190, 2019.
- FLORES-MARTÍN, D. et al. Towards dynamic and heterogeneous social iot environments. **Computing**, v. 105, p. 1141–1164, 2022.
- FORLIZZI, J.; FORD, S. The building blocks of experience: an early framework for interaction designers. In: **Proceedings of the 3rd conference on Designing interactive systems: processes, practices, methods, and techniques**. [S.l.: s.n.], 2000. p. 419–423.
- FREZZO, D. C.; BEHRENS, J. T.; MISLEVY, R. J. Design patterns for learning and assessment: Facilitating the introduction of a complex simulation-based learning environment into a community of instructors. **Journal of Science Education and Technology**, Springer, v. 19, p. 105–114, 2010.
- FRID, E.; PANARIELLO, C.; NÚÑEZ-PACHECO, C. Customizing and evaluating accessible multisensory music experiences with pre-verbal children—a case study on the perception of musical haptics using participatory design with proxies. **Multimodal Technologies and Interaction**, v. 6, p. 55, 2022.
- GALLEGO, D. et al. Incorporating proactivity to context-aware recommender systems for e-learning. In: IEEE. **2013 World Congress on Computer and Information Technology (WCCIT)**. [S.l.], 2013. p. 1–6.
- GARCIA-GATHRIGHT, J. et al. Understanding and evaluating user satisfaction with music discovery. In: **The 41st International ACM SIGIR Conference on Research & Development in Information Retrieval**. [S.l.: s.n.], 2018. p. 55–64.

- GARLAND, R. The mid-point on a rating scale: Is it desirable. **Marketing bulletin**, v. 2, n. 1, p. 66–70, 1991.
- GARRETT, J. J. **The elements of user experience: user-centered design for the web and beyond**. [S.l.]: Pearson Education, 2010.
- GHARAHIGHEHI, A.; VENS, C. Diversification in session-based news recommender systems. **Personal and Ubiquitous Computing**, v. 27, p. 5–15, 2021.
- GILDA, S. et al. Smart music player integrating facial emotion recognition and music mood recommendation. In: IEEE. **2017 International Conference on Wireless Communications, Signal Processing and Networking (WiSPNET)**. [S.l.], 2017. p. 154–158.
- GILLHOFER, M.; SCHEDL, M. Iron maiden while jogging, debussy for dinner? an analysis of music listening behavior in context. In: SPRINGER. **MultiMedia Modeling: 21st International Conference, MMM 2015, Sydney, NSW, Australia, January 5-7, 2015, Proceedings, Part II 21**. [S.l.], 2015. p. 380–391.
- GIRI, G.; HARJOKO, A. Music recommendation system based on context using case-based reasoning and self organizing map. **Indonesian Journal of Electrical Engineering and Computer Science**, v. 4, n. 2, p. 459–464, 2016.
- GONG, Y. et al. Edgereg. **Proceedings of the 29th ACM International Conference on Information and Knowledge Management**, 2020.
- GREENBERG, D. M. et al. The self-congruity effect of music. **Journal of Personality and Social Psychology**, v. 121, p. 137–150, 2021.
- GRUSON, A. et al. Offline evaluation to make decisions about playlist recommendation algorithms. In: **Proceedings of the Twelfth ACM International Conference on Web Search and Data Mining**. [S.l.: s.n.], 2019. p. 420–428.
- GUO, Y.; WU, C.; PETEIRO-BARRAL, D. An eeg-based brain informatics application for enhancing music experience. In: SPRINGER. **International Conference on Brain Informatics**. [S.l.], 2012. p. 265–276.
- HAGEN, A. N. The playlist experience: Personal playlists in music streaming services. **Popular Music and Society**, Taylor & Francis, v. 38, n. 5, p. 625–645, 2015.
- HAN, B.-J. et al. Music emotion classification and context-based music recommendation. **Multimedia Tools and Applications**, Springer, v. 47, n. 3, p. 433–460, 2010.
- HAN, W. et al. The impact of digital alarm sound to human emotions: A case study. In: IEEE. **2018 IEEE International Conference on Systems, Man, and Cybernetics (SMC)**. [S.l.], 2018. p. 1903–1908.
- HASSENZAHL, M. Experience design: Technology for all the right reasons. **Synthesis lectures on human-centered informatics**, Morgan & Claypool Publishers, v. 3, n. 1, p. 1–95, 2010.
- HASSENZAHL, M. The thing and i: Understanding the relationship between user and product. In: \_\_\_\_\_. **Funology 2: From Usability to Enjoyment**. Cham: Springer International Publishing, 2018. p. 301–313. ISBN 978-3-319-68213-6. Disponível em: <[https://doi.org/10.1007/978-3-319-68213-6\\_19](https://doi.org/10.1007/978-3-319-68213-6_19)>.

- HEKKERT, P.; SCHIFFERSTEIN, H. N. Introducing product experience. **Product experience**, Elsevier, p. 1–8, 2008.
- HELMHOLZ, P.; VETTER, S.; ROBRA-BISSANTZ, S. Ambitune: Bringing context-awareness to music playlists while driving. In: SPRINGER. **International Conference on Design Science Research in Information Systems**. [S.l.], 2014. p. 393–397.
- HEVNER, A. et al. Design science research in information systems. **Design research in information systems: theory and practice**, Springer, p. 9–22, 2010.
- HEVNER, A. R. A three cycle view of design science research. **Scandinavian journal of information systems**, v. 19, n. 2, p. 4, 2007.
- HILL, W. et al. Recommending and evaluating choices in a virtual community of use. In: **Proceedings of the SIGCHI conference on Human factors in computing systems**. [S.l.: s.n.], 1995. p. 194–201.
- HIMEUR, Y. et al. A survey of recommender systems for energy efficiency in buildings: Principles, challenges and prospects. **Information Fusion**, Elsevier, v. 72, p. 1–21, 2021.
- HONG, J. et al. Context-aware music recommendation in mobile smart devices. In: **Proceedings of the 29th annual ACM symposium on applied computing**. [S.l.: s.n.], 2014. p. 1463–1468.
- HSU, J.-L. et al. Affective content analysis of music emotion through eeg. **Multimedia Systems**, Springer, v. 24, n. 2, p. 195–210, 2018.
- HU, H. et al. Toward scalable systems for big data analytics: A technology tutorial. **IEEE access**, IEEE, v. 2, p. 652–687, 2014.
- HU, X. et al. Safedj: A crowd-cloud codesign approach to situation-aware music delivery for drivers. **ACM Transactions on Multimedia Computing, Communications, and Applications (TOMM)**, ACM New York, NY, USA, v. 12, n. 1s, p. 1–24, 2015.
- HUO, Y. Music personalized label clustering and recommendation visualization. **Complexity**, v. 2021, p. 1–8, 2021.
- IBRAHIM, K. M. et al. Audio-based auto-tagging with contextual tags for music. In: IEEE. **ICASSP 2020-2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)**. [S.l.], 2020. p. 16–20.
- IBRAHIM, K. M. et al. Audio-based auto-tagging with contextual tags for music. **ICASSP 2020 - 2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)**, 2020.
- ISO-9241-210, D. 9241–210: 2010: ergonomics of human-system interaction—part 210: human-centred design for interactive systems (formerly known as 13407). **Switzerland: International Standards Organization**, 2010.
- ISO, W. 9241-11. ergonomic requirements for office work with visual display terminals (vdts). **The international organization for standardization**, v. 45, n. 9, 1998.

- IYER, A. V. et al. Emotion based mood enhancing music recommendation. In: **IEEE. 2017 2nd IEEE International Conference on Recent Trends in Electronics, Information & Communication Technology (RTEICT)**. [S.l.], 2017. p. 1573–1577.
- JANSSON, A. Beyond the platform: music streaming as a site of logistical and symbolic struggle. **New Media & Society**, p. 146144482110363, 2021.
- JENKINS, E.; YANG, Y. Creating a music recommendation and streaming application for android. In: SPRINGER. **International Conference on Database and Expert Systems Applications**. [S.l.], 2016. p. 201–215.
- JEYASINGH, M. M.; APPAVOO, K. Mining the shirt sizes for indian men by clustered classification. **International Journal of Information Technology and Computer Science**, v. 4, p. 12–17, 2012.
- JIANG, C.; HE, Y. Smart-dj: Context-aware personalization for music recommendation on smartphones. In: **IEEE. 2016 IEEE 22nd International Conference on Parallel and Distributed Systems (ICPADS)**. [S.l.], 2016. p. 133–140.
- JIN, Y. et al. Contextplay: Evaluating user control for context-aware music recommendation. In: **Proceedings of the 27th ACM Conference on User Modeling, Adaptation and Personalization**. [S.l.: s.n.], 2019. p. 294–302.
- JOHNS, R. One size doesn't fit all: Selecting response scales for attitude items. **Journal of Elections, Public Opinion & Parties**, Taylor & Francis, v. 15, n. 2, p. 237–264, 2005.
- JRAD, R. B. N.; AHMED, M. D.; SUNDARAM, D. Upgrading unupgradable middleware legacy processes: misconceptions, challenges, and a roadmap. **Proceedings of the 1st International Workshop in Software Evolution and Modernization**, 2013.
- JUN, H. J. et al. “seoulhouse2vec”: an embedding-based collaborative filtering housing recommender system for analyzing housing preference. **Sustainability**, v. 12, p. 6964, 2020.
- JUSLIN, P. N. et al. An experience sampling study of emotional reactions to music: listener, music, and situation. **Emotion**, American Psychological Association, v. 8, n. 5, p. 668, 2008.
- KAMINSKAS, M.; RICCI, F. Location-adapted music recommendation using tags. In: SPRINGER. **International conference on user modeling, adaptation, and personalization**. [S.l.], 2011. p. 183–194.
- KAMINSKAS, M.; RICCI, F. Contextual music information retrieval and recommendation: State of the art and challenges. **Computer Science Review**, Elsevier, v. 6, n. 2-3, p. 89–119, 2012.
- KAMINSKAS, M.; RICCI, F.; SCHEDL, M. Location-aware music recommendation using auto-tagging and hybrid matching. In: **Proceedings of the 7th ACM conference on Recommender systems**. [S.l.: s.n.], 2013. p. 17–24.
- KANG, D.; SEO, S. Personalized smart home audio system with automatic music selection based on emotion. **Multimedia Tools and Applications**, Springer, v. 78, n. 3, p. 3267–3276, 2019.



- KARAPANOS, E. et al. User experience over time: an initial framework. In: **Proceedings of the SIGCHI conference on human factors in computing systems**. [S.l.: s.n.], 2009. p. 729–738.
- KARAPANOS, E. et al. Measuring the dynamics of remembered experience over time. **Interacting with Computers**, OUP, v. 22, n. 5, p. 328–335, 2010.
- KARLSSON, B. F.; OKADA, K.; NOLETO, T. A mobile-based system for context-aware music recommendations. In: SPRINGER. **IFIP International Conference on Artificial Intelligence Applications and Innovations**. [S.l.], 2012. p. 520–529.
- KARYDIS, I.; GKIOKAS, A.; KATSOUROS, V. Musical track popularity mining dataset. In: SPRINGER. **Artificial Intelligence Applications and Innovations: 12th IFIP WG 12.5 International Conference and Workshops, AIAI 2016, Thessaloniki, Greece, September 16-18, 2016, Proceedings 12**. [S.l.], 2016. p. 562–572.
- KASINATHAN, V. et al. Heartbeats: music recommendation system with fuzzy inference engine. **Indonesian Journal of Electrical Engineering and Computer Science**, v. 16, n. 1, p. 275–282, 2019.
- KIM, J. H. Shaping and co-shaping forms of vitality in music: beyond cognitivist and emotivist approaches to musical expressiveness. **Empirical Musicology Review**, v. 8, p. 162, 2013.
- KIM, Y. E. et al. Music emotion recognition: A state of the art review. In: **Proc. ISMIR**. [S.l.: s.n.], 2010. p. 255–266.
- KITCHENHAM, B. et al. Systematic literature reviews in software engineering—a systematic literature review. **Information and software technology**, Elsevier, v. 51, n. 1, p. 7–15, 2009.
- KNEES, P.; SCHEDL, M. A survey of music similarity and recommendation from music context data. **ACM Transactions on Multimedia Computing, Communications, and Applications (TOMM)**, ACM New York, NY, USA, v. 10, n. 1, p. 1–21, 2013.
- KNIJNENBURG, B. P. et al. Explaining the user experience of recommender systems. **User Modeling and User-Adapted Interaction**, Springer, v. 22, n. 4, p. 441–504, 2012.
- KO, Y. J. et al. A Patient-centered medical environment with wearable sensors and cloud monitoring. **IEEE World Forum on Internet of Things, WF-IoT 2015 - Proceedings**, p. 628–633, 2015.
- KONSTAN, J. A.; RIEDL, J. Recommender systems: from algorithms to user experience. **User modeling and user-adapted interaction**, Springer, v. 22, n. 1-2, p. 101–123, 2012.
- KRIPPENDORFF, K. **The semantic turn: A new foundation for design**. [S.l.]: crc Press, 2005.
- KUJALA, S. et al. Ux curve: A method for evaluating long-term user experience. **Interacting with computers**, Oxford University Press Oxford, UK, v. 23, n. 5, p. 473–483, 2011.

- LAFIT, G. et al. Selection of the number of participants in intensive longitudinal studies: a user-friendly shiny app and tutorial to perform power analysis in multilevel regression models that account for temporal dependencies. 2020.
- LAMERE, P. Social tagging and music information retrieval. **Journal of new music research**, Taylor & Francis, v. 37, n. 2, p. 101–114, 2008.
- LAMONT, A.; WEBB, R. K. Short- and long-term musical preferences: what makes a favourite piece of music? **Psychology of Music**, v. 38, p. 222–241, 2009.
- LAW, E. L.-C. et al. Understanding, scoping and defining user experience: a survey approach. In: **Proceedings of the SIGCHI conference on human factors in computing systems**. [S.l.: s.n.], 2009. p. 719–728.
- LAZAR, J.; FENG, J. H.; HOCHHEISER, H. **Research methods in human-computer interaction**. [S.l.]: Morgan Kaufmann, 2017.
- LE, N. T. et al. Using vital-sensor in tracking user emotion as a contextual input for music recommendation system. In: **IADIS International Conference Interfaces and Human Computer Interaction 2011, Part of the IADIS Multi Conference on Computer Science and Information Systems 2011, MCCSIS 2011**. [S.l.: s.n.], 2011. p. 316–320.
- LEE, M.; CHO, J.-D. Logmusic: context-based social music recommendation service on mobile device. In: **Proceedings of the 2014 ACM International Joint Conference on Pervasive and Ubiquitous Computing: Adjunct Publication**. [S.l.: s.n.], 2014. p. 95–98.
- LEE, W.-P. et al. A smartphone-based activity-aware system for music streaming recommendation. **Knowledge-Based Systems**, Elsevier, v. 131, p. 70–82, 2017.
- LEHTINIEMI, A.; HOLM, J. Using animated mood pictures in music recommendation. In: **IEEE. 2012 16th International Conference on Information Visualisation**. [S.l.], 2012. p. 143–150.
- LEVITIN, D. J.; TIROVOLAS, A. K. Current advances in the cognitive neuroscience of music. **Annals of the New York Academy of Sciences**, v. 1156, p. 211–231, 2009.
- LI, Q. et al. A music recommender based on audio features. In: **Proceedings of the 27th annual international ACM SIGIR conference on Research and development in information retrieval**. [S.l.: s.n.], 2004. p. 532–533.
- LI, Q.; LIU, D. Research of music recommendation system based on user behavior analysis and word2vec user emotion extraction. In: **SPRINGER. International Conference on Intelligent and Interactive Systems and Applications**. [S.l.], 2017. p. 469–475.
- LIFSON, A. et al. New era of music. 2023.
- LIN, M.-h.; CHENG, S.-h. Semantic shifting within the interaction sequence. In: **Proceedings of IASDR Conference**. [S.l.: s.n.], 2011.

- LIU, H. et al. Neural matrix factorization recommendation for user preference prediction based on explicit and implicit feedback. **Computational Intelligence and Neuroscience**, v. 2022, p. 1–12, 2022.
- LIU, W.; LI, X.; HUANG, D. A survey on context awareness. In: IEEE. **2011 International Conference on Computer Science and Service System (CSSS)**. [S.l.], 2011. p. 144–147.
- LOCHER, P.; OVERBEEKE, K.; WENSVEEN, S. A framework for aesthetic experience. In: CITESEER. **Proceedings of Conference on Human Factors in Computing Systems**. [S.l.], 2009.
- LOCKNER, D. et al. Emotion and interface design. **Proceedings of the 2014 Ergonomie et Informatique Avancée Conference - Design, Ergonomie et IHM: quelle articulation pour la co-conception de l'interaction on - Ergo'IA '14**, p. 33–40, 2014. ISSN 18729126. Disponível em: <<http://dl.acm.org/citation.cfm?doid=2671470.2671475>>.
- LOPES, P. S. et al. The use of the convolutional neural network as an emotion classifier in a music recommendation system. In: **Proceedings of the XIV Brazilian Symposium on Information Systems**. [S.l.: s.n.], 2018. p. 1–8.
- LU, J. et al. Recommender system application developments: a survey. **Decision Support Systems**, v. 74, p. 12–32, 2015.
- LUO, D. et al. Optimally estimating the sample mean from the sample size, median, mid-range, and/or mid-quartile range. **Statistical methods in medical research**, SAGE Publications Sage UK: London, England, v. 27, n. 6, p. 1785–1805, 2018.
- MAGARA, M. B. et al. Mplist: Context aware music playlist. In: IEEE. **2016 IEEE International Conference on Emerging Technologies and Innovative Business Practices for the Transformation of Societies (EmergiTech)**. [S.l.], 2016. p. 309–316.
- MAHLKE, S.; THÜRING, M. Studying antecedents of emotional experiences in interactive contexts. In: **Proceedings of the SIGCHI conference on Human factors in computing systems**. [S.l.: s.n.], 2007. p. 915–918.
- MANDL, M. et al. Consumer decision making in knowledge-based recommendation. **Journal of Intelligent Information Systems**, v. 37, p. 1–22, 2010.
- MANKEL, K.; BARBER, J. L.; BIDELMAN, G. M. Auditory categorical processing for speech is modulated by inherent musical listening skills. **NeuroReport**, v. 31, p. 162–166, 2020.
- MARIAPPAN, M. B.; SUK, M.; PRABHAKARAN, B. Facefetch: A user emotion driven multimedia content recommendation system based on facial expression recognition. In: IEEE. **2012 IEEE International Symposium on Multimedia**. [S.l.], 2012. p. 84–87.
- MARTI, P.; IACONO, I. Anticipated, momentary, episodic, remembered: the many facets of user experience. In: IEEE. **2016 Federated Conference on Computer Science and Information Systems (FedCSIS)**. [S.l.], 2016. p. 1647–1655.

- MCINERNEY, J. et al. Explore, exploit, and explain: personalizing explainable recommendations with bandits. In: **Proceedings of the 12th ACM conference on recommender systems**. [S.l.: s.n.], 2018. p. 31–39.
- MEINECKE, C.; HAKIMI, A. D.; JÄNICKE, S. Explorative visual analysis of rap music. **Information**, v. 13, p. 10, 2021.
- MENDOZA, V.; NOVICK, D. G. Usability over time. In: **Proceedings of the 23rd annual international conference on Design of communication: documenting & designing for pervasive information**. [S.l.: s.n.], 2005. p. 151–158.
- MILES, S. A. et al. What to expect when the unexpected becomes expected: harmonic surprise and preference over time in popular music. **Frontiers in Human Neuroscience**, v. 15, 2021.
- MILLECAMP, M. et al. Controlling spotify recommendations: effects of personal characteristics on music recommender user interfaces. In: **Proceedings of the 26th Conference on user modeling, adaptation and personalization**. [S.l.: s.n.], 2018. p. 101–109.
- MILLER, S. et al. Geoshuffle: Location-aware, content-based music browsing using self-organizing tag clouds. In: **ISMIR**. [S.l.: s.n.], 2010. p. 237–242.
- MOSTEFAOUI, G. K.; PASQUIER-ROCHA, J.; BREZILLON, P. Context-aware computing: a guide for the pervasive computing community. In: IEEE. **The IEEE/ACS International Conference on Pervasive Services, 2004. ICPS 2004. Proceedings**. [S.l.], 2004. p. 39–48.
- MRÓZ, B. Online piracy: an emergent segment of the shadow economy. empirical insight from poland. **Journal of Financial Crime**, Emerald Group Publishing Limited, 2016.
- MURCIEGO, Á. L. et al. Context-aware recommender systems in the music domain: A systematic literature review. **Electronics**, MDPI, v. 10, n. 13, p. 1555, 2021.
- NARDUCCI, F.; GEMMIS, M. D.; LOPS, P. A general architecture for an emotion-aware content-based recommender system. In: **Proceedings of the 3rd Workshop on Emotions and Personality in Personalized Systems 2015**. [S.l.: s.n.], 2015. p. 3–6.
- NIELSEN, J. **Usability engineering**. [S.l.]: Morgan Kaufmann, 1994.
- NIRJON, S. et al. Musicalheart: A hearty way of listening to music. In: **Proceedings of the 10th ACM Conference on Embedded Network Sensor Systems**. [S.l.: s.n.], 2012. p. 43–56.
- NORMAN, D. **Emotional Design: Why We Love (or Hate) Everyday Things**. [S.l.: s.n.], 2004. v. 27. ISBN 0465051359.
- NORMAN, D.; NIELSEN, J. **The Definition of User Experience (UX)**. 2021. Disponível em: <<https://www.nngroup.com/articles/definition-user-experience/>>.
- OKADA, K. et al. ContextPlayer: Learning contextual music preferences for situational recommendations. **SIGGRAPH Asia 2013 Symposium on Mobile Graphics and Interactive Applications on - SA '13**, p. 1–7, 2013. Disponível em: <<http://dl.acm.org/citation.cfm?doid=2543651.2543655>>.

- OLIVEIRA, E. R.; LUZ, L. C.; PRATES, R. O. Aplicação semi-estruturada do método de inspeção semiótica: estudo de caso para o domínio educacional. In: **Proceedings of the VIII Brazilian Symposium on Human Factors in Computing Systems**. [S.l.: s.n.], 2008. p. 50–59.
- OLIVEIRA, E. R. de; PRATES, R. O. Intermediated semiotic inspection method. In: **Proceedings of the 17th Brazilian Symposium on Human Factors in Computing Systems**. [S.l.: s.n.], 2018. p. 1–10.
- ORAMAS, S. et al. Sound and music recommendation with knowledge graphs. **ACM Transactions on Intelligent Systems and Technology**, v. 8, p. 1–21, 2016.
- PAAS, F. et al. Cognitive load measurement as a means to advance cognitive load theory. **Educational psychologist**, Taylor & Francis, v. 38, n. 1, p. 63–71, 2003.
- PADOVANI, R. R.; FERREIRA, L. N.; LELIS, L. H. Bardo: Emotion-based music recommendation for tabletop role-playing games. In: **Thirteenth Artificial Intelligence and Interactive Digital Entertainment Conference**. [S.l.: s.n.], 2017.
- PANDA, R. et al. How does the spotify api compare to the music emotion recognition state-of-the-art? In: AXEA SAS/SMC NETWORK. **Proceedings of the 18th Sound and Music Computing Conference (SMC 2021)**. [S.l.], 2021. p. 238–245.
- PARK, M.; LEE, K. Exploiting negative preference in content-based music recommendation with contrastive learning. 2022.
- PEFFERS, K. et al. Design science research evaluation. In: SPRINGER. **Design Science Research in Information Systems. Advances in Theory and Practice: 7th International Conference, DESRIST 2012, Las Vegas, NV, USA, May 14-15, 2012. Proceedings 7**. [S.l.], 2012. p. 398–410.
- PRENIQI, V.; KALIMERI, K.; SAITIS, C. Soundscapes of morality: linking music preferences and moral values through lyrics and audio. 2023.
- PRIBEANU, C. A revised set of usability heuristics for the evaluation of interactive systems. **Informatica Economica**, INFOREC Association, v. 21, n. 3, p. 31, 2017.
- PYO, T.; LEE, J. Y.; PARK, H. M. The effects of consumer preference and peer influence on trial of an experience good. **Journal of Marketing Research**, v. 59, p. 1161–1178, 2022.
- RAJESWARI, J. S.; HARIHARAN, S. Personalized search recommender system: state of art, experimental results and investigations. **International Journal of Education and Management Engineering**, v. 6, p. 1–8, 2016.
- RAZZAQUE, M. A.; DOBSON, S.; NIXON, P. Categorization and modelling of quality in context information. American Scientific Publishers, 2006.
- REN, Y.; MA, Y.; WANG, J. Security ct after-sales service system design based on ssi framework. 2016.
- RENTFROW, P. J.; GOSLING, S. D. The do re mi's of everyday life: The structure and personality correlates of music preferences. **Journal of Personality and Social Psychology**, v. 84, n. 6, p. 1236–1256, 2003. ISSN 1939-1315. Disponível em: <<http://doi.apa.org/getdoi.cfm?doi=10.1037/0022-3514.84.6.1236>>.

- RESNICK, P.; VARIAN, H. R. Recommender systems. **Communications of the ACM**, ACM New York, NY, USA, v. 40, n. 3, p. 56–58, 1997.
- RHO, S. et al. Implementing situation-aware and user-adaptive music recommendation service in semantic web and real-time multimedia computing environment. **Multimedia tools and applications**, Springer, v. 65, n. 2, p. 259–282, 2013.
- RIEHMANN, P.; HANFLER, M.; FROEHLICH, B. Interactive sankey diagrams. In: IEEE. **IEEE Symposium on Information Visualization, 2005. INFOVIS 2005**. [S.l.], 2005. p. 233–240.
- ROBERT, J.-M.; LESAGE, A. Designing and evaluating user experience. In: **The handbook of human-machine interaction**. [S.l.]: CRC Press, 2017. p. 321–338.
- ROSA, R. L.; RODRIGUEZ, D. Z.; BRESSAN, G. Music recommendation system based on user’s sentiments extracted from social networks. **IEEE Transactions on Consumer Electronics**, IEEE, v. 61, n. 3, p. 359–367, 2015.
- ROSLY, R. M.; KHALID, F. Evaluation of the “e-daftar” system using the technology acceptance model (tam). **Creative Education**, Scientific Research Publishing, v. 9, n. 5, p. 675–686, 2018.
- ROTO, V. et al. Ux white paper: Bringing clarity to the concept of ux. **2011**, 2011.
- ROTO, V. et al. **User Experience White Paper. Outcome of the Dagstuhl Seminar on Demarcating User Experience, Germany**. 2015.
- RUSSELL, J. A.; WEISS, A.; MENDELSON, G. A. Affect Grid: A Single-Item Scale of Pleasure and Arousal. **Journal of Personality and Social Psychology**, v. 57, n. 3, p. 493–502, 1989.
- SAGAR, K.; SAHA, A. A systematic review of software usability studies. **International Journal of Information Technology**, Springer, p. 1–24, 2017.
- SALDAÑA, J. **The coding manual for qualitative researchers**. [S.l.]: sage, 2021.
- SCHEDL, M. Ameliorating music recommendation: Integrating music content, music context, and user context for improved music retrieval and recommendation. In: **Proceedings of International Conference on Advances in Mobile Computing & Multimedia**. [S.l.: s.n.], 2013. p. 3–9.
- SCHEDL, M.; BREITSCHOPF, G.; IONESCU, B. Mobile music genius: Reggae at the beach, metal on a friday night? In: **Proceedings of International Conference on Multimedia Retrieval**. [S.l.: s.n.], 2014. p. 507–510.
- SCHEDL, M. et al. Current challenges and visions in music recommender systems research. **International Journal of Multimedia Information Retrieval**, Springer, v. 7, n. 2, p. 95–116, 2018.
- SCHERER, K. R. What are emotions? And how can they be measured? **Social Science Information**, v. 44, n. 4, p. 695–729, dez. 2005. ISSN 0539-0184.
- SCHILIT, B.; ADAMS, N.; WANT, R. Context-aware computing applications. In: IEEE. **1994 First Workshop on Mobile Computing Systems and Applications**. [S.l.], 1994. p. 85–90.

- SCHILIT, B. N.; THEIMER, M. M. Disseminating active map information to mobile hosts. **IEEE network**, IEEE, v. 8, n. 5, p. 22–32, 1994.
- SCHMIDT, A.; BEIGL, M.; GELLERSEN, H.-W. There is more to context than location. **Computers & Graphics**, Elsevier, v. 23, n. 6, p. 893–901, 1999.
- SEN, A.; LARSON, M. From sensors to songs: A learning-free novel music recommendation system using contextual sensor data. In: **LocalRec@ RecSys**. [S.l.: s.n.], 2015. p. 40–43.
- SIDEN, H. et al. Designing and implementing a longitudinal study of children with neurological, genetic or metabolic conditions: charting the territory. **BMC Pediatrics**, v. 10, 2010.
- SILVER, D.; LEE, M.; CHILDRESS, C. Genre complexes in popular music. **Plos One**, v. 11, p. e0155471, 2016.
- SIMONE. **Improve your Flow in Deezer**. 2021. Disponível em: <<https://support.deezer.com/hc/en-gb/articles/115004367189-Improve-your-Flow-in-Deezer>>.
- SINHA, A.; GLEICH, D. F.; RAMANI, K. Deconvolving feedback loops in recommender systems. 2017.
- SNYDER, M.; ICKES, W. Personality and social behavior. **Handbook of social psychology**, v. 2, n. 3, p. 883–947, 1985.
- SOMEREN, M. W. van; BARNARD, Y. F.; SANDBERG, J. A. C. **The Think Aloud Method: A practical guide to modelling cognitive processes**. London, UK: Academic Press, 1994. 218 p. ISBN 0127142703.
- SONG, Y.; DIXON, S.; PEARCE, M. A survey of music recommendation systems and future perspectives. In: CITESEER. **9th International Symposium on Computer Music Modeling and Retrieval**. [S.l.], 2012. v. 4, p. 395–410.
- SOUZA, C. S. D. **The semiotic engineering of human-computer interaction**. [S.l.]: MIT press, 2005.
- SOUZA, C. S. D.; LEITÃO, C. F. Semiotic engineering methods for scientific research in hci. **Synthesis Lectures on Human-Centered Informatics**, Morgan & Claypool Publishers, v. 2, n. 1, p. 1–122, 2009.
- SOUZA, C. S. D. et al. The semiotic inspection method. In: **Proceedings of VII Brazilian symposium on Human factors in computing systems**. [S.l.: s.n.], 2006. p. 148–157.
- SOUZA, C. S. de et al. Can inspection methods generate valid new knowledge in hci? the case of semiotic inspection. **International Journal of Human-Computer Studies**, Elsevier, v. 68, n. 1-2, p. 22–40, 2010.
- SPOTIFY. **Company Info**. 2021. Disponível em: <<https://newsroom.spotify.com/company-info/>>.
- SUBBU, K. P.; VASILAKOS, A. V. Big data for context aware computing—perspectives and challenges. **Big Data Research**, Elsevier, v. 10, p. 33–43, 2017.

- SUN, D. P. Using factor decomposition machine learning method to music recommendation. **Complexity**, v. 2021, p. 1–10, 2021.
- SUN, H. Interactive knowledge visualization based on iot and augmented reality. **Journal of Sensors**, 2022.
- SUN, J. Personalized music recommendation algorithm based on spark platform. **Computational Intelligence and Neuroscience**, v. 2022, p. 1–9, 2022.
- SUN, P. Music individualization recommendation system based on big data analysis. **Computational Intelligence and Neuroscience**, Hindawi, v. 2022, 2022.
- SUN, Y. c. **Wireless Communications and Mobile Computing**, 2023.
- SYAKUR, M. et al. Integration k-means clustering method and elbow method for identification of the best customer profile cluster. In: IOP PUBLISHING. **IOP conference series: materials science and engineering**. [S.l.], 2018. v. 336, p. 012017.
- TABER, K. S. The use of cronbach’s alpha when developing and reporting research instruments in science education. **Research in science education**, Springer, v. 48, p. 1273–1296, 2018.
- TAKEUCHI, M.; MORISHITA, S.; SANO, Y. Music roles affect the selection of consumption means: a questionnaire survey of people’s expectations for music and exploratory factor analysis. **The Review of Socionetwork Strategies**, v. 16, p. 453–464, 2022.
- TEIXEIRA, G. V.; ZAINA, L. A. Using lean personas to the description of ux-related requirements: A study with software startup professionals. In: **ICEIS (2)**. [S.l.: s.n.], 2022. p. 211–222.
- TENG, Y.-C.; KUO, Y.-S.; YANG, Y.-H. A large in-situ dataset for context-aware music recommendation on smartphones. In: IEEE. **2013 IEEE International Conference on Multimedia and Expo Workshops (ICMEW)**. [S.l.], 2013. p. 1–4.
- TERZIS, S. et al. Middleware for pervasive and ad hoc computing. **Personal and Ubiquitous Computing**, v. 10, p. 4–6, 2005.
- THAYER, R. E. **The biopsychology of mood and arousal**. [S.l.]: Oxford University Press, 1990.
- THOMES, T. P. An economic analysis of online streaming music services. **Information Economics and Policy**, Elsevier, v. 25, n. 2, p. 81–91, 2013.
- TSUKUDA, K.; GOTO, M. Taste or addiction?: using play logs to infer song selection motivation. **Advances in Knowledge Discovery and Data Mining**, p. 721–733, 2017.
- TUULARI, E. Context aware hand-held devices. **VTT publications**, TECHNICAL RESEARCH CENTRE OF FINLAND ESPOO, v. 4, n. 1, p. 2, 2000.
- UTIMULA, K. et al. Stochastic estimations of the total number of classes for a clustering having extremely large samples to be included in the clustering engine. **Advanced Theory and Simulations**, v. 4, 2021.



- VALL, A. et al. Feature-combination hybrid recommender systems for automated music playlist continuation. **User Modeling and User-Adapted Interaction**, v. 29, p. 527–572, 2019.
- VATEEKUL, P. et al. Item-based learning for music emotion prediction using eeg data. In: **Principles and Practice of Multi-Agent Systems**. [S.l.]: Springer, 2015. p. 155–167.
- VELANKAR, M.; KULKARNI, P. Music recommendation systems: Overview and challenges. In: \_\_\_\_\_. **Advances in Speech and Music Technology: Computational Aspects and Applications**. Cham: Springer International Publishing, 2023. p. 51–69. ISBN 978-3-031-18444-4. Disponível em: <[https://doi.org/10.1007/978-3-031-18444-4\\_3](https://doi.org/10.1007/978-3-031-18444-4_3)>.
- VENKATESH, V. et al. User acceptance of information technology: Toward a unified view. **MIS quarterly**, JSTOR, p. 425–478, 2003.
- VERMEEREN, A. P. et al. User experience evaluation methods: current state and development needs. In: **Proceedings of the 6th Nordic conference on human-computer interaction: Extending boundaries**. [S.l.: s.n.], 2010. p. 521–530.
- VOLOKHIN, S.; AGICHTTEIN, E. Towards intent-aware contextual music recommendation: Initial experiments. In: **The 41st International ACM SIGIR Conference on Research & Development in Information Retrieval**. New York, NY, USA: Association for Computing Machinery, 2018. (SIGIR '18), p. 1045–1048. ISBN 9781450356572. Disponível em: <<https://doi.org/10.1145/3209978.3210154>>.
- WANG, C.-Y.; WANG, Y.-C.; CHOU, S.-C. T. A context and emotion aware system for personalized music recommendation. **Journal of Internet Technology**, v. 19, n. 3, p. 765–779, 2018.
- WANG, D. et al. Learning to embed music and metadata for context-aware music recommendation. **World Wide Web**, v. 21, p. 1399–1423, 2017.
- WANG, X.; ROSENBLUM, D.; WANG, Y. Context-aware mobile music recommendation for daily activities. In: **Proceedings of the 20th ACM international conference on Multimedia**. [S.l.: s.n.], 2012. p. 99–108.
- WANT, R. et al. An overview of the parctab ubiquitous computing experiment. **IEEE Personal Communications**, v. 2, n. 6, p. 28–43, 1995.
- WARRINER, A. B. et al. Sliding into happiness: a new tool for measuring affective responses to words. **Canadian Journal of Experimental Psychology - Revue Canadienne De Psychologie Experimentale**, v. 71, p. 71–88, 2017.
- WELCH, K. C. Physiological signals of autistic children can be useful. **IEEE Instrumentation & Measurement Magazine**, IEEE, v. 15, n. 1, p. 28–32, 2012.
- WIERINGA, R. J. **Design science methodology for information systems and software engineering**. [S.l.]: Springer, 2014.

- WILAMOWITZ-MOELLENDORFF, M. von; HASSENZAHL, M.; PLATZ, A. Dynamics of user experience: How the perceived quality of mobile phones changes over time. In: **User Experience-Towards a unified view, Workshop at the 4th Nordic Conference on Human-Computer Interaction**. [S.l.: s.n.], 2006. p. 74–78.
- WILLEMSSEN, M. C. et al. Using latent features diversification to reduce choice difficulty in recommendation lists. **RecSys**, v. 11, n. 2011, p. 14–20, 2011.
- WISCHENBART, M. et al. Engaging end-user driven recommender systems: personalization through web augmentation. **Multimedia Tools and Applications**, v. 80, p. 6785–6809, 2020.
- WOHLFAHRT-LAYMANNA, J.; HEIMBURGERH, A. Content aware music analysis with multi-dimensional similarity measure. **Information Modelling and Knowledge Bases XXVIII**, IOS Press, v. 292, p. 303, 2017.
- WU, J. Research on product design strategy based on user preference and machine learning intelligent recommendation. **Wireless Communications and Mobile Computing**, v. 2022, p. 1–11, 2022.
- XIE, L. et al. Explainable recommendation based on knowledge graph and multi-objective optimization. **Complex & Intelligent Systems**, v. 7, p. 1241–1252, 2021.
- XU, J.; GAN, M.; ZHANG, X. Mmusic: a hierarchical multi-information fusion method for deep music recommendation. **Journal of Intelligent Information Systems**, Springer, p. 1–24, 2023.
- XUE, L. et al. Implications of application programming interfaces for third-party new app development and copycatting. **Production and Operations Management**, v. 28, p. 1887–1902, 2019.
- YANG, J. et al. Emotion-aware music recommendation. In: SPRINGER. **International Conference of Design, User Experience, and Usability**. [S.l.], 2016. p. 110–121.
- YANG, Y.-H.; CHEN, H. H. **Music emotion recognition**. [S.l.]: CRC Press, 2011.
- YANG, Y.-H.; TENG, Y.-C. Quantitative study of music listening behavior in a smartphone context. **ACM Transactions on Interactive Intelligent Systems (TiIS)**, ACM New York, NY, USA, v. 5, n. 3, p. 1–30, 2015.
- YEUNG, K. F.; YANG, Y. A proactive personalized mobile news recommendation system. In: IEEE. **2010 Developments in E-systems Engineering**. [S.l.], 2010. p. 207–212.
- YOO, H. Multicultural choral music pedagogy based on the facets model. **Music Educators Journal**, v. 104, p. 34–39, 2017.
- YOON, K.; LEE, J.; KIM, M.-U. Music recommendation system using emotion triggering low-level features. **IEEE Transactions on Consumer Electronics**, IEEE, v. 58, n. 2, p. 612–618, 2012.
- YOUTUBE. **YouTube Music Premium**. 2021. Disponível em: <<https://www.youtube.com/musicpremium>>.

YU, P.; LIN, L.; WANG, J. A novel framework to alleviate the sparsity problem in context-aware recommender systems. **New Review of Hypermedia and Multimedia**, v. 23, p. 141–158, 2016.

ZANGERLE, E.; PICHL, M.; SCHEDL, M. User models for culture-aware music recommendation: fusing acoustic and cultural cues. **Transactions of the International Society for Music Information Retrieval**, v. 3, p. 1–16, 2020.

ZHANG, Y. et al. Causal intervention for leveraging popularity bias in recommendation. **Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval**, 2021.

ZIEGLER, C. et al. Improving recommendation lists through topic diversification. **Proceedings of the 14th International Conference on World Wide Web - WWW '05**, 2005.

# Apêndices

---

## APÊNDICE A

Avaliação da Experiência do Usuário  
em Plataformas Comerciais de  
Música: Questionário de Perfil dos  
Participantes e Questionário SAM

---

# Recomendação de música

## considerando a emoção e o contexto

Eu, Willian Garcias de Assunção, aluno de Doutorado do programa de pós-graduação em Ciência da Computação pela Universidade Federal de São Carlos (UFSCar), convido a participar da pesquisa intitulada "Recomendação musical considerando a emoção e o contexto do usuário".

Esta pesquisa tem como objetivo identificar diante dos sistemas de recomendação musical a implementação ou não de aspectos considerados desejáveis nos sistemas de recomendação música, tais como: a atividade do usuário, satisfação, feedback, cold-start, carga cognitiva, aprendizado, personalidade e preferências do usuário. Dentro desta pesquisa, foi selecionado um conjunto de ferramentas de transmissão musical que buscam ajudar o ouvinte a melhorar sua experiência de escuta musical. Neste sentido, o objetivo desta atividade é avaliar como a ferramenta \_\_\_\_\_ lida e trata os aspectos desejáveis durante a recomendação de música. Para isto estão sendo propostas tarefas que envolvem a seleção e busca de informações na ferramenta; essas tarefas serão fornecidas no início da atividade. Após a conclusão de cada tarefa realizada na ferramenta o participante irá preencher o instrumento Self Assessment Manikin (SAM) para classificação das respostas emocionais. Os pesquisadores estarão disponíveis durante a atividade para sanar quaisquer dúvidas que possam surgir. O público-alvo de respondentes da pesquisa são ouvintes de músicas que possuem o hábito de ouvir música em seu dia a dia.

Diante disso, solicitamos o seu consentimento para participação no estudo, em especial quanto a coleta de dados. Para decidir sobre o seu consentimento, é importante que você conheça as seguintes informações sobre a pesquisa:

- Os dados coletados durante o estudo destinam-se estritamente as atividades de cunho acadêmico;
- Os pesquisadores se comprometem em divulgar os resultados da pesquisa para toda a instituição, após a conclusão do trabalho. A divulgação desses resultados pauta-se no respeito à sua privacidade, e o anonimato dos participantes será preservado em quaisquer documentos que elaborarmos;
- O estudo vai acontecer na modalidade on-line através da plataforma Google Meet, e será gravada em áudio e vídeo para que o pesquisador possa ter acesso integral e fiel a fonte dos dados coletados.
- Todas as gravações serão baixadas para que a análise de vídeo possa ser feita localmente usando a plataforma Atlas.ti. Após baixar as gravações, todo e qualquer registro será excluído de qualquer plataforma virtual, ambiente compartilhado, ou "nuvem".
- Os pesquisadores se responsabilizam pela guarda e confidencialidade de todos os dados coletados no estudo, eles serão os únicos a terem acesso aos dados e tomarão

todas as providencias necessárias para manter o sigilo das informações.

- Depois que a análise dos vídeos for realizada utilizando a plataforma Atlas.ti, as gravações locais também serão apagadas.
- A transmissão e reprodução de produtos audiovisuais e/ou resultantes são de uso exclusivo para o desenvolvimento da pesquisa, ou seja, esses materiais não serão distribuídos para terceiros, em nenhuma hipótese, e serão usados apenas com intuito acadêmico;
- O participante terá acesso aos resultados da pesquisa sempre que desejar e solicitar devendo entrar em contato com o pesquisador responsável;
- O cansaço e estresse do participante, que pode ser um possível dano causado pela sua participação nesta pesquisa, é mitigado através da apresentação de um questionário de perfil curto onde o participante gastará em média 5 minutos para o preenchimento;
- O cansaço e estresse do participante, que pode ser um possível dano causado pela sua participação nesta pesquisa, é mitigado através de sessões de avaliação da ferramenta que terão duração máxima de 1 hora;
- O consentimento para qualquer atividade que envolva coleta de dados é uma escolha livre, feita mediante a prestação de todos os esclarecimentos necessários sobre a pesquisa;
- O participante tem plena liberdade para decidir sobre sua participação sem prejuízo ou represália alguma, de qualquer natureza;
- O participante tem plena liberdade de retirar seu consentimento, em qualquer fase da pesquisa, sem prejuízo ou represália alguma, de qualquer natureza. Nesse caso, os dados colhidos de sua participação até o momento da retirada do consentimento serão descartados a menos que o participante autorize explicitamente o contrário;
- O participante pode solicitar assistência antes, durante ou depois de finalizar sua participação entrando em contato por e-mail com o pesquisador responsável ou solicitando o auxílio ao um dos pesquisadores durante a aplicação do estudo;
- A participação nesta pesquisa é voluntária e sem qualquer compensação financeira;
- Todas as despesas com o transporte e a alimentação decorrentes da sua participação na pesquisa, quando for o caso, serão ressarcidas no dia da coleta. Você terá direito a indenização por qualquer tipo de dano resultante da sua participação na pesquisa;
- Este termo ficará armazenado em formato digital sob a guarda do pesquisador responsável, sendo que o participante poderá solicitar uma cópia digital do documento a qualquer momento caso deseje.

Qualquer dúvida sobre o estudo é possível contatar o pesquisador pelo e-mail

[willian.assuncao@ufscar.br](mailto:willian.assuncao@ufscar.br)

Esta coleta de dados foi autorizada pelo Comitê de Ética em Pesquisa (CEP) da Universidade Federal de São Carlos (UFSCar), vinculado à Comissão Nacional de Ética em Pesquisa (CONEP), do Conselho Nacional de Saúde (CNS) do Ministério da Saúde (MS). O CEP tem por finalidade cumprir e fazer cumprir o disposto nas Resoluções CNS nº 510/16, nº 370/07, nº 240/97, nº 563/17, nº 580/18 e nas Normas Operacionais nº 006/09 e nº 001/13, além das demais resoluções do Conselho Nacional de Saúde, no que diz respeito aos aspectos éticos das pesquisas envolvendo seres humanos, sob a ética do indivíduo e das coletividades, de modo a prezar pela seguridade aos direitos dos participantes da pesquisa e os direitos e deveres da comunidade científica e do Estado. Os dados do CEP da UFSCar para contato são: Rd. Washington Luiz KM 235, CEP 13565-905, São Carlos - SP, Fone: (16) 33519685, e-mail: [cephumanos@ufscar.br](mailto:cephumanos@ufscar.br).

Após a leitura do presente termo, caso haja aceite, selecione a opção "Concordo em participar", localizada abaixo da apresentação do TCLE on-line, acusando que leu e está de acordo com o Termo apresentado.

**\*Obrigatório**

1. Tendo em vista o Termo de Consentimento Livre e Esclarecido acima, você aceita participar desta pesquisa? \*

*Marcar apenas uma oval.*

Concordo em participar

Não concordo em participar

2. Nome completo \*

---

3. E-mail \*

---



4. Gênero \*

*Marcar apenas uma oval.*

- Masculino
- Feminino
- Prefiro não dizer

5. Idade \*

*Marcar apenas uma oval.*

- 18 anos a 24 anos
- 25 anos a 34 anos
- 35 anos a 44 anos
- 45 anos a 54 anos
- Mais de 54

6. Escolaridade \*

*Marcar apenas uma oval.*

- Nenhuma escolaridade
- Ensino fundamental: 1a a 4a série
- Ensino Fundamental: 5a a 8a série
- Ensino médio
- Superior
- Pós-graduação

7. Com que frequência você ouve música? \*

*Marcar apenas uma oval.*

- Todos os dias
- Uma vez por semana
- Duas vezes por semana
- Três ou mais vezes por semana
- Nenhum dia

8. Qual dispositivo a seguir você prefere ouvir suas músicas? \*

*Marcar apenas uma oval.*

- Celular
- Computador
- Smart TV
- Rádio
- Outro

9. Qual dos seguintes contextos você costuma ouvir música (você pode selecionar mais de uma opção)? \*

*Marque todas que se aplicam.*

- No trabalho
- Alimentando
- Dirigindo
- Exercitando
- Brincando
- Em um veículo
- Durante a leitura
- Ao dormir
- Durante o banho
- Outro

10. Em que estados emocionais você costuma ouvir música (você pode selecionar mais de uma opção)? \*

*Marque todas que se aplicam.*

- Zangado
- Abençoado
- Exaltado
- Medroso
- Feliz
- Sem ânimo
- Tranquilo
- Inquieto
- Triste
- Outro

11. Qual a sua principal plataforma de escuta musical? \*

*Marcar apenas uma oval.*

- Deezer
- Apple Music
- Last.Fm
- Spotify
- SoundCloud
- YouTube
- Google Play Music
- Outro

12. Quais gêneros musicais você costuma ouvir? \*

*Marque todas que se aplicam.*

- Axé
- Blues
- Country
- Eletrônica
- Forró
- Funk
- Gospel
- Hip Hop
- Jazz
- MPB
- Música Clássica
- Pagode
- Pop
- Rap
- Reggae
- Rock
- Samba
- Sertanejo
- Outro

---

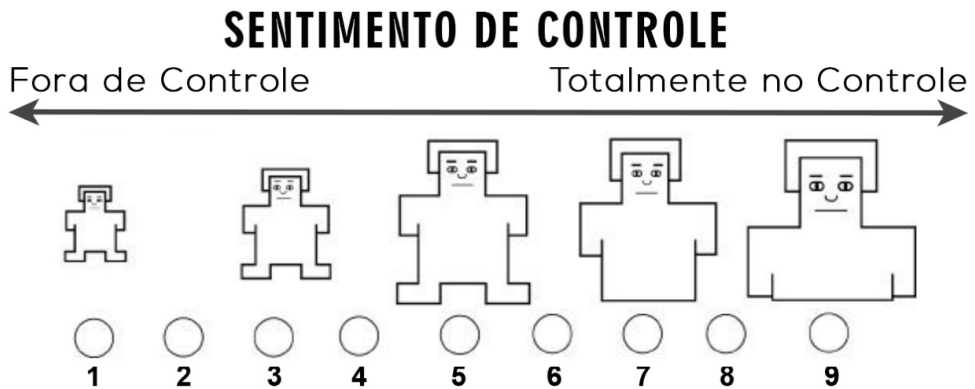
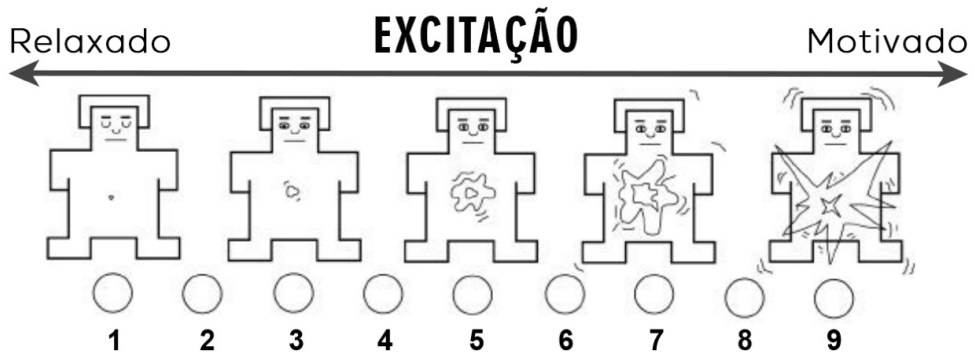
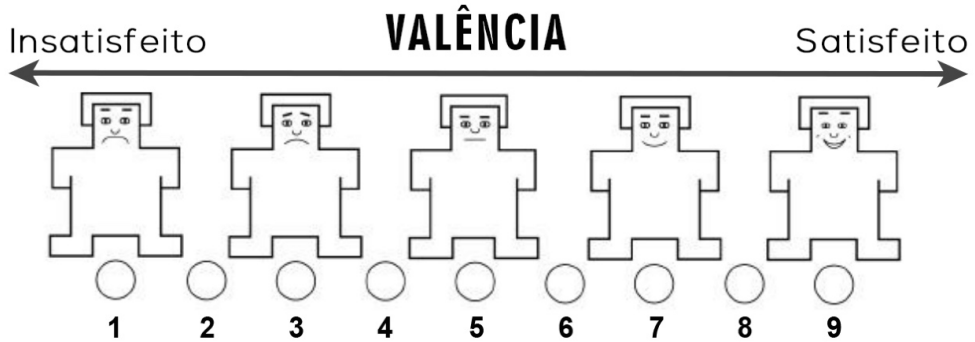
Este conteúdo não foi criado nem aprovado pelo Google.

Google Formulários

# SAM

(Self Assessment Manikin)

Participante: \_\_\_\_\_ Tarefa: \_\_\_\_\_



---

## APÊNDICE B

Avaliação da Comunicabilidade da  
UConteXt Arch no MixFy:  
Questionário de Perfil Demográfico,  
Questionário TAM e Roteiro de  
Inspeção

---

# Pesquisa de Interesse MixFy

Eu, Willian Garcias de Assunção, aluno de Doutorado do programa de pós-graduação em Ciência da Computação pela Universidade Federal de São Carlos (UFSCar), convido a participar da pesquisa intitulada "Recomendação musical considerando a emoção e o contexto do usuário".

Esta pesquisa tem como objetivo o desenvolvimento e validação de uma abordagem de recomendação musical que considera o contexto e a experiência do usuário e relacionada a outros aspectos (por exemplo, satisfação, atividade do usuário, feedback e outros) além da precisão dos algoritmos. Para avaliar a abordagem proposta foi construído uma ferramenta (aplicativo) chamado MixFy que foi integrado à plataforma comercial Spotify que oferece acesso a uma biblioteca ampla de músicas. Dentro desta pesquisa, será feito uma avaliação para verificar se abordagem de recomendação proposta atende e implementa os aspectos desejáveis de maneira que o contexto do usuário seja obtido de maneira \_\_\_\_\_. Para isso estão sendo propostas tarefas que envolvem busca de músicas, audição das prévias e avaliações das recomendações oferecidas pelo MixFy. Após a conclusão de cada tarefa serão feitos questionamentos a respeito do comportamento da ferramenta e percepção do uso da ferramenta por parte dos participantes. Os pesquisadores estarão disponíveis durante a atividade para sanar quaisquer dúvidas que possam surgir. O público-alvo de respondentes da pesquisa são ouvintes de músicas que possuem o hábito de ouvir música em seu dia a dia.

Diante disso, solicitamos o seu consentimento para participação no estudo, em especial quanto a coleta de dados. Para decidir sobre o seu consentimento, é importante que você conheça as seguintes informações sobre a pesquisa:

- Os dados coletados durante o estudo destinam-se estritamente as atividades de cunho acadêmico;
- Os pesquisadores se comprometem em divulgar os resultados da pesquisa para toda a instituição, após a conclusão do trabalho. A divulgação desses resultados pauta-se no respeito à sua privacidade, e o anonimato dos participantes será preservado em quaisquer documentos que elaborarmos;
- O estudo vai acontecer na modalidade on-line através da plataforma Google Meet, e será gravada em áudio e vídeo para que o pesquisador possa ter acesso integral e fiel a fonte dos dados coletados.
- Todas as gravações serão baixadas para que a análise de vídeo possa ser feita localmente usando a plataforma Atlas.ti. Após baixar as gravações, todo e qualquer registro será excluído de qualquer plataforma virtual, ambiente compartilhado, ou "nuvem".
- Os pesquisadores se responsabilizam pela guarda e confidencialidade de todos os dados coletados no estudo, eles serão os únicos a terem acesso aos dados e tomarão todas as providencias necessárias para manter o sigilo das informações.
- Depois que a análise dos vídeos for realizada utilizando a plataforma Atlas.ti, as

gravações locais também serão apagadas.

- A transmissão e reprodução de produtos audiovisuais e/ou resultantes são de uso exclusivo para o desenvolvimento da pesquisa, ou seja, esses materiais não serão distribuídos para terceiros, em nenhuma hipótese, e serão usados apenas com intuito acadêmico;
- O participante terá acesso aos resultados da pesquisa sempre que desejar e solicitar devendo entrar em contato com o pesquisador responsável;
- O cansaço e estresse do participante, que pode ser um possível dano causado pela sua participação nesta pesquisa, é mitigado através da apresentação de um questionário de perfil curto onde o participante gastará em média 5 minutos para o preenchimento;
- O cansaço e estresse do participante, que pode ser um possível dano causado pela sua participação nesta pesquisa, é mitigado através de sessões de avaliação da ferramenta que terão duração máxima de 1 hora;
- O consentimento para qualquer atividade que envolva coleta de dados é uma escolha livre, feita mediante a prestação de todos os esclarecimentos necessários sobre a pesquisa;
- O participante tem plena liberdade para decidir sobre sua participação sem prejuízo ou represália alguma, de qualquer natureza;
- O participante tem plena liberdade de retirar seu consentimento, em qualquer fase da pesquisa, sem prejuízo ou represália alguma, de qualquer natureza. Nesse caso, os dados colhidos de sua participação até o momento da retirada do consentimento serão descartados a menos que o participante autorize explicitamente o contrário;
- O participante pode solicitar assistência antes, durante ou depois de finalizar sua participação entrando em contato por e-mail com o pesquisador responsável ou solicitando o auxílio ao um dos pesquisadores durante a aplicação do estudo;
- A participação nesta pesquisa é voluntária e sem qualquer compensação financeira;
- Todas as despesas com o transporte e a alimentação decorrentes da sua participação na pesquisa, quando for o caso, serão ressarcidas no dia da coleta. Você terá direito a indenização por qualquer tipo de dano resultante da sua participação na pesquisa;
- Este termo ficará armazenado em formato digital sob a guarda do pesquisador responsável, sendo que o participante poderá solicitar uma cópia digital do documento a qualquer momento caso deseje.

Qualquer dúvida sobre o estudo é possível contatar o pesquisador pelo e-mail [willian.assuncao@ufscar.br](mailto:willian.assuncao@ufscar.br)

Esta coleta de dados foi autorizada pelo Comitê de Ética em Pesquisa (CEP) da Universidade Federal de São Carlos (UFSCar), vinculado à Comissão Nacional de Ética em Pesquisa (CONEP), do Conselho Nacional de Saúde (CNS) do Ministério da Saúde (MS). O CEP tem por finalidade cumprir e fazer cumprir o disposto nas Resoluções CNS nº 510/16, nº 370/07, nº 240/97, nº 563/17, nº 580/18 e nas Normas Operacionais nº



006/09 e nº 001/13, além das demais resoluções do Conselho Nacional de Saúde, no que diz respeito aos aspectos éticos das pesquisas envolvendo seres humanos, sob a ética do indivíduo e das coletividades, de modo a prezar pela seguridade aos direitos dos participantes da pesquisa e os direitos e deveres da comunidade científica e do Estado. Os dados do CEP da UFSCar para contato são: Rd. Washington Luiz KM 235, CEP 13565-905, São Carlos - SP, Fone: (16) 33519685, e-mail: [cephumanos@ufscar.br](mailto:cephumanos@ufscar.br).

Após a leitura do presente termo, caso haja aceite, selecione a opção "Concordo em participar", localizada abaixo da apresentação do TCLE on-line, acusando que leu e está de acordo com o Termo apresentado.

1. Tendo em vista o Termo de Consentimento Livre e Esclarecido acima, você aceita participar desta pesquisa?

*Marcar apenas uma oval.*

- Concordo em participar
- Não concordo em participar

2. Nome completo

---

3. E-mail

---

Perfil Demográfico

4. Gênero

*Marcar apenas uma oval.*

- Feminino
- Masculino
- Prefiro não dizer

5. Idade

*Marcar apenas uma oval.*

- 18 anos a 24 anos
- 25 anos a 34 anos
- 35 anos a 44 anos
- 45 anos a 54 anos
- Mais de 54 anos

6. Escolaridade

*Marcar apenas uma oval.*

- Nenhuma escolaridade
- Ensino fundamental: 1a a 4a série
- Ensino fundamental: 5a a 8a série
- Ensino médio
- Ensino superior
- Pós-graduação

Assumindo que você utilizou o aplicativo MixFy durante o período de 5 dias, o quanto você concorda com as afirmativas abaixo, referente funcionalidades:

7. O MixFy me ajuda a encontrar músicas relacionadas ao meu artista preferido.

*Marcar apenas uma oval.*

Discordo plenamente

1

2

3

4

Concordo plenamente

8. O MixFy me sugere músicas relacionadas aos meus gêneros musicais preferidos

*Marcar apenas uma oval.*

Discordo plenamente

1

2

3

4

Concordo plenamente

9. O MixFy identifica meu contexto e recomenda músicas adequadas.

*Marcar apenas uma oval.*

Discordo plenamente

1

2

3

4

Concordo plenamente

10. O MixFy atualiza constantemente as recomendações e traz novas músicas.

*Marcar apenas uma oval.*

Discordo plenamente

1

2

3

4

Concordo plenamente

11. O MixFy permite que eu avalie constantemente as recomendações oferecidas.

Marcar *apenas uma oval.*

Discordo plenamente

1

2

3

4

Concordo plenamente

12. O MixFy aprende constantemente minhas preferências e evita sugestões de músicas fora do meu estilo musical preferido.

Marcar *apenas uma oval.*

Discordo plenamente

1

2

3

4

Concordo plenamente

Assumindo que você assistiu ao vídeo inicial e acessou ao protótipo do aplicativo, o quanto você concorda com as afirmativas abaixo, referente usabilidade:

13. Aprender a usar o MixFy seria fácil para mim

Marcar apenas uma oval.

Discordo plenamente

1

2

3

4

Concordo plenamente

14. Eu acharia fácil usar as funcionalidades do MixFy

Marcar apenas uma oval.

Discordo plenamente

1

2

3

4

Concordo plenamente

15. Minha interação com o MixFy seria clara e compreensível

Marcar apenas uma oval.

Discordo plenamente

1

2

3

4

Concordo plenamente

16. Eu consideraria o MixFy flexível para interagir

Marcar apenas uma oval.

Discordo plenamente

1

2

3

4

Concordo plenamente

17. Seria fácil para mim me tornar habilidoso no uso do MixFy

Marcar *apenas uma oval.*

Discordo plenamente

1

2

3

4

Concordo plenamente

18. Eu consideraria o MixFy fácil de se usar

Marcar *apenas uma oval.*

Discordo plenamente

1

2

3

4

Concordo plenamente

Assumindo que você assistiu ao vídeo inicial e acessou ao protótipo do aplicativo, o quanto você concorda com as afirmativas abaixo, referente intenção de uso:



19. Vejo-me utilizando o MixFy

Marcar *apenas uma oval.*

Discordo plenamente

1

2

3

4

Concordo plenamente

20. Eu tenho a intenção de compartilhar minha localização

Marcar *apenas uma oval.*

Discordo plenamente

1

2

3

4

Concordo plenamente

21. Eu tenho a intenção de avaliar se as recomendações sugeridas

Marcar *apenas uma oval.*

Discordo plenamente

1

2

3

4

Concordo plenamente

22. Eu não deixo de utilizar o MixFy por ele ser fácil de usar

Marcar *apenas uma oval.*

Discordo plenamente

1

2

3

4

Concordo plenamente

23. Eu não deixaria de usar o MixFy por ter que compartilhar minha localização

Marcar *apenas uma oval.*

Discordo plenamente

1

2

3

4

Concordo plenamente

24. Eu não deixaria de usar o Mixfy por ter que realizar avaliações constantes

Marcar *apenas uma oval.*

Discordo plenamente

1

2

3

4

Concordo plenamente

# **ROTEIRO - Método de Inspeção Semiótica Intermediado (MISI)**

## **Procedimentos:**

### **1. PRÉ-INSPEÇÃO/PERFIL DO USUÁRIO OUVINTE DE MÚSICA**

#### **A. Preferências de Escuta Musical**

- Qual o seu nível de escolaridade?
- Com que frequência você ouve música?
- Qual dispositivo você prefere ouvir suas músicas?
- Em qual contexto você costuma ouvir música?
- Qual sua principal plataforma de escuta de música?
- Quais gêneros musicais você gosta de ouvir?

#### **B. Aplicativos de Recomendação de Música (Streaming)**

- Se possui aparelho(s) móvel(is) (smartphones ou tablets) e se costuma utilizá-los no dia-a-dia? Qual modelo (Android, iPhone ou outros)?
- Tem conhecimento sobre plataformas streaming/recomendação de música?
- Utiliza alguma plataforma de recomendação de música?
  - Se sim, como definiu a escolha?
- Cria lista de músicas baseada em algum contexto específico?
  - Se sim, como você faz isso?
- Teve contato com outras plataformas de recomendação de música?
  - Se sim, porque deixou de utilizar?

### **2. INSPEÇÃO DA PLATAFORMA USANDO O MISI**

#### **Passo 1 - Signos Metalinguísticos**

Antes de logar na ferramenta, acesse o menu “Sobre”, leia o conteúdo e em seguida descreva:

- A partir da sua leitura, qual é seu entendimento sobre:
  - A quem a ferramenta se destina?
  - O que você entende que seja o objetivo da ferramenta?
  - Como você imagina que utiliza a ferramenta?

- Que músicas você esperaria que fossem recomendadas para quem está utilizando?

## **Passo 2 - Signos Estáticos e Dinâmicos**

### **[Tarefa 1 - Logar e definir gênero musical preferido]**

- Logar (usuário "email@email.com")
- Você consegue identificar mais de 1 gênero musical?
- Acha fácil a interação? Precisa de muito controle de movimento para usar?

### **[Tarefa 2 - Ouvir a prévia de uma música]**

- Você consegue identificar o elemento de reprodução da música?
- Você consegue identificar o elemento de paralisar a reprodução da música?
- Você acha que um usuário sem o Spotify instalado poderia interagir com esse aplicativo?

### **[Tarefa 3 - Avaliar uma música]**

- Você consegue identificar o elemento para avaliar a música?
- Os emojis ajudam na avaliação de uma música?
- Você acha que o campo de comentário é interessante ser preenchido sempre que decidir avaliar uma música? Pode ter algum impacto?
- Você consegue identificar a opção de enviar avaliações? Na sua opinião, prefere enviar uma avaliação por vez ou um conjunto de avaliações?

### **[Tarefa 4 - Buscar recomendações para um determinado contexto e popularidade]**

- Você consegue identificar o menu de contexto?
- Você consegue selecionar um intervalo de popularidade de música adequada?
- Acha fácil a interação?
- Que efeito você acha que o intervalo de popularidade pode refletir nas recomendações que a plataforma oferece?

### **[Tarefa 5 - Avaliar 40 músicas para um contexto escolhido]**

- Durante o envio das avaliações, percebeu alguma mudança na lista de recomendações? Quais?
- Você consegue identificar músicas pertencentes ao seu gênero musical nas sugestões?
- Você consegue identificar músicas relacionadas aos seus artistas favorito?
- Você acha que o parâmetro de popularidade ajuda identificar músicas pertencentes ao seu estilo musical?

**[Tarefa 5 - Avaliar 10 músicas que você não gostaria de ouvir no contexto definido]**

- O que você achou das recomendações apresentadas nesta tarefa?
- Você acha que a mudança constante das músicas pode despertar mais o interesse do ouvinte em continuar avaliando as recomendações?
- Acha que o uso prolongado da plataforma pode apoiar na automatização de recomendações de música para um determinado contexto? Por quê ?

**Passo 3 - Retorno dos Passos de Consolidação**

- Agora que utilizou todos os recursos da plataforma, como descreveria seu objetivo?
  - A quem a ferramenta se destina?
  - O que você entende que seja o objetivo da ferramenta?
  - Como você imagina que utiliza a ferramenta?
  - Que músicas você esperaria que fossem recomendadas para quem esta utilizando?

**3. OUTROS COMENTÁRIOS**

Tem alguma outra coisa que vcs não abordamos que você gostaria de falar?

**4. AGRADECIMENTO**

---

## APÊNDICE C

Avaliação da Arquitetura UConteXt  
Arch a partir da Experiência do  
Usuário: Questionário de Perfil  
Demográfico e Questionário TAM

---

# Pesquisa de Interesse MixFy

Eu, Willian Garcias de Assunção, aluno de Doutorado do programa de pós-graduação em Ciência da Computação pela Universidade Federal de São Carlos (UFSCar), convido a participar da pesquisa intitulada "Recomendação musical considerando a emoção e o contexto do usuário".

Esta pesquisa tem como objetivo o desenvolvimento e validação de uma abordagem de recomendação musical que considera o contexto e a experiência do usuário e relacionada a outros aspectos (por exemplo, satisfação, atividade do usuário, feedback e outros) além da precisão dos algoritmos. Para avaliar a abordagem proposta foi construído uma ferramenta (aplicativo) chamado MixFy que foi integrado à plataforma comercial Spotify que oferece acesso a uma biblioteca ampla de músicas. Dentro desta pesquisa, será feita uma avaliação para verificar se abordagem de recomendação proposta atende e implementa os aspectos desejáveis de maneira que **o contexto seja definido pelo usuário**. Para isso estão sendo propostas tarefas que envolvem busca de músicas, audição das prévias e avaliações das recomendações oferecidas pelo MixFy. Após a conclusão de cada tarefa serão feitos questionamentos a respeito do comportamento da ferramenta e percepção do uso da ferramenta por parte dos participantes. Os pesquisadores estarão disponíveis durante a atividade para sanar quaisquer dúvidas que possam surgir. O público-alvo de respondentes da pesquisa são ouvintes de músicas que possuem o hábito de ouvir música em seu dia a dia.

Diante disso, solicitamos o seu consentimento para participação no estudo, em especial quanto a coleta de dados. Para decidir sobre o seu consentimento, é importante que você conheça as seguintes informações sobre a pesquisa:

- Os dados coletados durante o estudo destinam-se estritamente as atividades de cunho acadêmico;
- Os pesquisadores se comprometem em divulgar os resultados da pesquisa para toda a instituição, após a conclusão do trabalho. A divulgação desses resultados pauta-se no respeito à sua privacidade, e o anonimato dos participantes será preservado em quaisquer documentos que elaborarmos;
- O estudo vai acontecer na modalidade on-line através da plataforma Google Meet, e será gravada em áudio e vídeo para que o pesquisador possa ter acesso integral e fiel a fonte dos dados coletados.
- Todas as gravações serão baixadas para que a análise de vídeo possa ser feita localmente usando a plataforma Atlas.ti. Após baixar as gravações, todo e qualquer registro será excluído de qualquer plataforma virtual, ambiente compartilhado, ou "nuvem".
- Os pesquisadores se responsabilizam pela guarda e confidencialidade de todos os dados coletados no estudo, eles serão os únicos a terem acesso aos dados e tomarão todas as providências necessárias para manter o sigilo das informações.
- Depois que a análise dos vídeos for realizada utilizando a plataforma Atlas.ti, as gravações locais também serão apagadas.



- A transmissão e reprodução de produtos audiovisuais e/ou resultantes são de uso exclusivo para o desenvolvimento da pesquisa, ou seja, esses materiais não serão distribuídos para terceiros, em nenhuma hipótese, e serão usados apenas com intuito acadêmico;
- O participante terá acesso aos resultados da pesquisa sempre que desejar e solicitar devendo entrar em contato com o pesquisador responsável;
- O cansaço e estresse do participante, que pode ser um possível dano causado pela sua participação nesta pesquisa, é mitigado através da apresentação de um questionário de perfil curto onde o participante gastará em média 5 minutos para o preenchimento;
- O cansaço e estresse do participante, que pode ser um possível dano causado pela sua participação nesta pesquisa, é mitigado através de sessões de avaliação da ferramenta que terão duração máxima de 1 hora;
- O consentimento para qualquer atividade que envolva coleta de dados é uma escolha livre, feita mediante a prestação de todos os esclarecimentos necessários sobre a pesquisa;
- O participante tem plena liberdade para decidir sobre sua participação sem prejuízo ou represália alguma, de qualquer natureza;
- O participante tem plena liberdade de retirar seu consentimento, em qualquer fase da pesquisa, sem prejuízo ou represália alguma, de qualquer natureza. Nesse caso, os dados colhidos de sua participação até o momento da retirada do consentimento serão descartados a menos que o participante autorize explicitamente o contrário;
- O participante pode solicitar assistência antes, durante ou depois de finalizar sua participação entrando em contato por e-mail com o pesquisador responsável ou solicitando o auxílio ao um dos pesquisadores durante a aplicação do estudo;
- A participação nesta pesquisa é voluntária e sem qualquer compensação financeira;
- Todas as despesas com o transporte e a alimentação decorrentes da sua participação na pesquisa, quando for o caso, serão ressarcidas no dia da coleta. Você terá direito a indenização por qualquer tipo de dano resultante da sua participação na pesquisa;
- Este termo ficará armazenado em formato digital sob a guarda do pesquisador responsável, sendo que o participante poderá solicitar uma cópia digital do documento a qualquer momento caso deseje.

Qualquer dúvida sobre o estudo é possível contatar o pesquisador pelo e-mail [willian.assuncao@ufscar.br](mailto:willian.assuncao@ufscar.br)

Esta coleta de dados foi autorizada pelo Comitê de Ética em Pesquisa (CEP) da Universidade Federal de São Carlos (UFSCar), vinculado à Comissão Nacional de Ética em Pesquisa (CONEP), do Conselho Nacional de Saúde (CNS) do Ministério da Saúde (MS). O CEP tem por finalidade cumprir e fazer cumprir o disposto nas Resoluções CNS nº 510/16, nº 370/07, nº 240/97, nº 563/17, nº 580/18 e nas Normas Operacionais nº

006/09 e nº 001/13, além das demais resoluções do Conselho Nacional de Saúde, no que diz respeito aos aspectos éticos das pesquisas envolvendo seres humanos, sob a ética do indivíduo e das coletividades, de modo a prezar pela segurança aos direitos dos participantes da pesquisa e os direitos e deveres da comunidade científica e do Estado. Os dados do CEP da UFSCar para contato são: Rd. Washington Luiz KM 235, CEP 13565-905, São Carlos - SP, Fone: (16) 33519685, e-mail: [cephumanos@ufscar.br](mailto:cephumanos@ufscar.br).

Após a leitura do presente termo, caso haja aceite, selecione a opção "Concordo em participar", localizada abaixo da apresentação do TCLE on-line, acusando que leu e está de acordo com o Termo apresentado.

\* Indica uma pergunta obrigatória

---

1. Tendo em vista o Termo de Consentimento Livre e Esclarecido acima, você aceita participar desta pesquisa? \*

*Marcar apenas uma oval.*

- Concordo em participar  
 Não concordo em participar

2. Nome completo

\_\_\_\_\_

3. E-mail \*

\_\_\_\_\_

#### Perfil Demográfico

4. Gênero \*

*Marcar apenas uma oval.*

- Feminino  
 Masculino  
 Prefiro não dizer

5. Idade \*

*Marcar apenas uma oval.*

- 18 anos a 24 anos
- 25 anos a 34 anos
- 35 anos a 44 anos
- 45 anos a 54 anos
- Mais de 54 anos

6. Escolaridade \*

*Marcar apenas uma oval.*

- Nenhuma escolaridade
- Ensino fundamental: 1a a 4a série
- Ensino fundamental: 5a a 8a série
- Ensino médio
- Ensino superior
- Pós-graduação

Assumindo que você utilizou o aplicativo MixFy, o quanto você concorda com as afirmativas abaixo, referente utilidade percebida:

7. O MixFy me ajuda a encontrar músicas relacionadas ao meu gosto musical (artistas e gênero musical favorito)? \*

*Marcar apenas uma oval.*

1   2   3   4

---

Disc     Concordo plenamente

---

8. O MixFy é eficaz ao oferecer recomendações musicais, mesmo quando tenho pouca interação prévia? \*

*Marcar apenas uma oval.*

1 2 3 4

Disc     Concordo plenamente

9. O MixFy me ajuda a escolher música adequada para minha atividade atual? \*

*Marcar apenas uma oval.*

1 2 3 4

Disc     Concordo plenamente

10. O MixFy ajuda a reduzir o esforço necessário para encontrar novas músicas? \*

*Marcar apenas uma oval.*

1 2 3 4

Disc     Concordo plenamente

11. O MixFy permite que eu avalie regularmente e atualiza constantemente as recomendações oferecidas? \*

*Marcar apenas uma oval.*

1 2 3 4

Disc     Concordo plenamente

12. O aprendizado constante do MixFy melhora a relevância das sugestões de música? \*

*Marcar apenas uma oval.*

1 2 3 4

Disc     Concordo plenamente

Assumindo que você utilizou o aplicativo MixFy, o quanto você concorda com as afirmativas abaixo, referente a facilidade de uso percebida:

13. O MixFy é fácil de usar, permitindo-me ser mais ativo na descoberta de novas músicas? \*

*Marcar apenas uma oval.*

1 2 3 4

Disc     Concordo plenamente

14. O MixFy é fácil de usar quando estou escolhendo música para uma atividade específica? \*

*Marcar apenas uma oval.*

1 2 3 4

Disc     Concordo plenamente

15. O sistema de avaliações e feedback do MixFy é intuitivo e fácil de usar? \*

*Marcar apenas uma oval.*

1 2 3 4

Disc     Concordo plenamente

16. Encontrar música nova através do MixFy é fácil, mesmo com pouca interação prévia? \*

*Marcar apenas uma oval.*

1 2 3 4

Disc     Concordo plenamente

17. O MixFy facilita a descoberta de música nova sem exigir muito esforço? \*

*Marcar apenas uma oval.*

1 2 3 4

Disc     Concordo plenamente

18. É fácil para mim entender como o MixFy aprende e adapta suas recomendações com base em minhas preferências musicais? \*

*Marcar apenas uma oval.*

1 2 3 4

Disc     Concordo plenamente

Assumindo que você utilizou o aplicativo MixFy, o quanto você concorda com as afirmativas abaixo, referente intenção de uso:

19. Pretendo continuar usando o MixFy por causa da satisfação que suas recomendações me proporcionam? \*

*Marcar apenas uma oval.*

1 2 3 4

Disc     Concordo plenamente

20. Pretendo realizar avaliações constantes para o MixFy para melhorar suas recomendações? \*

*Marcar apenas uma oval.*

1 2 3 4

Disc     Concordo plenamente

21. Estou disposto a fornecer minha localização para reduzir o esforço em receber recomendações músicas. \*

*Marcar apenas uma oval.*

1 2 3 4

Disc     Concordo plenamente

22. Estou disposto a informar minha atividade atual para reduzir o esforço em receber recomendações músicas. \*

*Marcar apenas uma oval.*

1 2 3 4

Disc     Concordo plenamente

23. Tenho a intenção de continuar usando o MixFy mesmo quando não estiver familiarizado com as recomendações? \*

*Marcar apenas uma oval.*

1 2 3 4

Disc     Concordo plenamente

24. Tenho a intenção de continuar usando o MixFy à medida que ele aprende e se <sup>\*</sup> adapta às minhas preferências musicais?

*Marcar apenas uma oval.*

1 2 3 4

Disc     Concordo plenamente

---

Este conteúdo não foi criado nem aprovado pelo Google.

Google Formulários



# Anexos

---

## **ANEXO A**

**Parecer de Aprovação 1 (Comitê de Ética): Estudo sobre a Avaliação da Experiência do Usuário em Plataformas Comerciais de Música.**

---



## PARECER CONSUBSTANCIADO DO CEP

### DADOS DO PROJETO DE PESQUISA

**Título da Pesquisa:** Recomendação de música considerando a emoção e o contexto do usuário.

**Pesquisador:** WILLIAN GARCIAS DE ASSUNCAO

**Área Temática:**

**Versão:** 2

**CAAE:** 66650523.4.0000.5504

**Instituição Proponente:** Departamento de Computação

**Patrocinador Principal:** Financiamento Próprio

### DADOS DO PARECER

**Número do Parecer:** 6.049.031

#### Apresentação do Projeto:

As informações elencadas nos campos "Apresentação do Projeto", "Objetivo da Pesquisa" e Avaliação dos Riscos e Benefícios" foram extraídas do arquivo Informações Básicas da Pesquisa ( PB\_INFORMAÇÕES\_BÁSICAS\_DO\_PROJETO\_2070727.pdf, de 29/03/2023) e/ou do Projeto- pdf de 29/03/2023): RESUMO, HIPÓTESE (se houver), METODOLOGIA, CRITÉRIOS DE INCLUSÃO E EXCLUSÃO.

Introdução:

A música muitas vezes desempenha um papel importante na vida cotidiana das pessoas. As pessoas escutam música em diferentes situações e ambientes (por exemplo, na estrada, trabalhando, limpando a hora, ou mesmo durante o banho). Além disso, diferentes tipos de música podem combinar com vários sentimentos humanos particulares [16]. Os elementos do som na música incluem o tom, o ritmo e as qualidades sônicas do timbre e da textura, etc. Os artistas criam as músicas para expressar emoções, sentimentos e pensamentos [23]. De acordo com um relatório recente, a prevalência da maioria das atividades de lazer, como assistir televisão ou cinema ou ler livros, foi superada pela música ouvida [26]. Ao longo dos últimos 20 anos, novas tecnologias digitalizaram nossa experiência de escuta musical. No mundo de hoje, temos acesso a grandes quantidades de música em todos os lugares e o tempo todo. No momento, há cada vez mais músicas em computadores pessoais, em bibliotecas de música e na Internet [16]. Um exemplo para tais novos serviços são as plataformas de transmissão de música (e.g, Spotify,

**Endereço:** WASHINGTON LUIZ KM 235

**Bairro:** JARDIM GUANABARA

**CEP:** 13.565-905

**UF:** SP

**Município:** SAO CARLOS

**Telefone:** (16)3351-9685

**E-mail:** cephumanos@ufscar.br



SoundCloud, Last.fm, Apple Music) que permitem aos consumidores escolher livremente as faixas que escutam e criar suas próprias listas de reprodução. Uma desvantagem desta liberdade de escolha é que é difícil para os clientes identificar novas faixas que eles gostam e querem ouvir nesta grande quantidade de artistas e faixas. Além do mais ter acesso a grandes quantidades de música digital leva a demanda de técnicas automatizadas para a seleção e recomendação de música [22]. Uma das formas de otimizar o processo de seleção e recomendação de música é aproveitar o poder emocional da música. A emoção é essência da música e as músicas têm a possibilidade de expressar diversas emoções [33]. No estudo realizado por Zentner et al.[35], os autores mostraram que a música é um meio eficaz de indução emocional e que pode mudar o comportamento emocional do usuário. Além disso, os pesquisadores também mostraram que, na vida cotidiana, a música é predominantemente usada para regular o estado emocional. Levando em conta as emoções durante a recomendação musical pode ajudar a melhorar as sugestões musicais e a experiência do usuário de ouvir música [33]. Entretanto, para alcançar este objetivo ainda é necessário um grande esforço, pois a escolha da música na vida cotidiana é influenciada significativamente pelas circunstâncias contextuais que envolvem os ouvintes de música. Os métodos atuais de recomendação e reprodução de música dependendo da emoção e contexto do usuário requerem uma interação manual, ou seja, o usuário procura manualmente uma música de acordo com sua emoção e contexto ou recebe sugestões um conjunto de músicas já préclassificadas, mas que não pertencem a seu estilo musical preferido. Os usuários criam listas de reprodução de música para vários contextos e atividades nos quais estão interessados e o fazem manualmente. Eles atualizam e carregam a nova lista de reprodução cada vez que sua atividade ou contexto muda. Assim, a tarefa de ouvir música torna-se menos eficiente porque pode levar muito tempo e esforço na busca de música apropriada ao contexto e à atividade atual [24].

#### Metodologia Proposta:

##### Tipo de Estudo

Este trabalho se caracteriza como um estudo experimental e investigativo sobre a avaliação do uso de uma ferramenta de recomendação de música que considera o contexto e a experiência do usuário. O público alvo deste trabalho será pessoas que possuem o hábito de ouvir músicas enquanto realizam diversas atividades em seu dia a dia.

##### Local da Pesquisa

Por medidas de segurança adotadas na contenção da pandemia, a pesquisa ocorrerá no formato on-line. As avaliações serão agendadas respeitando a disponibilidade dos participantes e dos

**Endereço:** WASHINGTON LUIZ KM 235

**Bairro:** JARDIM GUANABARA

**CEP:** 13.565-905

**UF:** SP

**Município:** SAO CARLOS

**Telefone:** (16)3351-9685

**E-mail:** cephumanos@ufscar.br



Continuação do Parecer: 6.049.031

pesquisadores. Dessa forma, acredita-se que o uso da tecnologia auxiliará a pesquisa na medida em que visa trazer flexibilidade e diálogo com os participantes, assim como respeito pelas questões éticas e de sigilo. O aplicativo Google Meet será utilizado na primeira avaliação. Será enviado um link para o participante que dará acesso a sala virtual que ocorrerá a avaliação.

#### Aspectos éticos da pesquisa

Atendendo ao rigor ético e científico o projeto de pesquisa será encaminhado ao Comitê de Ética em Pesquisa em Seres Humanos da Universidade Federal de São Carlos e após sua anuência será iniciada a coleta de dados, de acordo com as recomendações da Resolução 510/2016 do Conselho Nacional de Saúde do Ministério de Saúde [5].

#### Participantes

O convite será direcionado a pessoas que fazem parte da rede de contatos dos pesquisadores deste projeto e que têm o hábito de ouvir músicas em sua vida diária. A divulgação ocorrerá nas redes sociais assim como listas de e-mail. Os convites enviados via e-mail utilizaram listas que não permitem a identificação dos convidados nem a visualização dos seus dados de contato (e-mail, telefone, etc.) por terceiros. A mensagem de convite conterá: um breve resumo da pesquisa; os objetivos; um link para um questionário de perfil; e um link da sala virtual (Google Meet) onde a avaliação da ferramenta ocorrerá individualmente. O convite também incluirá o Termo de Consentimento Livre e Esclarecido (Apêndice A) para que antes de responder as perguntas fornecidas pelo pesquisador, o candidato possa decidir se concorda ou não em participar. Se o candidato concordar em participar, será considerado como concordância quando responder ao questionário de perfil e marcar que concorda com o Termo de Consentimento Livre e Esclarecido. Entretanto, os participantes serão informados no convite que poderão a qualquer momento e sem qualquer prejuízo retirar seu consentimento para o uso dos dados. Nessas situações, o participante receberá a resposta de ciência do interesse do participante de pesquisa retirar seu consentimento. Será sinalizado no TCLE um trecho de texto para que o participante identifique em qual avaliação ele participará. A previsão é que ocorra uma avaliação em dois momentos distintos pelo uso da mesma ferramenta. O recrutamento ocorrerá durante um mês e pretende-se atingir aproximadamente 38 participações, sendo 8 participantes para a primeira avaliação e 30 para segunda avaliação. Os critérios de inclusão dos sujeitos na pesquisa são: maiores de 18 anos; brasileiros; e alfabetizados. Como se trata de atividade que exige a visualização de imagens e textos, adotou-se como critérios de exclusão a não participação de pessoas cegas ou com baixa visão. Os dados dos participantes que por livre espontânea vontade não concluírem os experimentos não serão considerados na análise.

**Endereço:** WASHINGTON LUIZ KM 235

**Bairro:** JARDIM GUANABARA

**CEP:** 13.565-905

**UF:** SP

**Município:** SAO CARLOS

**Telefone:** (16)3351-9685

**E-mail:** cephumanos@ufscar.br



Continuação do Parecer: 6.049.031

**Instrumentos de Coleta de Dados** A coleta de dados da primeira avaliação dar-se-á por meio dos seguintes instrumentos: gravação das ações dos usuário na ferramenta que estará sendo avaliada, gravação das falas dos participantes durante o uso, anotações do pesquisador e questionário de perfil demográfico e feedback (Apêndice B). Os dados coletados por meio de formulários e gravações utilizando o Google Meet não permanecerão disponíveis nas plataformas on-line. Todos dados coletados serão baixados para um dispositivo eletrônico local para análise posterior.

### **Objetivo da Pesquisa:**

**Objetivo Primário:**

Este projeto tem como objetivo primário a definição, desenvolvimento e avaliação de uma abordagem de recomendação musical que considera as preferências e o contexto do usuário, de maneira que a experiência do usuário seja avaliada diante de outros aspectos além da precisão dos algoritmos. O foco a princípio é oferecer ao usuário recomendações de música que melhor se adaptem as suas preferências de escuta atendendo a um conjunto de aspectos desejados e o contexto atual. Visto que atualmente para o usuário alcançar esse objetivo é necessário que ele faça uma busca manualmente de músicas, pois os métodos convencionais de recomendação de música ainda não consideram o contexto do usuário relacionando a estes aspectos.

**Objetivo Secundário:**

O objetivo geral do projeto se desdobrará em objetivos específicos que visam: (i) investigar métodos que recomendam músicas baseadas no contexto e emoção, bem como quais características de contexto são utilizadas; (ii) investigar a interação do usuário com dois sistemas comerciais de recomendação de música; (iii) propor uma abordagem de recomendação de música que considera o contexto e as preferências do usuário; e (iv) avaliar a abordagem de recomendação proposta.

### **Avaliação dos Riscos e Benefícios:**

**Riscos:**

Existem os seguintes riscos para os participantes do trabalho: estresse, tristeza, cansaço e tédio, seja pelos conteúdos, tempo de realização das tarefas e/ou resposta de questionários. O sujeito de pesquisa pode, ainda, se frustrar pela recomendação de músicas sugeridas por algum dos métodos, como também se sentir desconfortável por estar sendo avaliado. Além disso, ele pode se sentir desconfortável com a webcam gravando sua interação com a aplicação. Será feito o possível

**Endereço:** WASHINGTON LUIZ KM 235

**Bairro:** JARDIM GUANABARA

**CEP:** 13.565-905

**UF:** SP

**Município:** SAO CARLOS

**Telefone:** (16)3351-9685

**E-mail:** cephumanos@ufscar.br



Continuação do Parecer: 6.049.031

para minimizar os impactos listados previamente. O participante poderá estar em um estado emocional de baixa excitação com

a intenção de ouvir músicas e que animam, no entanto, caso ocorra a recomendação de músicas desagradáveis aos participantes, estas serão excluídas do experimento. Ainda assim, caso ocorram, o participante pode se recusar a responder aos questionários, como também para a escuta das músicas ou até mesmo interromper a sua participação a qualquer momento.

**Benefícios:**

Os benefícios relacionados à participação dos sujeitos de pesquisa estão em contribuir com o trabalho, assim como para o avanço do estado da arte na investigação das abordagens de recomendação musical que consideram a emoção e o contexto.

**Comentários e Considerações sobre a Pesquisa:**

Vide campo "Conclusões ou Pendências e Lista de Inadequações"

**Considerações sobre os Termos de apresentação obrigatória:**

Vide campo "Conclusões ou Pendências e Lista de Inadequações"

**Recomendações:**

Vide campo "Conclusões ou Pendências e Lista de Inadequações"

**Conclusões ou Pendências e Lista de Inadequações:**

Agradecemos as providências e os cuidados tomados pelos pesquisadores ao apresentarem a 2ª versão do protocolo de pesquisa ao CEP da UFSCar. Trata-se de análise de resposta ao parecer pendente n. 5.923.633 emitido pelo CEP em 03/03/2023.

Seguem abaixo as pendências listadas no parecer anterior do CEP e seu status (atendida, não atendida, parcialmente atendida).

Pendência 1- Apresentar orçamento previsto.

Resposta - No projeto foi criada a Seção 10 referente ao orçamento, bem como uma tabela que demonstra o custo de cada item. Assim, foi adicionado o seguinte texto:

“Esta seção contém uma estimativa dos custos envolvidos no projeto e uma descrição detalhada dos recursos necessários para atingir os objetivos estabelecidos. A elaboração de um orçamento preciso e detalhado é fundamental para garantir que o projeto seja executado de forma eficiente e eficaz, além de permitir uma gestão adequada dos recursos disponíveis. A Tabela 3 apresenta os custos envolvidos para a realização desta pesquisa, que inclui gastos com materiais de escritório,

**Endereço:** WASHINGTON LUIZ KM 235

**Bairro:** JARDIM GUANABARA

**CEP:** 13.565-905

**UF:** SP

**Município:** SAO CARLOS

**Telefone:** (16)3351-9685

**E-mail:** cephumanos@ufscar.br



Continuação do Parecer: 6.049.031

como folhas de papel para impressão dos questionários, canetas, assim como o custo relacionado ao transporte do pesquisador para o

local onde serão realizados os estudos. É essencial prever os gastos materiais de escritório e transporte para que seja possível executar a pesquisa de forma eficiente e sem interrupções.

Avaliação: Pendência atendida.

#### Considerações Finais a critério do CEP:

Diante do exposto, o Comitê de ética em pesquisa - CEP, de acordo com as atribuições definidas na Resolução CNS nº 510 de 2016, manifesta-se por considerar "Aprovado" o projeto. Conforme dispõe o Capítulo VI, Artigo 28, da Resolução Nº 510 de 07 de abril de 2016, a responsabilidade do pesquisador é indelegável e indeclinável e compreende os aspectos éticos e legais, cabendo-lhe, após aprovação deste Comitê de Ética em Pesquisa: II - conduzir o processo de Consentimento e de Assentimento Livre e Esclarecido; III - apresentar dados solicitados pelo CEP ou pela CONEP a qualquer momento; IV - manter os dados da pesquisa em arquivo, físico ou digital, sob sua guarda e responsabilidade, por um período mínimo de 5 (cinco) anos após o término da pesquisa; V - apresentar no relatório final que o projeto foi desenvolvido conforme delineado, justificando, quando ocorridas, a sua mudança ou interrupção. Este relatório final deverá ser protocolado via notificação na Plataforma Brasil. OBSERVAÇÃO: Nos documentos encaminhados por Notificação NÃO DEVE constar alteração no conteúdo do projeto. Caso o projeto tenha sofrido alterações, o pesquisador deverá submeter uma "EMENDA".

#### Este parecer foi elaborado baseado nos documentos abaixo relacionados:

Tipo Documento	Arquivo	Postagem	Autor	Situação
Informações Básicas do Projeto	PB_INFORMAÇÕES_BÁSICAS_DO_PROJETO_2070727.pdf	29/03/2023 14:23:42		Aceito
Outros	Carta_Resposta_versao1.pdf	29/03/2023 14:23:01	WILLIAN GARCIAS DE ASSUNCAO	Aceito
Projeto Detalhado / Brochura Investigador	ProjetoPesquisa.pdf	29/03/2023 14:21:50	WILLIAN GARCIAS DE ASSUNCAO	Aceito
TCLE / Termos de Assentimento / Justificativa de Ausência	apendice_A.pdf	03/01/2023 12:04:18	WILLIAN GARCIAS DE ASSUNCAO	Aceito
Folha de Rosto	folha_de_rosto.pdf	03/01/2023	WILLIAN GARCIAS	Aceito

**Endereço:** WASHINGTON LUIZ KM 235

**Bairro:** JARDIM GUANABARA

**CEP:** 13.565-905


**UF:** SP

**Município:** SAO CARLOS

**Telefone:** (16)3351-9685

**E-mail:** cephumanos@ufscar.br





Continuação do Parecer: 6.049.031

Folha de Rosto	folha_de_rosto.pdf	12:01:11	DE ASSUNCAO	Aceito
----------------	--------------------	----------	-------------	--------

**Situação do Parecer:**

Aprovado

**Necessita Apreciação da CONEP:**

Não

SAO CARLOS, 09 de Maio de 2023

---

**Assinado por:**  
**Sonia Regina Zerbetto**  
**(Coordenador(a))**

**Endereço:** WASHINGTON LUIZ KM 235

**Bairro:** JARDIM GUANABARA

**CEP:** 13.565-905

**UF:** SP

**Município:** SAO CARLOS

**Telefone:** (16)3351-9685

**E-mail:** cephumanos@ufscar.br

---

## **ANEXO B**

**Parecer de Aprovação 2 (Comitê de Ética): Estudo sobre Avaliação da Experiência de Usuários no MixFy: Abordagem Semiótica Intermediada e Uso o Prolongado diante do Contexto Atual.**

---



## PARECER CONSUBSTANCIADO DO CEP

### DADOS DO PROJETO DE PESQUISA

**Título da Pesquisa:** Recomendação de música considerando a emoção e o contexto do usuário

**Pesquisador:** WILLIAN GARCIAS DE ASSUNCAO

**Área Temática:**

**Versão:** 2

**CAAE:** 46828621.4.0000.5504

**Instituição Proponente:** Departamento de Computação

**Patrocinador Principal:** Financiamento Próprio

### DADOS DO PARECER

**Número do Parecer:** 4.901.583

#### **Apresentação do Projeto:**

Informações retiradas do documento PB\_INFORMAÇÕES\_BÁSICAS\_DO\_PROJETO\_1749189.pdf de 09/05/2021:

Ao longo dos últimos 20 anos, novas tecnologias digitalizaram nossa experiência de escuta musical. No mundo de hoje, temos acesso a grandes quantidades de música em todos os lugares e o tempo todo. No momento, há cada vez mais músicas em computadores pessoais, em bibliotecas de música e na Internet. Ter acesso a grandes quantidades de música digital leva a demanda de técnicas automatizadas para a seleção de música. Na indústria da música, as demandas de recuperação e recomendação de música atraem muitos pesquisadores para explorar as características acústicas para a classificação de gêneros musicais. Uma das formas de otimizar o processo de seleção e recomendação de música é aproveitar o poder emocional da música e do usuário. Os sistemas tradicionais de recomendação normalmente sugerem músicas aos seus ouvintes a partir do histórico de audição. Contudo, pouco foi explorado até o momento sobre como outros aspectos podem melhorar a recomendação de música relacionando com as emoções e contexto. Nesse sentido, este projeto tem como objetivo o desenvolvimento e validação de um Framework de recomendação musical que considera a emoção e o contexto do usuário ao sugerir músicas. O foco a princípio é ajudar o usuário alcançar um estado emocional desejado partindo do seu estado emocional atual. Visto que os métodos convencionais de recomendação de música

**Endereço:** WASHINGTON LUIZ KM 235

**Bairro:** JARDIM GUANABARA

**CEP:** 13.565-905

**UF:** SP

**Município:** SAO CARLOS

**Telefone:** (16)3351-9685

**E-mail:** cephumanos@ufscar.br



Continuação do Parecer: 4.901.583

requerem a interação humana na escolha das músicas.

#### Hipótese:

Tendo observado na literatura toda a influência que a música traz para as pessoas e a relação entre as plataformas de música com seus ouvintes, a hipótese levantada por este projeto é: Ao sugerir músicas considerando os aspectos desejáveis descobertos pela revisão da literatura, os sistemas de recomendação musical podem melhorar a experiência musical do usuário.

#### Metodologia Proposta:

##### Tipo de Estudo

Este trabalho se caracteriza como estudo experimental e investigativo sobre as necessidades e dificuldades enfrentadas pelos ouvintes de música em receber recomendações que consideram a emoção e o contexto. O público alvo deste trabalho será pessoas que possuem o hábito de ouvir músicas enquanto realizam diversas atividades em seu dia a dia.

#### Local da Pesquisa

Por medidas de segurança adotadas na contenção da pandemia, a pesquisa ocorrerá no formato on-line. As avaliações serão agendadas respeitando a disponibilidade dos participantes e dos pesquisadores. Dessa forma, acredita-se que o uso da tecnologia auxiliará a pesquisa na medida em que visa trazer flexibilidade e diálogo com os participantes, assim como respeito pelas questões éticas e de sigilo. O aplicativo utilizado para as avaliações das ferramentas será o Google Meet ou Skype. Será enviado um link para o participante que dará acesso a sala virtual que ocorrerá a avaliação.

#### Aspectos éticos da pesquisa

Atendendo ao rigor ético e científico o projeto de pesquisa será encaminhado ao Comitê de Ética em Pesquisa em Seres Humanos da Universidade Federal de São Carlos e após sua anuência será iniciada a coleta de dados, de acordo com as recomendações da Resolução 466/12 do Conselho Nacional de Saúde do Ministério de Saúde [5].

#### Participantes

Os participantes serão convidados através de redes sociais e e-mail. O convite será enviado a contatos pré-estabelecidos pelos pesquisadores deste projeto. O convite será direcionado a

**Endereço:** WASHINGTON LUIZ KM 235

**Bairro:** JARDIM GUANABARA

**CEP:** 13.565-905

**UF:** SP

**Município:** SAO CARLOS

**Telefone:** (16)3351-9685

**E-mail:** cephumanos@ufscar.br



Continuação do Parecer: 4.901.583

peçoas que possuem o hábito de ouvir músicas em seu dia a dia enquanto realizam algum tipo de atividade. A mensagem de convite conterá: um breve resumo da pesquisa; objetivos; uma cópia do TCLE (Apêndice A); e um link para um questionário de perfil; e o link para a sala virtual (Google Meet ou Skype) onde a avaliação da ferramenta ocorrerá individualmente. Nas avaliações das ferramentas será sinalizado no TCLE um trecho de texto para que a identificação da ferramenta seja preenchido de acordo com a ferramenta que será avaliada. A previsão é que ocorra a avaliação de duas ferramentas no mínimo. O recrutamento ocorrerá durante um mês e pretende-se atingir aproximadamente 20 participações, sendo 10 participantes para cada avaliação de ferramenta. Os critérios de inclusão dos sujeitos na pesquisa são: maiores de 18 anos; brasileiros; e alfabetizados. Como se trata de atividade que exige a visualização de imagens e textos, adotou-se como critérios de exclusão a não participação de pessoas cegas ou com baixa visão. Os dados dos participantes que por livre espontânea vontade não concluírem os experimentos não serão considerados na análise.

#### Instrumentos de Coleta de Dados

A coleta de dados das avaliações das ferramentas dar-se-á por meio dos seguintes instrumentos: gravação das ações dos usuário na ferramenta que estará sendo avaliada, gravação das falas dos participantes durante o uso e anotações do pesquisador. Durante as avaliações das ferramentas será também utilizado o protocolo Think Aloud [28] que consiste em o usuário expor seus pensamentos em voz alta a medida em que explora as ferramentas. Através da fala do usuário e seu comportamento ao explorar as ferramentas e seu ambiente pode-se perceber as dificuldades, dúvidas ou intenções do usuário. A avaliação das ferramentas serão conduzidas utilizando as ferramentas Google Meet ou Skype. O perfil dos participantes serão coletados meio de um questionário desenvolvido no Google Forms (Apêndice B). No questionário desenvolvido (Apêndice B) está disponível: um breve resumo da pesquisa; os dados do pesquisador; o TCLE e sua coleta de concordância; coleta dos dados de perfil dos participantes; e características e detalhes sobre os sistemas de recomendação musical.

Ao fim de cada tarefa executada nas ferramentas os participante terão que responder o instrumento de auto relato SAM (Self-Assessment Manikin) [4] (Apêndice C)...

(maiores informações, vide Projeto de Pesquisa original em anexo).

#### Metodologia de Análise de Dados:

**Endereço:** WASHINGTON LUIZ KM 235

**Bairro:** JARDIM GUANABARA

**CEP:** 13.565-905

**UF:** SP

**Município:** SAO CARLOS

**Telefone:** (16)3351-9685

**E-mail:** cephumanos@ufscar.br



Continuação do Parecer: 4.901.583

A análise dos dados das avaliações das ferramentas serão analisados através da análise qualitativa de vídeo e voz. O vídeo conterà a gravação da interação do participante que será complementado por suas falas capturadas através do uso do Think Aloud. Na análise de vídeo será buscado por problemas no uso da ferramenta como por exemplo dúvidas, barreiras que impediam a realização de alguma tarefa ou parte dela ou tempo excessivo para conclusão de uma tarefa. Na análise dos vídeos os códigos serão atribuídos a partes vídeo e das falas que trazem informações sobre a interação do participante com a ferramenta, que consiste na criação de códigos que descrevam os problemas encontrados. Para isso será utilizado o Método de Avaliação da Comunicabilidade (MAC) [9] que origina-se dos conceitos da Engenharia Semiótica, área da Interação Homem-Computador (IHC). O MAC é uma metodologia que auxilia os pesquisadores a encontrar falhas de comunicação que podem ocorrer durante a interação usuário-sistema. O breakdown ocorre quando ocorre uma falha na comunicação e pode ser percebida pelo usuário durante a interação, gerando dúvidas sobre a ação que ele deve realizar, ou a localização de um recurso, levando o usuário a cometer erros. Essas falhas podem dificultar ou mesmo inviabilizar que o usuário atinja seus objetivos no sistema [8,9]. Além disto, será feito também uma análise das respostas do instrumento de autoavaliação SAM para avaliar os domínios que são diretamente correspondentes aos domínios da estrutura do espaço emocional semântico definidos por [30]. Esse tipo de escala de avaliação é composta por três conjuntos de pictogramas que representam os domínios de Valência (satisfeito - insatisfeito), Excitação (motivado - relaxado) e Sentimento de controle (completamente no controle - fora de controle) [25]. Cada domínio é representado por uma escala de valores que varia de 1-9. O usuário é instruído a escolher um dos cinco pictogramas ou intermediário entre os dois - o que melhor representa o seu estado emocional, no que diz respeito ao domínio que está sendo avaliado.

Por fim, o resultado será comparado com a análise qualitativa dos vídeos e áudios. Para o perfil dos participantes serão construídos gráficos e tabelas que informem seus dados.

Desfecho Primário:

Dentre os resultados esperados, pretende-se verificar se:

1. As plataformas avaliadas implementam e lidam com os aspectos desejáveis ao considerar as emoções e o contexto.
2. Detalhes sobre práticas e dificuldades que os participantes possuem durante a interação com as ferramentas avaliadas.

**Endereço:** WASHINGTON LUIZ KM 235

**Bairro:** JARDIM GUANABARA

**CEP:** 13.565-905

**UF:** SP

**Município:** SAO CARLOS

**Telefone:** (16)3351-9685

**E-mail:** cephumanos@ufscar.br



Continuação do Parecer: 4.901.583

**Objetivo da Pesquisa:**

Informações retiradas do documento PB\_INFORMAÇÕES\_BÁSICAS\_DO\_PROJETO\_1749189.pdf de 09/05/2021:

**Objetivo Primário:**

Este projeto tem como objetivo primário a definição, desenvolvimento e validação de um Framework de recomendação musical que considera a emoção e o contexto do usuário ao sugerir músicas. O objetivo geral vai além da proposta de um Framework. O foco a princípio é ajudar o usuário alcançar um estado emocional desejado partindo do seu estado emocional atual. Visto que os métodos convencionais de recomendação de música requerem a interação humana na escolha das músicas.

**Objetivo Secundário:**

O objetivo geral do projeto se desdobrará em objetivos específicos que visam: (i) investigar métodos que recomendam músicas baseadas no contexto e emoção, bem como quais características de contexto são utilizadas; (ii) estabelecer relações entre recomendações de música por emoção e contexto; (iii) desenvolver um algoritmo para recomendação de música considerando a emoção e o contexto do usuário; e (iv) desenvolver e avaliar o framework proposto.

Tendo em vista os objetivos específicos do projeto de pesquisa, este documento apresenta ao comitê de ética a proposta de interações com seres humanos que visa coletar dados que serão utilizados no projeto de pesquisa. Objetiva-se realizar coleta de dados e avaliações junto ao público-alvo que serão ouvintes de músicas. Dentro dos objetivos específicos, no item (i) já foi realizada a revisão da literatura conforme Seção 1.2 deste documento. Para dar continuidade ao objetivo específico (i) agora será realizado um experimento fora de um ambiente controlado a fim, de capturar a interação do usuário com dois sistemas de recomendação musical. O objetivo do experimento é identificar rupturas de comunicação durante a interação. Para isso será aplicado um conjunto de tarefas ao usuário para que possa verificar a implementação ou não dos aspectos desejáveis. Por fim, também será aplicado um questionário online para coleta de perfil demográfico.

Deve-se ressaltar que não faz parte deste documento a descrição da avaliação do algoritmo e framework. Este será alvo de proposta posterior.

**Endereço:** WASHINGTON LUIZ KM 235

**Bairro:** JARDIM GUANABARA

**CEP:** 13.565-905

**UF:** SP

**Município:** SAO CARLOS

**Telefone:** (16)3351-9685

**E-mail:** cephumanos@ufscar.br



Continuação do Parecer: 4.901.583

**Avaliação dos Riscos e Benefícios:**

Informações retiradas do documento PB\_INFORMAÇÕES\_BÁSICAS\_DO\_PROJETO\_1749189.pdf de 09/05/2021:

**Riscos:**

Existem os seguintes riscos para os participantes do trabalho: estresse, tristeza, cansaço e tédio, seja pelos conteúdos, tempo de realização das tarefas e/ou resposta de questionários. O sujeito de pesquisa pode, ainda, se frustrar pela recomendação de músicas sugeridas por algum dos métodos, como também se sentir desconfortável por estar sendo avaliado. Além disso, ele pode se sentir desconfortável com a webcam gravando sua interação com a aplicação.

Será feito o possível para minimizar os impactos listados previamente. O participante poderá estar em um estado emocional de baixa excitação com a intenção de ouvir músicas e que animam, no entanto, caso ocorra a recomendação de músicas desagradáveis aos participantes, estas serão excluídas do experimento. Ainda assim, caso ocorram, o participante pode se recusar a responder aos questionários, como também para a escuta das músicas ou até mesmo interromper a sua participação a qualquer momento.

**Benefícios:**

Os benefícios relacionados à participação dos sujeitos de pesquisa estão em contribuir com o trabalho, assim como para o avanço do estado da arte na investigação das abordagens de recomendação musical que consideram a emoção e o contexto.

**Comentários e Considerações sobre a Pesquisa:**

Projeto de doutorado em desenvolvimento no programa de pós-graduação em Ciência da Computação pela Universidade Federal de São Carlos.

**Considerações sobre os Termos de apresentação obrigatória:**

Vide campo "Conclusões ou Pendências e Lista de Inadequações".

**Recomendações:**

Vide campo "Conclusões ou Pendências e Lista de Inadequações".

**Conclusões ou Pendências e Lista de Inadequações:**

Agradecemos as providências e os cuidados tomados pelos pesquisadores ao apresentarem a 2ª versão do protocolo de pesquisa ao CEP da UFSCar. Seguem abaixo as pendências listadas no parecer anterior do CEP e seu status (atendida, não atendida, parcialmente atendida).

**Endereço:** WASHINGTON LUIZ KM 235

**Bairro:** JARDIM GUANABARA

**CEP:** 13.565-905

**UF:** SP

**Município:** SAO CARLOS

**Telefone:** (16)3351-9685

**E-mail:** cephumanos@ufscar.br





Continuação do Parecer: 4.901.583

1. De acordo com orientações da CONEP, pesquisas com seres humanos que não envolvem intervenção no corpo devem seguir a Resolução 510/2016 e não a 466/2012. Dessa forma, solicita-se a adequação dos documentos que fazem referência a Resolução 466/2012 (TCLE e Projeto).

Resposta: No projeto, a referência feita à Resolução 466/2012 na Seção de Aspectos Éticos da Pesquisa foi removida e a referência à Resolução 510/2016 foi adicionada. No TCLE do Apêndice A e B houve apenas a exclusão da referência à Resolução 466/2012, uma vez que a citação da Resolução 510/2016 já havia sido mencionada anteriormente.

Análise: Atendida.

2. Explicitar no projeto e TCLE o atendimento às orientações da Conep sobre PROCEDIMENTOS EM PESQUISAS COM QUALQUER ETAPA EM AMBIENTE VIRTUAL. Este documento pode ser acessado na página do CEP UFSCar: <http://www.propq.ufscar.br/etica/cep>.

Em especial, os seguintes itens devem ser observados:

- Especificar no projeto como será realizado o convite para participação na pesquisa. De acordo com as orientações da Conep, o convite não deve ser feito com a utilização de listas que permitam a identificação dos convidados nem a visualização dos seus dados de contato (e-mail, telefone, etc) por terceiros. Qualquer convite individual enviado por e-mail só poderá ter um remetente e um destinatário, ou ser enviado na forma de lista oculta.

Resposta:

Na Seção de Participantes o texto foi reformulado para atender às diretrizes do Conep relativas ao convite de participação. O texto foi dividido em quatro parágrafos. O primeiro parágrafo foi escrito para atender este apontamento: O texto foi alterado para:

“O convite será direcionado a pessoas aleatórias que fazem parte da rede de contatos dos pesquisadores deste projeto e que têm o hábito de ouvir músicas em sua vida diária.

O convite será enviado via e-mail utilizando listas que não permitem a identificação dos convidados nem a visualização dos seus dados de contato (e-mail, telefone, etc.) por terceiros.”.

Análise: atendida.

-Deve ficar claro ao participante da pesquisa, no convite, que o consentimento será previamente apresentado e, caso, concorde em participar, será considerado anuência quando responder ao questionário/formulário ou entrevista da pesquisa.

**Endereço:** WASHINGTON LUIZ KM 235

**Bairro:** JARDIM GUANABARA

**CEP:** 13.565-905

**UF:** SP

**Município:** SAO CARLOS

**Telefone:** (16)3351-9685

**E-mail:** cephumanos@ufscar.br



Continuação do Parecer: 4.901.583

Resposta:

Na Seção de Participantes, o segundo parágrafo foi criado para que pudesse atender a este apontamento. Portanto, o seguinte texto foi incluído "O convite também incluirá o Termo de Consentimento Livre e Esclarecido (Apêndice A) para que antes de responder as perguntas fornecidas pelo pesquisador, o candidato possa decidir se concorda ou não em participar. Se o candidato concordar em participar, será considerado como concordância quando responder ao questionário de perfil e marcar que concorda com o Termo de Consentimento Livre e Esclarecido."

Análise: atendida.

-É da responsabilidade do pesquisador o armazenamento adequado dos dados coletados, bem como os procedimentos para assegurar o sigilo e a confidencialidade das informações do participante da pesquisa. Uma vez concluída a coleta de dados, é recomendado ao pesquisador responsável fazer o download dos dados coletados para um dispositivo eletrônico local, apagando todo e qualquer registro de qualquer plataforma virtual, ambiente compartilhado ou "nuvem".

Resposta:

Para garantir a confidencialidade das informações dos participantes da pesquisa sobre os dados coletados, um novo parágrafo foi adicionado na seção Instrumentos de Coleta de Dados, como se segue:

"Os dados coletados por meio de formulários e gravações utilizando o Google Meet não permanecerão disponíveis nas plataformas on-line. Todos dados coletados serão baixados para um dispositivo eletrônico local para análise posterior. Após a etapa de coleta de dados estar concluída, todo o material disponível nas plataformas on-line será excluído. Isto permitirá aos pesquisadores garantir o sigilo e a confidencialidade das informações dos participantes da pesquisa."

Análise: atendida.

-O convite para a participação na pesquisa deverá conter, obrigatoriamente, link para endereço eletrônico ou texto com as devidas instruções de envio, que informem ser possível, a qualquer momento e sem nenhum prejuízo, a retirada do consentimento de utilização dos dados do participante da pesquisa. Nessas situações, o pesquisador responsável fica obrigado a enviar ao participante de pesquisa, a resposta de ciência do interesse do participante de pesquisa retirar seu consentimento.

**Endereço:** WASHINGTON LUIZ KM 235

**Bairro:** JARDIM GUANABARA

**CEP:** 13.565-905

**UF:** SP

**Município:** SAO CARLOS

**Telefone:** (16)3351-9685

**E-mail:** cephumanos@ufscar.br



Continuação do Parecer: 4.901.583

Resposta:

Na Seção de Participantes, o terceiro parágrafo foi criado para informar a retirada do consentimento de utilização dos dados do participante da pesquisa, como segue:

“Entretanto, os participantes serão informados no convite que poderão a qualquer momento e sem qualquer prejuízo retirar seu consentimento para o uso dos dados.

Nessas situações, o participante receberá a resposta de ciência do interesse do participante de pesquisa retirar seu consentimento.”.

Análise: atendida.

- Durante o processo de consentimento, o pesquisador deverá esclarecer o participante de maneira clara e objetiva, como se dará o registro de seu consentimento para participar da pesquisa.

Resposta:

Foi informado na seção Participantes que o registro de consentimento será feito quando o participante preencher o formulário de perfil e marcar que concorda com o Termo de Consentimento Livre e Esclarecido, de acordo com o texto a seguir:

“Se o candidato concordar em participar, será considerado como concordância quando responder ao questionário de perfil e marcar que concorda com o Termo de Consentimento Livre e Esclarecido.”.

No TCLE foi incluído: “Após a leitura do presente termo, caso haja aceite, selecione a opção “Concordo em participar”, localizada abaixo da apresentação do TCLE on-line, acusando que leu e esta de acordo com o Termo apresentado. ”

Análise: atendida.

- Necessário indicar em método e no TCLE como o material gravado será cuidado (quem terá acesso, como será arquivado ou se será apagado/excluído).

Resposta:

Na Seção de Métodos de análises dos dados foi indicado que o material gravado será baixado e sem seguida excluído das plataformas virtuais. Além do mais, todas gravações após serem baixadas e analisadas também serão apagadas. Pois os registros das análises serão armazenadas apenas na plataforma Atlas.ti, sem a possibilidade de identificar qualquer participante. O texto inserido foi:

“As gravações serão feitas utilizando a plataforma Google Meet. Todas as gravações serão

**Endereço:** WASHINGTON LUIZ KM 235

**Bairro:** JARDIM GUANABARA

**CEP:** 13.565-905

**UF:** SP

**Município:** SAO CARLOS

**Telefone:** (16)3351-9685

**E-mail:** cephumanos@ufscar.br



baixadas para que a análise de vídeo possa ser feita localmente usando a plataforma Atlas.ti. Após baixar as gravações, todo e qualquer registro será excluído de qualquer plataforma virtual, ambiente compartilhado, ou "nuvem". Somente os pesquisadores deste projeto terão acesso às gravações localmente. Depois que a análise dos vídeos for realizada utilizando a plataforma Atlas.ti, as gravações locais também serão apagadas.”.

Análise: atendida.

3. No documento "TCLE.pdf", submetido em 09/05/2021, solicita-se:

- Os documentos em formato eletrônico relacionados à obtenção do consentimento devem apresentar todas as informações necessárias para o adequado esclarecimento do participante, com as garantias e direitos previstos na Resolução CNS no 510 de 2016.

Resposta:

Os documentos do TCLE em formato eletrônico presentes no Apêndice A e Apêndice B foram ajustados conforme os apontamentos informados para estarem de acordo com as garantias e direitos previstos na Resolução CNS no 510 de 2016.

Foram adicionados os seguintes tópicos no TCLE:

- O estudo vai acontecer na modalidade on-line através da plataforma Google Meet, e será gravada em áudio e vídeo para que o pesquisador possa ter acesso integral e fiel a fonte dos dados coletados.
- Todas as gravações serão baixadas para que a análise de vídeo possa ser feita localmente usando a plataforma Atlas.ti. Após baixar as gravações, todo e qualquer registro será excluído de qualquer plataforma virtual, ambiente compartilhado, ou "nuvem".
- Os pesquisadores se responsabilizam pela guarda e confidencialidade de todos os dados coletados no estudo, eles serão os únicos a terem acesso aos dados e tomarão todas as providências necessárias para manter o sigilo das informações.
- Depois que a análise dos vídeos for realizada utilizando a plataforma Atlas.ti, as gravações locais também serão apagadas.
- O cansaço e estresse do participante, que pode ser um possível dano causado pela sua participação nesta pesquisa, e mitigado através de sessões de avaliação da ferramenta que terão duração máxima de 1 hora; Além do mais, o tópico seguinte foi reformulado:
- O participante pode solicitar assistência antes, durante ou depois de finalizar sua participação entrando em contato por e-mail com o pesquisador responsável ou solicitando o auxílio ao um

**Endereço:** WASHINGTON LUIZ KM 235

**Bairro:** JARDIM GUANABARA

**CEP:** 13.565-905

**UF:** SP

**Município:** SAO CARLOS

**Telefone:** (16)3351-9685

**E-mail:** cephumanos@ufscar.br



Continuação do Parecer: 4.901.583

dos pesquisadores durante a aplicação do estudo;  
Análise: atendida.

- Necessário indicar em método e no TCLE como o material gravado será cuidado (quem terá acesso, como será arquivado ou se será apagado/excluído).

Resposta:

Assim como foi indicado no método como o material gravado será cuidado, no documento do TCLE foram acrescentados outros tópicos para garantir somente os pesquisadores terão acesso às gravações e que, após as análises, todos os vídeos serão apagados para garantir a não identificação dos participantes. Os tópicos adicionados foram:

- Todas as gravações serão baixadas para que a análise de vídeo possa ser feita localmente usando a plataforma Atlas.ti. Após baixar as gravações, todo e qualquer registro será excluído de qualquer plataforma virtual, ambiente compartilhado, ou "nuvem".
- Os pesquisadores se responsabilizam pela guarda e confidencialidade de todos os dados coletados no estudo, eles serão os únicos a terem acesso aos dados e tomarão todas as providências necessárias para manter o sigilo das informações.
- Depois que a análise dos vídeos for realizada utilizando a plataforma Atlas.ti, as gravações locais também serão apagadas.

Análise: atendida.

#### **Considerações Finais a critério do CEP:**

Diante do exposto, o Comitê de ética em pesquisa - CEP, de acordo com as atribuições definidas na Resolução CNS nº 510 de 2016, manifesta-se por considerar "Aprovado" o projeto. Conforme dispõe o Capítulo VI, Artigo 28, da Resolução Nº 510 de 07 de abril de 2016, a responsabilidade do pesquisador é indelegável e indeclinável e compreende os aspectos éticos e legais, cabendo-lhe, após aprovação deste Comitê de Ética em Pesquisa: II - conduzir o processo de Consentimento e de Assentimento Livre e Esclarecido; III - apresentar dados solicitados pelo CEP ou pela CONEP a qualquer momento; IV - manter os dados da pesquisa em arquivo, físico ou digital, sob sua guarda e responsabilidade, por um período mínimo de 5 (cinco) anos após o término da pesquisa; V - apresentar no relatório final que o projeto foi desenvolvido conforme delineado, justificando, quando ocorridas, a sua mudança ou interrupção. Este relatório final deverá ser protocolado via notificação na Plataforma Brasil. OBSERVAÇÃO: Nos documentos encaminhados por Notificação NÃO DEVE constar alteração no conteúdo do projeto. Caso o projeto

**Endereço:** WASHINGTON LUIZ KM 235

**Bairro:** JARDIM GUANABARA

**CEP:** 13.565-905

**UF:** SP

**Município:** SAO CARLOS

**Telefone:** (16)3351-9685

**E-mail:** cephumanos@ufscar.br



Continuação do Parecer: 4.901.583

tenha sofrido alterações, o pesquisador deverá submeter uma "EMENDA".

**Este parecer foi elaborado baseado nos documentos abaixo relacionados:**

Tipo Documento	Arquivo	Postagem	Autor	Situação
Informações Básicas do Projeto	PB_INFORMAÇÕES_BÁSICAS_DO_PROJETO_1749189.pdf	29/07/2021 12:01:09		Aceito
Outros	Carta_Resposta_versao1.pdf	29/07/2021 11:58:47	WILLIAN GARCIAS DE ASSUNCAO	Aceito
Projeto Detalhado / Brochura Investigador	ProjetoPesquisa.pdf	29/07/2021 11:44:47	WILLIAN GARCIAS DE ASSUNCAO	Aceito
TCLE / Termos de Assentimento / Justificativa de Ausência	TCLE.pdf	29/07/2021 11:44:22	WILLIAN GARCIAS DE ASSUNCAO	Aceito
Folha de Rosto	FolhaRostoWillian.pdf	09/05/2021 11:23:25	WILLIAN GARCIAS DE ASSUNCAO	Aceito

**Situação do Parecer:**

Aprovado

**Necessita Apreciação da CONEP:**

Não

SAO CARLOS, 12 de Agosto de 2021

---

**Assinado por:**

**Adriana Sanches Garcia de Araújo  
(Coordenador(a))**

**Endereço:** WASHINGTON LUIZ KM 235

**Bairro:** JARDIM GUANABARA

**CEP:** 13.565-905

**UF:** SP

**Município:** SAO CARLOS

**Telefone:** (16)3351-9685

**E-mail:** cephumanos@ufscar.br