

UNIVERSIDADE FEEVALE

ÉRICO DE SOUZA LOEWE

RECOMENDAÇÃO DE GÊNEROS MUSICAIS ATRAVÉS DE
CONTEXTO

Novo Hamburgo

2020

ÉRICO DE SOUZA LOEWE

RECOMENDAÇÃO DE GÊNEROS MUSICAIS ATRAVÉS DE
CONTEXTO

Trabalho de Conclusão de Curso
apresentado como requisito parcial
à obtenção do grau de Bacharel em
Nome do Curso pela
Universidade Feevale

Orientador: Juliano Varella De Carvalho

Novo Hamburgo

2020

AGRADECIMENTOS

Gostaria de agradecer a todos os que, de alguma maneira, contribuíram para a realização desse trabalho de conclusão, em especial:

Ao meu professor orientador, meu irmão Lucas minha colega Tatiana, a minha família, aos amigos e às pessoas que convivem comigo diariamente, minha gratidão, pelo apoio emocional - nos períodos mais difíceis do trabalho.

RESUMO

As pessoas têm dificuldades em lidar com um grande volume de informações e, com a internet e a evolução da tecnologia, cresceu incontestavelmente, trazendo a necessidade de os sistemas evoluírem suas recomendações, surgindo os Sistemas de Recomendações (*RecSys*). Eles são utilizados em diversos tipos de aplicações. Vendas, seleção de um filme, na escolha de uma música, que é um dos objetivos dessa pesquisa, são só alguns dos exemplos. O LORS (*Loewe's Recommender System*) veio para melhorar esse sistema, através da recomendação de gêneros musicais baseado em contexto comportamental e de ambiente. Nele, é utilizado o algoritmo KNN para, a partir do contexto musical (gostou, não gostou, repetiu), comportamental (atividade, sentimento) e de ambiente (lugar), encontrar o gênero musical mais adequado para o momento. É apresentada toda pesquisa, desde o desenvolvimento e evolução do sistema, até os resultados alcançados com as recomendações (onde obteve-se uma acurácia de 0,46 nos 1775 registros de um usuário do plugin desenvolvido).

Palavras-chave: *RecSys. Machine Learning. Sistemas de recomendação musical. K-Nearest Neighbors. Música. Spotify.*

ABSTRACT

Everybody knows people have difficulties in dealing with a large volume of information. With the internet and the evolution of technology, there was an increase of the available amount of information, bringing the need for systems to improve their recommendations, arising the RecSys. These systems are used in several types of applications such as sales, selecting a movie and choosing a song, which one is one of the goals of this research. In this work, a music genre recommender system called LORS (*Loewe's Recommender System*) based on behavior and environmental context was developed. The system uses the KNN (K-Nearest Neighbors) algorithm, with the musical (like, hate, repeat), behavior (activity, feeling) and environmental (location) features to find the best music genre for the moment. We show all the research since the development of the system until the recommendation results (where an accuracy of 0.46 was obtained by the plugin user 1775 records).

Keywords: RecSys. Machine Learning. Music Recommender System. K-Nearest Neighbors. Music. Spotify.

LISTA DE FIGURAS

Figura 1 - Motor avançado de busca da ACM.....	18
Figura 2 - Resultado de busca dos <i>proceedings</i> no motor de busca da ACM.....	19
Figura 3 - Resultado de busca dos <i>journals</i> no motor de busca da ACM	19
Figura 4 - Etapas realizadas para filtrar os trabalhos encontrados no motor de busca da ACM	20
Figura 5 - Filtro em cima dos trabalhos selecionados através do resumo	21
Figura 6 - Procedimento de filtro realizado baseado nos trabalhos encontrados no motor de busca da ACM	21
Figura 7 - Fatores da preferência musical	30
Figura 8 - Etapas do desenvolvimento do sistema de recomendação musical	34
Figura 9 - Apresentação dos contextos estudados no trabalho.....	35
Figura 10 - A esquerda, tela introdutória da aplicação. A direita, tela de login da aplicação ..	41
Figura 11 - A esquerda, tela de preenchimento do contexto. A direita, tela da lista de dispositivos do Spotify	42
Figura 12 - A esquerda, tela principal, a qual apresenta a música sendo reproduzida ao usuário. A direita, tela de busca de músicas que encaixem melhor no momento	43
Figura 13 - Console do Realtime Database do Firebase.....	45
Figura 14 - Representação gráfica da classificação do algoritmo KNN sobre um plano x1 e x2. No plano, os pontos amarelos são a representação da classe A, roxos classe B e vermelho é o ponto de teste.....	47
Figura 15 - Visão macro das etapas para transformar os eventos registrados no firebase na tabela que sera rodado o KNN.....	49
Figura 16 - Representação dos eventos salvos no Firebase.....	50
Figura 17 - Representação das listas geradas na etapa “Separa contexto”	50
Figura 18 - Representação das listas geradas na etapa “separa contexto das músicas”	51
Figura 19 - Representação da tabela na etapa “separa contexto das músicas”	51
Figura 20 - <i>head()</i> do <i>dataframe</i> criado a partir da variável <i>genreTable</i>	52
Figura 21 - Visão macro do sistema LORS.....	54
Figura 22 – A direita, parte superior da tela de recomendações. A esquerda, parte inferior da tela de recomendações	56

LISTA DE QUADROS

Quadro 1 - Relação das funcionalidades desenvolvidas em cada artigo revisado.....	31
Quadro 2 - Perguntas e respostas disponibilizadas a um certo público através dos formulários do Google.	37
Quadro 3 Número de eventos registrados por usuário	46
Quadro 4 - Lista de ações possíveis nos eventos.....	48
Quadro 5 - Campos e seus respectivos valores utilizados na recomendação	55
Quadro 6 - relação dos gêneros e a classe utilizada no KNN.....	57
Quadro 7 - matriz confusão da classe 12, gênero musical country	58
Quadro 8 - Matrix confusão do usuário spotify:user:4i3jdhv6vubcjdpsn38iv8u4	59

LISTA DE ABREVIATURAS E SIGLAS

AIR	Activity-aware Intent Recommendation
App	Application
AUC	Operating Characteristic Curve
GPML	Gaussian Process for Machine Learning
GPR	Gaussian Process Regression
LORS	Loewe's Recommender System
POC	Proof of concept
RBF	Radial Basis Function
RecSys	Recommender Systems
SDK	Software development kit
SPTF	RecSys do Spotify
SVM	Support Vector Machine
URI	Uniform Resource Identifier

SUMÁRIO

1 INTRODUÇÃO	11
1.1 Objetivo Geral	14
1.2 Objetivos Específicos	14
1.3 Metodologia.....	14
2 TRABALHOS RELACIONADOS	16
2.1 Levantamento bibliográfico inicial.....	16
2.2 O protocolo de revisão.....	17
2.3 PROCURA NOS MOTORES DE BUSCA	18
2.4 ETAPAS DA REVISÃO DOS TRABALHOS	20
2.4.1 Trabalhos selecionados	21
2.5 FUNCIONALIDADES DOS TRABALHOS INVESTIGADOS	30
2.6 Conclusões dos trabalhos revisados	33
3 COLETA DO CONTEXTO DOS USUÁRIOS	34
3.1 Contexto	34
3.1.1 O que é o contexto comportamental?	35
3.1.2 O que é o contexto de ambiente?	35
3.1.3 Como serão obtidos os contextos?.....	36
3.1.4 O que são as ações do usuário?.....	37
3.2 Pesquisa com usuários sobre recomendação musical (QUESTIONÁRIO)	37
3.2.1 Pré-teste do questionário.....	39
3.2.2 Resultados do questionário	39
3.3 Desenvolvimento Do plugin.....	41
3.3.1 Telas da aplicação (<i>plugin</i>).....	42
3.3.2 Tecnologias utilizadas no desenvolvimento	44
3.4 Distribuição da aplicação e coleta de dados	44
3.4.1 Pré-teste	44
3.4.2 Hospedagem	45
3.4.3 Coleta do Firebase	45
4 SISTEMA LORS	47
4.1 O Algoritmo KNN.....	47

4.1.1	Preparação dos dados para o KNN	48
4.1.2	Testes com KNN.....	52
4.2	Predição no sistema <i>LORS</i>	53
4.2.1	POC (Proof of Concept)	54
4.2.2	Servidor.....	54
4.2.3	Hospedagem	55
4.2.4	Recomendação	55
4.2.5	Resultado da recomendação (integração <i>webapp</i>).....	56
4.2.6	Resultados do experimento	56
5	CONCLUSÃO	61
5.1	Trabalhos futuros	62
	REFERÊNCIAS BIBLIOGRÁFICAS	64

1 INTRODUÇÃO

A tecnologia avançou muito nos últimos anos, principalmente quando aborda-se internet e armazenamento de dados (MURARO, 2009). O custo de armazenar um arquivo vem ficando mais barato e tem feito com que as pessoas tenham mais espaço de armazenamento, possibilitando a geração de mais informações (UNIVERSIDADE FEDERAL DO CEARA, [s.d.]). A quantidade de aplicações disponíveis na internet tem aumentado cada vez mais e consecutivamente gerando mais dados e opções para os usuários.

Diversas vezes o indivíduo possui dificuldades em realizar escolhas entre as diversas alternativas daquilo que lhe é apresentado, e acaba geralmente confiando nas escolhas que lhe são apresentadas através de outras pessoas (RESNICK, PAUL AND VARIAN, 1997). A partir do aumento da quantidade de informações disponíveis e do conhecimento da habilidade do indivíduo de realizar escolhas, a partir de sua experiência pessoal, surgem os sistemas de recomendação. Esses sistemas buscam filtrar a grande massa de dados disponível, para auxiliar o indivíduo na escolha das opções disponíveis.

Sistemas de recomendação (RecSys - *Recommender Systems*) são implementações de *softwares* e técnicas, que apresentam sugestões de itens que seriam de uso de um usuário. As sugestões são de acordo com vários processos de decisão, como, que item comprar, que música escutar ou que notícia ler. No geral, sistemas de recomendação servem para dois propósitos diferentes: (i) podem ser utilizados para estimular os usuários a fazer algo, como comprar livros ou assistir algum filme ou (ii) utilizados para lidar com a sobrecarga de informações, selecionando os melhores itens de uma base maior (DIETMAR et al., 2010).

O auxílio que um sistema de recomendação provê pode ser bem específico ou genérico. Isso vai depender do tipo de filtragem escolhida para realizar a recomendação. Quando um sistema busca uma filtragem que leva em consideração as preferências do usuário, elas podem ser obtidas implicitamente, por meio de um monitoramento de comportamento. No entanto, um sistema de recomendação pode também obter explicitamente sua preferência através de perguntas (DIETMAR et al., 2010).

As recomendações personalizadas necessitam que o sistema conheça algo sobre cada usuário da base. Todo sistema de recomendação deve desenvolver e manter um *user model* ou *user profile*, que por exemplo, contém as preferências dele. A existência de um *user model* é essencial para qualquer sistema de recomendação (DIETMAR et al., 2010).

Os sistemas de recomendação iniciaram com a "Usenet" da Duke University, na década de 70, um sistema com uma distribuição global que buscava divulgar novas notícias postadas e classificadas pelos seus usuários. Em 1985, iniciaram-se as recomendações baseadas em conteúdo, a partir de uma arquitetura para sistemas de informação de larga escala. A Xerox teve sua grande participação em 1992, desenvolvendo o primeiro sistema (Tapestry) designado a realizar a filtragem colaborativa. Em 1997, foi desenvolvido o primeiro sistema de recomendação de filmes chamado Movielens. Até que em 2000, a Pandora iniciou o projeto genoma musical, onde a recomendação passou a ser utilizada para facilitar as escolhas de um usuário entre as diversas músicas existentes na época (BHATNAGAR, 2016).

Desde então, os sistemas de recomendação têm revolucionado o mercado de aplicações de diversas formas, pois com eles, aumentam-se o número de itens vendidos em sites de venda online, além dos sites conseguirem vender itens mais diversificados. Eles têm melhorado a satisfação dos usuários e, com isso, têm aumentado suas fidelidades na aplicação, e o principal, os *RecSys* ajudam a entender melhor o que os usuários querem. (RICCI; ROKACH; SHAPIRA, 2011)

Os *RecSys* têm evoluído muito desde o seu surgimento, isso acontece dado o interesse acadêmico e comercial sobre a área, além dos benefícios que ela pode trazer. Um caso famoso dos sistemas de recomendação foi o Netflix Prize, uma competição feita pela Netflix, que ofereceu um milhão a quem melhorasse o algoritmo de recomendação de seu sistema em 10%. A competição iniciou em 2006 e demorou 3 anos para alguém conseguir resolver o problema deles de maneira satisfatória. Nesse caso o vencedor utilizou um modelo híbrido de *RecSys* (FALK, 2019).

Dietmar diz que existem 4 tipos de sistemas de recomendação, sendo eles: recomendação colaborativa, recomendação baseada em conteúdo, recomendação baseada em conhecimento, e sistemas de recomendação híbridos (DIETMAR et al., 2010).

Na recomendação baseada em conteúdo, o sistema aprende a recomendar itens que são similares ao que o usuário gostou no passado, essa similaridade é calculada com base na relação das características dos itens a serem comparados. Por exemplo, no caso de usuário avaliar positivamente um filme do gênero comédia, então, o sistema pode registrar essa ação e futuramente recomendar outros filmes desse mesmo gênero. (RICCI; ROKACH; SHAPIRA, 2011)

A recomendação colaborativa parte da ideia de que se os usuários compartilharam dos mesmos interesses no passado, eles irão continuar tendo os mesmos interesses no futuro. Por exemplo, os usuários A e B tem um histórico de compras bem semelhante e o usuário A comprou um novo livro que o usuário B nem chegou a ver, nesse tipo de recomendação, a ideia é que o sistema sugira este livro para o usuário B (DIETMAR et al., 2010).

Diferente da recomendação colaborativa ou baseada em conteúdo, a recomendação baseada em aprendizado não consegue depender somente do histórico de compra de um usuário, é necessário um conteúdo mais estruturado e detalhado para uma recomendação, é utilizado um conteúdo adicional fornecido manualmente (conteúdo recente ao produto e usuário) (DIETMAR et al., 2010).

E por último, e não menos importante, DIETMAR et al. (2010) trazem em sua obra o modelo híbrido de recomendação, onde a ideia é combinar as diferentes técnicas, buscando gerar uma boa e mais assertiva recomendação.

Esses sistemas têm ajudado muito na venda de produtos online. No entanto, um dos segmentos de mercado que apresentaram problemas, foram as vendas de álbum ou faixas musicais online. Elas possibilitam às pessoas baixarem ou receberem as faixas a partir de compras em lojas virtuais, porém o preço de cada faixa ainda era muito caro, o que fazia com que muitos usuários optassem pela pirataria. Desta forma, surgiu uma nova maneira de anunciar os “produtos musicais” online, o *streaming* musical (BORJA; DIERINGER, 2016).

O mercado musical tem evoluído muito desde seu início. No começo, seu consumo aumentou cada vez mais com a evolução das tecnologias e internet. Com o *streaming* musical, as pessoas passaram a consumir mais os sistemas de *streaming*, diminuindo o consumo de pirataria online (ERIKSSON et al., 2019). Em 2018 o lucro global da indústria musical cresceu 9,7%. Nesse crescimento, o *streaming* pago possui boa parte dele com 34% do total (IFPI, 2019).

Os sistemas de *streaming* são um tipo de mecanismo de processamento de dados projetado com um conjunto de dados infinitos em mente (NIWA, 2018). Esse mecanismo pode ser desenvolvido para processar muitos tipos de mídia, tais como vídeos, fotos e áudio. Nesse trabalho será utilizado o *streaming* de áudio, mais especificamente, o *streaming* disponível nas APIs da ferramenta Spotify.

Dentro dos sistemas de *streaming*, existe o *streaming* de áudio que é semelhante a transmissão de rádio tradicional, exceto que é utilizada a internet para enviar e receber os

áudios, ao invés de utilizar ondas aéreas. Assim como o ato de ligar um rádio, o *streaming* de áudio é reproduzido em tempo real, o que é muito mais conveniente do que baixar uma música online e então consumi-la (LUINI; WHITMAN; DATE, 2002).

1.1 OBJETIVO GERAL

Desenvolver um sistema de recomendação musical, considerando o contexto comportamental do usuário, bem como o contexto do ambiente onde ele encontra-se.

1.2 OBJETIVOS ESPECÍFICOS

- Investigar APIs de Serviços de *Streamings* Musicais.
- Selecionar a API a ser utilizada no sistema de recomendação.
- Definir os contextos de ambiente a serem utilizados no sistema.
- Definir os contextos comportamentais do usuário a serem utilizados no sistema.
- Criar a infraestrutura necessária para o armazenamento e relacionamento das músicas com os contextos comportamentais e de ambiente do usuário.
- Criar um protótipo do sistema de recomendação.
- Avaliar o sistema de recomendação com usuários voluntários.

1.3 METODOLOGIA

Esse trabalho tem como natureza a pesquisa aplicada, pois através dos conhecimentos estudados de *RecSys* foi desenvolvido um sistema que gera as recomendações musicais personalizadas por usuário, por meio do contexto comportamental e ambiental, obtido através do *plugin* de reprodução musical.

O método científico utilizado por esse trabalho é do tipo dedutivo, dado que primeiro foi realizada uma pesquisa bibliográfica relacionada ao problema proposto, para então obter a solução. Essa pesquisa buscou estudar o funcionamento dos sistemas de recomendação musicais, por meio dos artigos relacionados, fazendo com que ela tenha como objetivo um estudo exploratório.

Utilizou-se 2 tipos de procedimentos técnicos nessa pesquisa. Pesquisa bibliográfica, dado que foi necessária uma base de conhecimentos e estudos sobre os *RecSys*, suas técnicas e algoritmos. Com o estudo realizado e os registros de contextos definidos, foi utilizado da pesquisa experimental, para avaliar a base disponível através da aplicação liberada aos

usuários. Para realizá-lo, foi necessário um estudo de técnicas para avaliar os resultados de um RecSys.

Com as técnicas de avaliação a serem utilizadas definidas, elas foram desenvolvidas no sistema, permitindo que os usuários consigam contribuir com sua recomendação através do uso. Essa pesquisa apresentou no final os resultados estatísticos obtidos pelas recomendações do sistema e suas avaliações, exibindo a quantidade de acertos e erros obtidos nas recomendações, fazendo com que, essa pesquisa tenha uma abordagem do tipo quantitativa.

Ao final, esse trabalho procurou responder a seguinte questão: Com base nas músicas conhecidas pelo usuário, é possível aperfeiçoar as recomendações de um sistema, aplicando os conhecimentos de RecSys e utilizando dados de contexto comportamental e de ambiente?

Portanto, de acordo com esse contexto, este trabalho construiu um sistema de recomendação musical, utilizando o contexto comportamental do usuário e o contexto do ambiente onde ele está inserido. Esse contexto foi obtido através da criação de um *plugin* que permitirá ao usuário escutar suas músicas enquanto são registrados os eventos do contexto vivido naquele momento.

O trabalho está dividido em 5 capítulos. O primeiro capítulo é esta introdução. No segundo capítulo aborda-se uma pesquisa bibliográfica, onde é apresentada uma revisão dos sistemas de recomendação relacionados e os trabalhos resultantes. O capítulo três detalha a definição do contexto, o questionário enviado aos usuários, o desenvolvimento do *plugin* e a coleta de dados da aplicação web. O quarto capítulo define o algoritmo utilizado, preparação dos dados coletados do *plugin*, modelagem do sistema desenvolvido e no fim os resultados obtidos no experimento. O último capítulo é a conclusão sobre a pesquisa.

2 TRABALHOS RELACIONADOS

Os sistemas de recomendação musical iniciaram nos anos 90 e têm evoluído muito desde então, ao ponto de que hoje existem diversos trabalhos relacionados a esse assunto para área. Nesse capítulo serão abordados alguns trabalhos encontrados, a partir de uma revisão bibliográfica realizada sobre o assunto.

Após ser realizada a revisão bibliográfica, foram analisados os algoritmos e estratégias de recomendação de cada artigo. E então, será desenvolvido o sistema de recomendação desse trabalho, utilizando um dos algoritmos levantados.

2.1 LEVANTAMENTO BIBLIOGRÁFICO INICIAL

Antes do início da revisão, foram encontrados diversos trabalhos relacionados através de: (i) busca genérica no Google Scholar; (ii) indicação dos avaliadores desse trabalho. Destes, foram selecionados 2 para serem revisados nesse trabalho.

Realizada a busca genérica no Google Scholar em busca de trabalhos relacionados ao tema desse trabalho, foram priorizados os trabalhos em português, para dar uma visão clara e rápida do assunto. E nessa busca foi encontrado o seguinte trabalho: “Desenvolvimento de um Sistema de Recomendação Musical Sensível ao Contexto”. (ALIAGA, 2018)

Esse trabalho teve como objetivo desenvolver o modelo de um sistema sensível ao contexto, utilizando das técnicas clássicas de recomendação, aplicando uma camada extra de filtragem colaborativa. Nessa camada, ele utiliza do algoritmo K-Vizinhos Mais Próximos (KNN) para realizá-la, o qual é o mais amplamente utilizado para esse tipo de recomendação conforme (ALIAGA, 2018 apud BOBADILLA et al., 2013, p. 43).

No trabalho de ALIAGA (2018) foram escolhidos 10 usuários para realizar o teste, tendo um contexto comum que era “Estudar” para atividade e “BR” para cultura. Foram realizados 240 testes para compilar os dados do experimento, e no fim foram apresentados os resultados do experimento realizado “Com contexto” e “Sem contexto”, em que o trabalho obteve uma precisão de 50% na taxa de aceitação das recomendações realizadas.

As indicações de trabalhos relacionados realizadas pelos avaliadores (na revisão do anteprojeto) foram analisadas e foi identificado o algoritmo KNN também no trabalho “Effective Nearest-Neighbor Music Recommendations”. (LUDEWIG et al., 2018) Esse trabalho apresenta uma técnica híbrida de recomendação, que utiliza uma combinação do KNN, fatoração de matriz e um pequeno conjunto heurístico.

2.2 O PROTOCOLO DE REVISÃO

Essa revisão tem como foco encontrar trabalhos que abordam os sistemas de recomendação, que a partir das músicas conhecidas pelo usuário, e do contexto comportamental e de ambiente apresentado, buscam melhorar assertividade das recomendações ao ouvinte.

Dado o foco da pesquisa e o conteúdo encontrado até o momento, foi feita uma lista de interesses que serão abordados nessa revisão:

- **Estudos realizados**
- **Técnicas de recomendação utilizadas**
- **Contextos utilizados para recomendação**

A partir do escopo de revisão que esse trabalho está inserido, foram definidas certas palavras-chaves para auxiliar no desenvolvimento da revisão, elas são:

- RecSys
- Machine Learning
- Sistemas de recomendação musical
- *Context-aware* (Cientes de contexto)

Para realizar a busca dos trabalhos relacionados foi utilizado o motor de busca da ACM¹, o qual permite realizar pesquisas avançadas a partir da linguagem desenvolvida pela ACM e dos filtros disponíveis na busca (ACM, 2020). Esse motor de busca foi escolhido por conter diversos trabalhos de excelência na área da computação.

Foi desenvolvida uma *string* de busca para filtrar por estudos que estejam de acordo com o foco de pesquisa do trabalho. Existem muitos artigos e diversas áreas de pesquisa relacionadas aos sistemas de recomendação musical, então, para realizar uma busca mais assertiva, foi utilizada a seguinte *string* de busca:

((“RecSys” OR “recommender systems”) AND (“machine learning”) AND (“music” OR “musical”) AND (“behavioral context” OR “environmental context” OR “context-aware”))

Com os resultados da busca, cada trabalho foi analisado, e esta análise foi dividida em quatro etapas: (i) a leitura inicial foi feita no título de cada artigo, e foram mantidos

¹ <https://dl.acm.org/>

àqueles que indicam uma relação com essa pesquisa; (ii) consistiu em realizar uma leitura dos resumos desses trabalhos e manter àqueles adequados; (iii) aplicou-se um filtro, baseando-se na leitura da introdução e conclusão dos artigos e por fim; (iv) leitura total dos artigos selecionados.

Após a leitura aprofundada em cima dos artigos selecionados, essa revisão trouxe informações de cada publicação, onde foi possível entender o que já foi desenvolvido. Ao final, foi desenvolvida uma tabela relacionando as funcionalidades existentes e o uso delas nos trabalhos encontrados, a qual será apresentada nas próximas seções.

2.3 PROCURA NOS MOTORES DE BUSCA

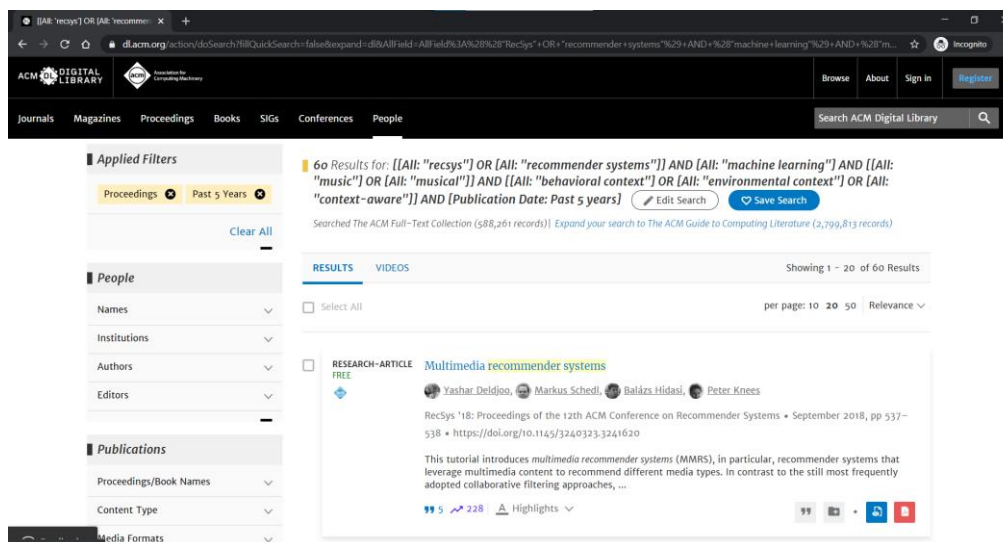
No dia 07/05/2020 foi realizada a pesquisa no motor de busca ACM utilizando a *string* de busca pré-definida anteriormente. As Figuras Figura 1, Figura 2 e Figura 3 ilustram esse processo. A Figura 1 apresenta a string de busca desenvolvida no motor da ACM, e as Figuras 2 e 3 apresentam respectivamente os resultados das buscas por *proceedings* e *journals*. A quantidade de resultados apresentados na ACM foi de 150 trabalhos.

Figura 1 - Motor avançado de busca da ACM

The screenshot shows the ACM Digital Library's advanced search page. At the top, there's a navigation bar with 'Journals', 'Magazines', 'Proceedings', 'Books', 'SIGs', 'Conferences', and 'People'. Below this is the 'Advanced Search' section. The search bar contains the query: ('RecSys' OR 'recommender systems' OR 'machine learning') AND ('music'). The interface includes a search bar, a dropdown for 'Search items from' (The ACM Full-Text collection), a 'Search Within' dropdown (Anywhere), and a 'Filters' section with 'Published in' and 'Match All' options. A 'Feedback' button and 'Publication Date' filter are also visible.

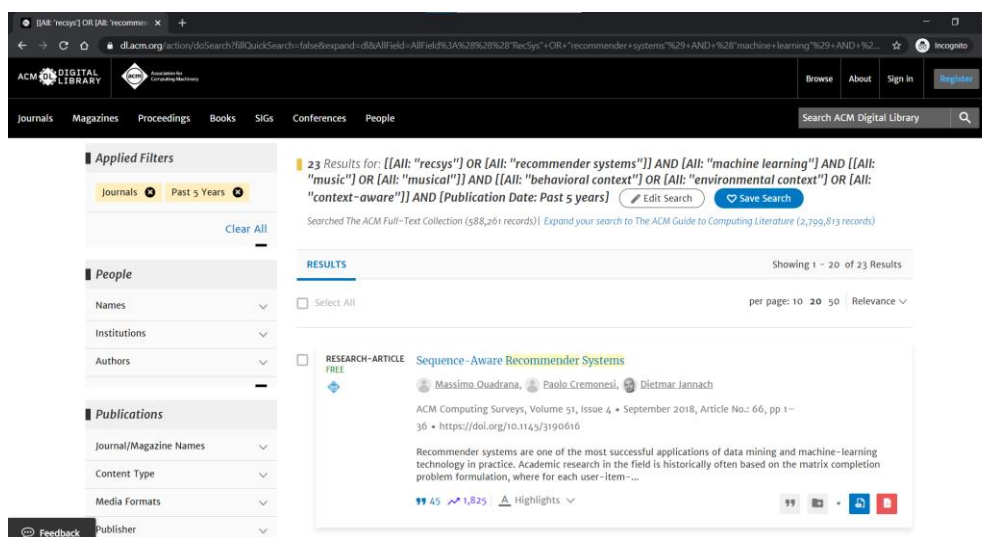
Fonte: Elaborado pelo autor (2020)

Buscando aumentar o foco da pesquisa, foram aplicados alguns filtros em cima da busca. Procurando trazer somente os trabalhos mais atuais relacionados à área, foram mantidos somente os artigos publicados nos últimos 5 anos (2015-2020).

Figura 2 - Resultado de busca dos *proceedings* no motor de busca da ACM

Fonte: Elaborado pelo autor (2020)

Visando trazer um conteúdo mais técnico para o trabalho, foram reduzidos os tipos de publicações aceitas para *proceedings* e *journals*. Após aplicados esses filtros, a quantidade de trabalhos encontrados passou para 83.

Figura 3 - Resultado de busca dos *journals* no motor de busca da ACM


Fonte: Elaborado pelo autor (2020)

Um dos principais motivos que levou essa revisão ser realizada através da ACM, ao invés de outras plataformas de busca como IEEE, é que ela concentra diversas conferências e eventos relacionados a área de RecSys (ACM RECSYS COMMUNITY, 2020).

2.4 ETAPAS DA REVISÃO DOS TRABALHOS

Com a busca realizada no dia 07/05/20, no motor da ACM, a partir da *string* de busca foram encontrados 83 trabalhos, sendo 23 do tipo *journal* e 60 do tipo *proceeding*. Em cima deles, foi realizado um filtro baseado em 3 etapas (demonstradas na Figura 4), que visam direcionar esta pesquisa para a revisão dos trabalhos que condizem com o objetivo descrito no protocolo.


Figura 4 - Etapas realizadas para filtrar os trabalhos encontrados no motor de busca da ACM



Fonte: Elaborado pelo autor (2020)

Baseado no conhecimento obtido dos trabalhos na segunda etapa, foi realizada uma classificação deles em 4 tipos, que são: (i) trabalhos que possuem relação com o foco de pesquisa da revisão; (ii) trabalhos que utilizam dos RecSys e contexto, mas que visam recomendar outros temas além da música como notícias, filmes e produtos; (iii) trabalhos que utilizam dos RecSys e contexto, mas que não abordam a recomendação musical; (iv) trabalhos que utilizam dos RecSys musicais, mas que não utilizam o contexto nas recomendações. A Figura 5 apresenta a relação entre os tipos e a quantidade de artigos encontrados.

Figura 5 - Filtro em cima dos trabalhos selecionados através do resumo

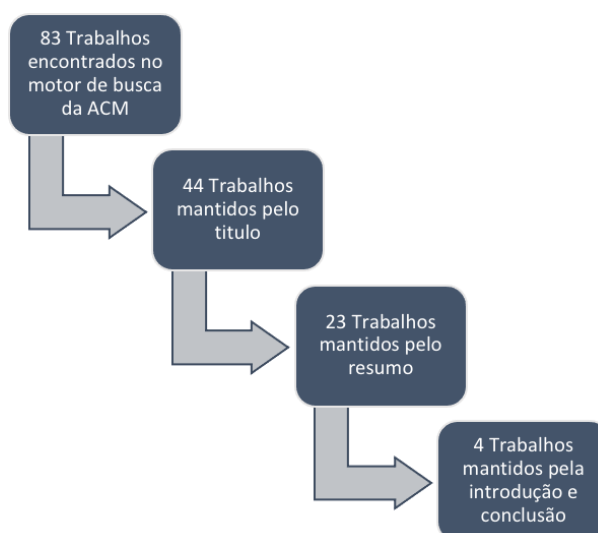


Fonte: Elaborado pelo autor (2020)

2.4.1 Trabalhos selecionados

O resultado do procedimento de filtro apresentado na Figura 6, resultou em 4 trabalhos relacionados ao objetivo descrito no protocolo de revisão desse trabalho.

Figura 6 - Procedimento de filtro realizado baseado nos trabalhos encontrados no motor de busca da ACM



Fonte: Elaborado pelo autor (2020)

Foi realizada uma revisão nesses trabalhos, a qual foi apresentada nas próximas seções. Em cada seção/artigo, foi apresentado um breve resumo do que foi desenvolvido e no fim, foram respondidas as seguintes perguntas:

- **Qual o problema que ele resolveu?**
 - Buscam obter uma recomendação personalizada pelo gosto do usuário?
- **Quais técnicas foram usadas?**
 - Foi utilizada alguma recomendação colaborativa?
 - Quais foram os algoritmos utilizados na recomendação?
- **Qual a base de treinamento e teste?**
 - Foi desenvolvida alguma aplicação para obter as bases?
- **Quais os contextos utilizados?**
 - Foi analisado o comportamento? Quais aspectos?
 - Foi analisado o ambiente? Quais fatores?
 - Como é obtido o contexto?
 - O usuário pode auxiliar na definição do contexto?
 - É apresentado o contexto atual para o usuário?
- **A recomendação atingiu as expectativas do usuário?**
 - Quais foram os critérios de qualidade utilizados?
 - Quantidade de usuários utilizada? (tamanho da base)
 - Quais foram as técnicas de avaliação usadas?

2.4.1.1 The New Challenges when Modeling Context through Diversity over Time in Recommender Systems (L'HUILLIER, 2016)

Foi realizada a revisão do trabalho e verificado que ele não apresenta dados e técnicas suficientes para serem consideradas nessa pesquisa, pois todas as informações do sistema desenvolvido estão em outros artigos citados por esse. Dada a falta de informações apresentadas nesse trabalho, não serão respondidas as questões pré-estabelecidas anteriormente.

2.4.1.2 Prediction of music pairwise preferences from facial expressions (TKALČIČ et al., 2019)

Essa pesquisa apresenta técnicas de como obter as preferências de um usuário através de suas expressões faciais. Para isso, foi desenvolvida uma aplicação onde a preferência do

usuário é obtida através da observação do seu comportamento. Cada usuário devia ouvir ao menos 10 segundos de cada uma das duas músicas apresentadas na tela e ao finalizar, poderia escolher qual música era mais adequada para se ouvir no ambiente pré-estabelecido que era seu trabalho. É nesse momento que são obtidos os dois contextos estudados no artigo revisado, que são: (i) as expressões faciais gravadas através de uma câmera; (ii) o tempo dedicado a ouvir cada música.

- **Qual o problema que ele resolveu?**

Nesse trabalho é apresentada uma abordagem para prever a preferência musical do usuário a partir das expressões faciais. Ela busca responder a seguinte questão: É possível inferir (implicitamente), em pares, as preferências musicais de um usuário, a partir de suas expressões faciais demonstradas, enquanto escuta suas músicas?

- **Quais técnicas foram usadas?**

A principal técnica utilizada para predição das músicas foi a de gerar um *score*, a partir da comparação par a par em cima das escolhas do usuário, nas opções de músicas apresentadas. Essa comparação foi realizada como: (i) um problema de regressão, onde eles predizem a pontuação numérica em pares; (ii) um problema de classificação, onde foi predito uma pontuação em pares como classe discreta alternativa (o usuário preferiu a da esquerda, direita ou ambas).

A recomendação gerada foi personalizada por usuário e não foi utilizado o modo colaborativo, mas foi demonstrado o interesse nos trabalhos futuros em adicionar ao RecSys esse modelo.

Para realizar a predição da música desejada, dada a expressão facial, foram experimentados diversos algoritmos, e no fim, foram utilizados os algoritmos *Random Forest* e *Gradient Boosting* por apresentarem os melhores resultados. Eles os escolheram, dado a principal base de predição, que foi, o uso do tempo em que os usuários escutaram as músicas e a diferença da duração entre duas músicas em par.

Para auxiliar no *score* em par, foi utilizado o *Spearman's Rank Correlation Coefficient* entre as diferentes durações (distribuições não normais). Isso é, quanto maior a diferença entre as duas músicas, maior a probabilidade de o usuário ter gostado da música que ele escutou por mais tempo. Para obter os resultados, foi realizada a comparação da precisão das preferências de predição dos modelos bases, utilizando *Root Mean Squared Error* (RMSE), precisão, *recall*, *F-measure* e acuracidade.

- **Qual a base de treinamento e teste?**

A base dessa pesquisa foi gerada através do uso em um ambiente controlado de uma aplicação desenvolvida. Foi utilizado um total de 75 usuários para utilizar a aplicação, com uma média de idade de 29,8 anos.

- **Quais os contextos utilizados?**

O principal contexto utilizado nesse trabalho foi relacionado às emoções dos usuários, obtidas através das expressões faciais dos usuários gravadas durante os testes realizados. No fim, foi apresentado um outro contexto comportamental, que é o tempo em que os usuários escutaram cada música. Não foi apresentado nenhum tipo de contexto de ambiente.

- **Como é obtido o contexto?**

Os dois contextos são obtidos enquanto o usuário está utilizando a aplicação de teste para reproduzir músicas. As emoções são obtidas a partir das expressões faciais produzidas, e o tempo que é gravado enquanto ele escuta cada música. Não é apresentado o contexto atual ao usuário, e não existe um formulário onde o usuário possa definir explicitamente o contexto.

A preferência do usuário foi obtida através da observação do seu comportamento em cima da aplicação. Cada usuário devia ouvir ao menos 10 segundos de cada uma das duas músicas apresentadas e ao finalizar, poderia escolher qual música era mais adequada para se ouvir no ambiente pré-estabelecido que era o seu trabalho.

- **A recomendação atingiu as expectativas do usuário?**

Para obter os resultados, foi realizada a comparação da precisão das preferências de predição dos modelos, utilizando *Root Mean Squared Error* (RMSE), precisão, *recall*, *F-measure* e acuracidade. A precisão, *recall* e *F-measure* foram calculadas, ponderando os *scores* de cada classe pelo número de instâncias verdadeiras de cada.

Para validar a qualidade da recomendação proposta, foi utilizado o tempo em que o usuário escutou cada música, pois, quanto maior a diferença entre as duas músicas, maior a probabilidade de o usuário ter gostado da música que ele ouviu por mais tempo. Outro critério apresentado foi a sua avaliação das músicas em par.

2.4.1.3 *Towards Intent-Aware Contextual Music Recommendation: Initial Experiments (VOLOKHIN; AGICHTEIN, 2018)*

O artigo apresenta técnicas e resultados que buscam estudar as intenções dos usuários ao buscar uma música para escutar, as quais são obtidas através do título e descrição das *playlists* reproduzidas. Para demonstrar as técnicas, foi realizado um estudo em cima da API do Spotify e Youtube. A partir desse estudo, são geradas *playlists* específicas para cada atividade relacionada às intenções dos usuários. E no fim é realizada uma avaliação comparativa dela com a gerada pelo método do Spotify (SPTF).

Para gerar as *playlists*, foi desenvolvido um método de recomendação chamado *Activity-aware Intent Recommendation (AIR)*, que usa a API do Spotify para obter suas melhores *playlist* relacionadas à busca, delas são obtidas as *top 10* músicas com melhores *scores*, as quais são incluídas nas recomendações futuras para cada atividade (Dirigir, Trabalhar, Cozinhar, ...).

- **Qual o problema que ele resolveu?**

São abordadas 3 contribuições no artigo: (i) é estimada uma distribuição empírica das intenções do ouvinte ao reproduzir um vídeo no Youtube; (ii) é realizado um experimento semelhante ao da primeira contribuição, porém utilizando o Spotify; (iii) são relatados os resultados iniciais obtidos, utilizando o modelo de intenções treinados para melhorar as recomendações. O modelo apresentado demonstra melhorias promissoras na recomendação de músicas através das intenções do usuário, ao invés de recomendações que dependem apenas de suas atividades.

- **Quais técnicas foram usadas?**

Dado o escopo desse trabalho, serão apresentadas somente as técnicas utilizadas nas recomendações de áudio. O artigo apresenta a especificação de um algoritmo que busca entender as intenções do usuário através dos títulos das *playlists*, disponibilizadas por ele. A pesquisa não utilizou da recomendação colaborativa.

As intenções foram obtidas através de diversos tipos de algoritmos de *machine learning* como: *Logistic Regression*, *Both Fuzzy* e *Hard Clustering*, mas os melhores resultados foram obtidos utilizando o *Random Forest Classifier* (utilizando a implementação do *sklearn*). Não foram apresentados os algoritmos utilizados para realizar a recomendação musical.

- **Qual a base de treinamento e teste?**

A base de intenções é montada a partir de testes realizados utilizando a API do Spotify em Python, em cima das *playlists* dispostas do usuário. Não é apresentada nenhuma aplicação desenvolvida para obter as bases.

- **Quais os contextos utilizados?**

Esse trabalho não busca entender o contexto em si. Ele apenas busca entender uma de suas características, que são as intenções do usuário, ao procurar por uma *playlist* e, a partir das intenções obtidas, procura gerar *playlists* relacionadas às atividades que o usuário está executando. O principal atributo utilizado para prever suas intenções é a descrição da *playlist* encontrada em sua busca.

- **Como é obtido o contexto?**

Para obter o comportamento do usuário foram avaliadas, durante um período de teste, as intenções dos usuários nas buscas por *playlists* e, a partir delas, foi gerada uma *playlist* de acordo com suas intenções. Esse comportamento é obtido de maneira implícita e o usuário não pode ajudar na definição do contexto. Não é apresentado ao usuário o contexto atual obtido através do seu comportamento.

- **A recomendação atingiu as expectativas do usuário?**

Para validar as recomendações do sistema, foi realizada uma comparação com o RecSys do Spotify (SPTF) e o criado no artigo revisado (AIR). Nessa comparação foi pedido ao usuário para avaliar as duas *playlists* geradas pelos sistemas. As *playlists* geradas automaticamente para cada uma das 10 atividades foram agrupadas. Depois foram avaliadas por 1-3 avaliadores humanos. A avaliação tem como objetivo validar o quanto a *playlist* se enquadrava na atividade estipulada.

A partir das avaliações realizadas, foram utilizadas 3 métricas para estimar a qualidade das recomendações feitas a partir dos coeficientes de correlação, elas são: (i) coeficiente de correlação de Kendall τ ; (ii) τ -AP para calcular a relevância das recomendações; (iii) uma variação do *Mean Reciprocal Rank* (nMMR). Essas métricas são importantes para avaliar numericamente a qualidade de cada *playlist* recomendada. Não é apresentado o tamanho da base utilizada nesse artigo.

2.4.1.4 *Quantitative Study of Music Listening Behavior in a Smartphone Context* (YANG; TENG, 2015)

O artigo revisado apresentou diversos resultados quantitativos, que foram obtidos através da classificação e computação dos dados de um aplicativo, o qual foi desenvolvido para reproduzir músicas e registrar o contexto de um usuário. Ele tem como principal objetivo responder as seguintes questões:

1. Em que medida podemos prever a música que um usuário prefere ouvir em diferentes contextos de atividade (ou seja, uso de música) da vida real?
2. Em que medida podemos prever a atividade de um usuário a partir dos dados do sensor coletados dos *smartphones*, em um contexto de um ouvinte musical da vida real?
3. Como fatores pessoais (dados demográficos, histórico musical, preferência musical de longo prazo e traços de personalidade) se correlacionam com a previsibilidade do uso de músicas e da atividade do usuário para diferentes usuários?

Cada pergunta investiga relações entre os fatores musicais, pessoais e situacionais da escuta musical. Especificamente é considerado um conjunto fechado de 8 tipos de atividades, atividades estas relacionadas a dados diários obtidos pelos 48 usuários durante um período de 3 semanas. O artigo não apresentou ou desenvolveu sistema de recomendação musical, porém, trouxe diversas informações pertinentes a esse trabalho.

- **Qual o problema que ele resolveu?**

Neste trabalho serão apresentadas diversas técnicas que buscam melhorar a recomendação personalizada, a partir de diversos dados obtidos por meio de sensores (implicitamente), ou através de perguntas realizadas ao usuário.

- **Quais técnicas foram usadas?**

Essa seção está dividida nas 3 questões que o artigo revisado busca resolver. Em nenhuma das questões é abordada a filtragem colaborativa.

- **Em que medida podemos prever a música que um usuário prefere ouvir em diferentes contextos de atividade (ou seja, uso de música) da vida real?**

Essa seção do trabalho teve como principal objetivo classificar (utilizando *auto-tagging*) a relação das preferências musicais x contextos dos usuários. Antes de iniciar essa

classificação, foi realizado um filtro na base gerada pelos usuários e aplicando certos critérios de qualidade sobraram 19 dos 48 usuários participantes do teste.

Baseado nos 19 usuários restantes, foi realizada a criação das *tags* do teste, que foram divididas em 2 esquemas de aprendizados: o personalizado e o geral. Os algoritmos considerados para essa classificação foram o linear e não linear, da *radial basis function* (RBF) e *support vector machine* (SVM). Dado os problemas com dados negativos nas classificações binárias, foi utilizada a técnica *EasyEnsemble* (mais especificamente a *Beta weights*) para neutralizar os dados.

Por fim, para medir a precisão das *tags* criadas, foi utilizado o *operating characteristic curve* (AUC), mais especificamente o *Pearson's linear correlation coefficient*. Buscando auxiliar a visualização da valência-excitação das emoções no espaço, foi utilizada a técnica de *Affective Norm for English Words* (ANEW). E no fim, para computar a associação entre as músicas e as emoções, foi feito uso do GPR (*Gaussian Process Regression*), mais especificamente o método *isotropic rational quadratic covariance kernel* implementado pelo *toolkit Gaussian Process for Machine Learning* (GPML).

Como a experiência da música é multidimensional, o artigo revisado busca extrair os atributos das músicas, e visa auxiliar o processo de classificação. Para isso, foram utilizados o *MIRtoolbox* e o *PsySound toolbox*, os quais conseguem extrair os atributos musicais.

- **Em que medida podemos prever a atividade de um usuário a partir dos dados do sensor coletados dos *smartphones* em um contexto de um ouvinte musical da vida real?**

O principal objetivo dessa seção do trabalho foi classificar as atividades dos usuários (*user-activity*) e relacionar às 8 atividades definidas com os dados obtidos dos sensores. Foram considerados os mesmos 19 usuários obtidos na filtragem apresentada na seção anterior.

A partir do aplicativo desenvolvido, foi possível obter os dados dos sensores utilizando o *Funf Open Sensing Framework*, e semelhante a classificação dos dados musicais com o contexto, para classificar as atividades dos usuários com os sensores foram utilizadas as técnicas de RBF e SVM.

- **Como fatores pessoais se correlacionam com a previsibilidade do uso de músicas e da atividade do usuário para diferentes usuários?**

Com os resultados obtidos nas seções anteriores, essa seção busca determinar quais fatores do usuário são fortes indicadores de desempenho das duas tarefas. Foram considerados os mesmos 19 usuários obtidos na filtragem apresentada na seção anterior.

Antes dos usuários passarem a utilizar o sistema, foram realizadas algumas perguntas a eles, validando e obtendo informações prévias deles. Nessa seção foi utilizado o *Pearson's linear correlation coefficient* e AUC para determinar quais fatores dos usuários são indicadores de desempenho das duas tarefas.

- **Qual a base de treinamento e teste?**

A partir do aplicativo desenvolvido, foram geradas uma base de treinamento e teste. Elas foram divididas em 3 partes, sendo elas: (i) relação música x contexto; (ii) relação dos sensores x atividades; (iii) e por último, os fatores extraídos dos usuários.

- **Quais os contextos utilizados?**

O trabalho revisado utiliza dos contextos comportamentais e de ambiente, e classificaram os fatores de uma preferência musical em 3 tipos (usuário, música e contexto). Eles são apresentados na Figura 7 abaixo.

Figura 7 - Fatores da preferência musical



Fonte: Elaborado pelo autor (2020)

- **Como é obtido o contexto?**

O contexto é obtido a partir do aplicativo desenvolvido, ele trouxe diversas informações sobre o dia a dia dos usuários, essas informações foram obtidas através de sensores e formulários que o usuário conseguia responder. Não é apresentado o contexto atual para o usuário.

- **A recomendação atingiu as expectativas do usuário?**

O artigo revisado não desenvolveu um sistema de recomendação, apenas disponibilizou diversos dados estatísticos que auxiliariam o desenvolvimento de um *RecSys*. Por isso, não foi definido nenhum critério de qualidade ou técnicas de avaliação das recomendações. A base foi obtida através do aplicativo desenvolvido nesse trabalho, ela continha 48 usuários, que a partir de uma filtragem dos dados efetuada, passou para 19 nas respostas das questões.

2.5 FUNCIONALIDADES DOS TRABALHOS INVESTIGADOS

O Quadro 1 apresenta a relação das funcionalidades dos 5 artigos revisados (2 indicados pelos avaliadores e 3 resultantes da revisão bibliográfica) e da proposta deste trabalho, focando em comparar apenas as funcionalidades utilizadas no desenvolvimento do

sistema de recomendação. O Quadro 1 apresenta a seguinte legenda de símbolos: ✓ caso possua, ✗ caso não possua.

Quadro 1 - Relação das funcionalidades desenvolvidas em cada artigo revisado

	(TKALČI Č et al., 2019)	(VOLOKHI N; AGICHTEIN, 2018)	(YANG ; TENG, 2015)	(ALIAG A, 2018)	(LUDEWI G et al., 2018)	Proposta deste trabalho
Tem foco no entendimento do contexto para recomendações musicais?	✓	✓	✗	✓	✗	✓
O trabalho foi/será validado em um caso real?	✗	✗	✓	✓	✓	✓
Utiliza do contexto comportamental ?	✓	✓	✓	✓	✗	✓
Utiliza do contexto de ambiente?	✗	✗	✓	✓	✗	✓
Utiliza do contexto explícito?	✗	✗	✓	✓	✗	✓
Utiliza do contexto implícito?	✓	✓	✓	✓	✗	✓
Utiliza do algoritmo K-	✗	✗	✗	✓	✓	✓

<i>Nearest Neighbors (KNN)</i> para classificação?						
Utiliza do algoritmo <i>Support Vector Machine (SVM)</i> para classificação?	✗	✓	✓	✗	✗	✗
Utiliza do algoritmo <i>Radial Basis Function (RBF)</i> para classificação?	✗	✗	✓	✗	✗	✗
Utiliza o algoritmo <i>Random Forest</i> para classificação?	✓	✗	✗	✗	✗	✗
Utiliza o algoritmo <i>Gradient Boosting</i> para classificação?	✓	✗	✗	✗	✗	✗

Fonte: Elaborado pelo autor (2020)

A definição dos algoritmos apresentados no Quadro 1, na coluna da proposta desse trabalho, foi atualizada a partir das conclusões apresentadas na capítulo 2.6. Onde é apresentado o algoritmo de classificação e o motivo da escolha.

2.6 CONCLUSÕES DOS TRABALHOS REVISADOS


Após a revisão dos 5 trabalhos estudados em relação a proposta deste trabalho, foi identificado que nenhum deles apresentou o algoritmo utilizado na recomendação. Foram apresentados algoritmos de classificação (*KNN*, *SVM*, *Random Forest*, etc.), métricas de avaliação de resultados (*AUC*, *Root Mean Squared Error*, *Mean Reciprocal Rank*, etc.), porém em nenhum momento foram apresentados os algoritmos de recomendação como *Matrix Factorization* (*SVD*, *Neighborhood SVD*, *Deep-Learning MF*, etc.) ou algoritmos de *Tensor Factorization* (*Tensor Decomposition*, *Nonnegative Tensor Factorization*, etc.), os quais são os algoritmos utilizados para realizar a recomendações nos *RecSys*.

Os algoritmos escolhidos para realizar a classificação foram os mais utilizados nos trabalhos, o *KNN* e *SVM*, os quais apareceram em 2 artigos. Porém o uso do *SVM* foi descartado, devido ao seu algoritmo tradicional estar mais voltado para a classificação de classes binárias (RÄTSCHE, 2004). Portanto, nesse trabalho escolheu-se usar o algoritmo *KNN*.

3 COLETA DO CONTEXTO DOS USUÁRIOS

A partir da revisão bibliográfica realizada, foi possível conhecer alguns sistemas e modelos que utilizam do contexto para realizar as recomendações musicais, tornando realizável entender certas lacunas que não foram analisadas nessa área de pesquisa e, no fim, desenvolvendo um sistema de recomendação chamado LORS (Loewe's Recommender System).

Figura 8 - Etapas do desenvolvimento do sistema de recomendação musical



Fonte: Elaborado pelo autor (2020)

LORS utiliza de uma análise recorrente do contexto, para realizar as recomendações. Esse algoritmo será apresentado com mais detalhes nas seções a seguir. Suas etapas de desenvolvimento são apresentadas na Figura 8.

3.1 CONTEXTO


Conforme o dicionário Michaelis (EDITORA MELHORAMENTOS LTDA, 2020), contexto pode ser definido por:

O conjunto de circunstâncias inter-relacionadas de cuja tessitura se depreende determinado fato ou situação; circunstância(s), conjuntura, situação.

Um sistema de recomendação busca encontrar os melhores itens para um devido fim, geralmente, baseado em dados históricos para a produzir. (DIETMAR et al., 2010) Observe-se que, com o entendimento do contexto, ou conforme a definição das “circunstâncias que levaram a certos fatos ou situações”, auxiliar as recomendações, aumentando o número de

dados disponíveis para realizar uma classificação e/ou filtro, já não é mais um problema. A Figura 9 apresenta uma visão macro dos contextos que serão considerados no projeto, os quais foram escolhidos por obterem mais votos no questionário que será apresentado na seção 3.2.

Figura 9 - Apresentação dos contextos estudados no trabalho



Fonte: Elaborado pelo autor (2020)

3.1.1 O que é o contexto comportamental?

Conforme o dicionário Michaelis (EDITORA MELHORAMENTOS LTDA, 2020), comportamento pode ser tido por:

Qualquer ação ou reação do organismo ou parte dele.

A partir da definição de contexto, surgiu um levantamento das possíveis ações a serem registradas em um sistema baseado no *app* Spotify, a fim de as colocar no questionário. Esse estudo trouxe a seguinte lista de ações:

- Passar / Voltar *n* músicas
- Escolher músicas preferidas
- Definir a atividade
- Definir o humor

3.1.2 O que é o contexto de ambiente?

Conforme o dicionário Michaelis (EDITORA MELHORAMENTOS LTDA, 2020), ambiente pode ser tido por:

Conjunto de condições físicas, biológicas e químicas que rodeiam os seres vivos e as coisas.

Pela citação acima, sucedeu-se pesquisas de sensores e informações que pudessem representar essas condições. A partir da análise dos contextos levantados, a análise expôs três possíveis contextos de ambiente a ser representados na aplicação, determinados por: (i) Localização; (ii) Clima e; (iii) Reprodução musical em grupo / individual. Com finalidade de explicitar o produto, o protótipo explorará apenas o serviço de localização.

3.1.3 Como serão obtidos os contextos?

Obter-se-á os contextos no *LORS* a partir da captura de formulários e eventos de um *webapp*, aplicados, por conjuntura, de duas maneiras: (i) explicitamente, para o usuário cadastrar o que está fazendo. Ex.: emoções, atividades e localização. (ii) implicitamente, adquirido através das ações do usuário realizadas no aplicativo como os componentes do *webapp*. Ex.: botão passar de música.

São poucas as ações que auxiliam no entendimento do contexto e que podem ser obtidas implicitamente, isso devido às limitações dos sensores e dados disponíveis na aplicação desenvolvida. Por isso, o sistema deste trabalho contará com informações dispostas de maneira explícita e implícita, sendo elas:

- **Informações adquiridas de maneira implícita:**
 - localização
 - ações sobre os componentes do *webapp*
 - tempo
 - músicas preferidas

- **Informações adquiridas de maneira explícita:**
 - localização
 - humor
 - atividade
 - músicas preferidas

Os dados de localização implícitos são os de latitude e longitude do usuário; eles foram salvos na aplicação - devido ao tempo limitado para o desenvolvimento, o dado não foi utilizado. Logo, o tempo implícito é a data e hora do evento, registrado para, no futuro, poder ser aplicado um modelo sequencial junto ao KNN.

3.1.4 O que são as ações do usuário?

As ações do usuário trazem diversas informações referentes ao que ele está vivendo (auxiliando o entendimento do seu ambiente e a validação da acuracidade das recomendações feitas, por exemplo). São elas que demonstrarão ao sistema, através das músicas recomendadas, o gosto do usuário, se são de um determinado estilo musical ou de outro. Cada ação terá um nível de importância, a qual será obtida pelas respostas do questionário. As possíveis ações a serem executadas pelo usuário estão listadas na seção 3.1.1.

3.2 PESQUISA COM USUÁRIOS SOBRE RECOMENDAÇÃO MUSICAL (QUESTIONÁRIO)

Criou-se um questionário com perguntas expostas que permitiram conhecer melhor os usuários que utilizarão a aplicação. Sendo assim, todas as questões permitem entender suas preferências, atividades, dentre outros fatores. As perguntas do questionário estão listadas no Quadro 2:

Quadro 2 - Perguntas e respostas disponibilizadas a um certo público através dos formulários do Google.

Pergunta	Possíveis respostas
1. Qual o aplicativo / reprodutor de música você utiliza atualmente?	Spotify, Deezer, Youtube Music, TIDAL, Apple Music, Google Play Music, Rádio Outro, qual?
2. Você acha que as recomendações musicais realizadas via software poderiam ser melhoradas?	Sim, não
3. Você acredita que o contexto poderia melhorar essas recomendações?	Sim, não
4. Em quais atividades você costuma ouvir música?	Acordando, Assistindo a filmes / séries / novelas, Comendo, Correndo, Dirigindo, Estudando, Jogando, Lazer, Lendo, Indo dormir, Passeando, Praticando exercícios, Trabalhando, Treinando, Outro, qual?
5. Em quais lugares você costuma ouvir	Academia, Bar, Biblioteca, Casa, Com os

músicas?	amigos, Escola, Festa, Praia, Restaurante, Trabalho, Outro, qual?
6. Você costuma ouvir música quando está:	Aborrecido, Alegre, Amoroso, Ansioso, Apavorado, Assustado, Constrangido, Culpado, Deprimido, Desapontado, Excitado, Envergonhado, Em pânico, Feliz, Frustrado, Furioso, Inseguro, Irado, Irritado, Humilhado, Magoado, Nervoso, Orgulhoso, Triste, Zangado, Outro, qual?
7. O que costuma te influenciar na escolha da música?	Atividades, Clima, Grupo / Individual, Horário do dia, Humor, Localização, Outro, Qual?
8. O que você faz quando gosta ou não de uma música?	Abrir / Fechar o app, Aumentar / Abaixar volume, Definir tempo da música, Escolher música / artista / gênero, Pausar / Tocar música, Passar / Voltar n músicas, Outra, qual?
9. As músicas que você escuta sozinho são diferentes das que escuta com os amigos?	Sim, não
10. Quanto tempo por semana você escuta música?	Menos que 5 horas, de 5 a 10 horas, de 11 a 30 horas, de 31 a 50 horas, mais que 50 horas
11. Quais são os gêneros musicais que gosta de escutar?	Alternativa, Blues, Clássica, Country, Dance, Eletrônica, Folk, Funk, Hip Hop, Latina, MPB, Jazz, Pop, Reggae, R&B, Rock, Soundtrack, Vocal
12. Gostaria de participar de uma pesquisa que visa melhorar a recomendação musical?	Sim, não
13. Sua idade	
14. Dicas e sugestões?	

Fonte: Elaborado pelo autor (2020)

3.2.1 Pré-teste do questionário

Com as perguntas do questionário definidas, deu-se o início de uma validação para garantir que elas fizessem sentido. O pré-teste foi feito enviando as indagações para 5 pessoas, responsáveis por analisar as inquirições e avaliar a dificuldade de entendimento de cada uma delas. O intuito é garantir que o público que recebesse o questionário posteriormente - o qual não está dentro do contexto do trabalho - também conseguisse responder as perguntas com a completa compreensão delas. As melhorias levantadas foram referentes a utilizar uma linguagem mais simples nas perguntas e respostas, explicar o que é contexto e melhorar a descrição do questionário.

3.2.2 Resultados do questionário

Com um alcance maior do que 1000 pessoas, sendo 800 funcionários da CWI, que possuem acesso ao Slack, 200 pessoas alcançadas através do Instagram e demais divulgações que tiveram, o questionário teve uma adesão de 222 respostas. O público respondente tinha entre 14 e 71 anos e um gosto musical bem diversificado, foram obtidos em torno de 60 estilos musicais, sendo o mais votado o Rock, com 181 marcações.

O questionário foi aberto no dia 6 de julho de 2020, no mesmo dia que, publicado no Instagram, fora demonstrado ao público. No decorrer de duas semanas, outras redes sociais participaram da pesquisa, como WhatsApp, Slack (empresarial), Twitter e Facebook. O seu fechamento aconteceu no dia 18 de julho de 2020, somando o total de 12 dias em que o ele ficou aberto.²

Dos dispositivos (ou aplicativos) utilizados para realizar a reprodução das músicas, com 168 respostas, o Spotify foi o mais escolhido das opções. Em segundo lugar ficou o Youtube com 103 respostas (variadas entre 86 no Youtube Music, e 17 tratando sobre o Youtube clássico).

A pergunta “Você acha que as recomendações musicais realizadas via software poderiam ser melhoradas?” trouxe uma visão clara sobre o espaço para esse trabalho evoluir nas técnicas de recomendação musical. Enquanto aquela que dizia “Você acredita que o contexto poderia melhorar essas recomendações?” mostrou se havia lugar nesse contexto do usuário para evoluir tais técnicas. Com 95% para a primeira e 96% para a segunda pergunta

² Link para as respostas do questionário: <https://forms.gle/FKW5iJBhT7oEa18eA>

de respostas marcadas como “sim”, foi possível verificar que esse trabalho pode agregar qualidade às recomendações musicais, segundo a opinião dos respondentes.

Para aperfeiçoar a visão do trabalho das características de maior importância, usou-se três indagações, que são: “Em quais atividades você costuma ouvir música?”, “Em quais lugares você costuma ouvir músicas?” e “Você costuma ouvir música quando está?”. Com elas, apareceram novas características (a partir do campo “outro”), como “Tomando banho”, obteve-se características que mais influenciam os usuários na escolha de uma música, como “Trabalhando”, a atividade mais votada com 74%.

Visando entender o comportamento do público, as questões “O que costuma te influenciar na escolha da música?” e “O que você faz quando gosta ou não de uma música?” foram importantíssimas. Dessa maneira, não há tanta dificuldade em compreender as características mais importantes a serem consideradas no algoritmo e ordem da aplicação, isso é, Humor e Atividades, as quais estão presentes no questionário do *plugin*.

A pergunta “As músicas que você escuta sozinho são diferentes das que escuta com os amigos?” foi desenvolvida para realizar uma avaliação se a *feature* “amigos ou sozinho” seria desenvolvida. Devido ao tempo disponível para desenvolvimento, ela acabou não sendo utilizada.

Para obter um conhecimento da intensidade musical do público que lidamos relacionada ao tempo (estritamente necessário), compôs-se de “Quanto tempo por semana você escuta música?”. Deu para entender que não era um público intenso; nas respostas, mais de 50% ouvia de 0 a 10 horas por semana.

Um Cold Start³ precisaria ser construído na aplicação. Então, “Quais são os gêneros musicais que gosta de escutar?” seria a melhor opção, caso o objetivo seja colocar as principais respostas ao *plugin*. A *feature* será desenvolvida nos desenvolvimentos futuros do projeto.

Respeitando a privacidade do público, foi feita a pergunta “Gostaria de participar de uma pesquisa que visa melhorar a recomendação musical?”, filtrando assim, somente os usuários que aceitaram enviar o convite para participar do *plugin*.

A pergunta “Sua idade” foi feita para obter conhecimento da faixa de idade da aplicação e, assim, desenvolver as facilidades visuais necessárias conforme a idade. Durante o envio do questionário, o escopo do trabalho estava em aberto - por isso, a pergunta “Dicas e sugestões?”. Assim, obteve-se ideias do público para aplicar no trabalho, como a resposta

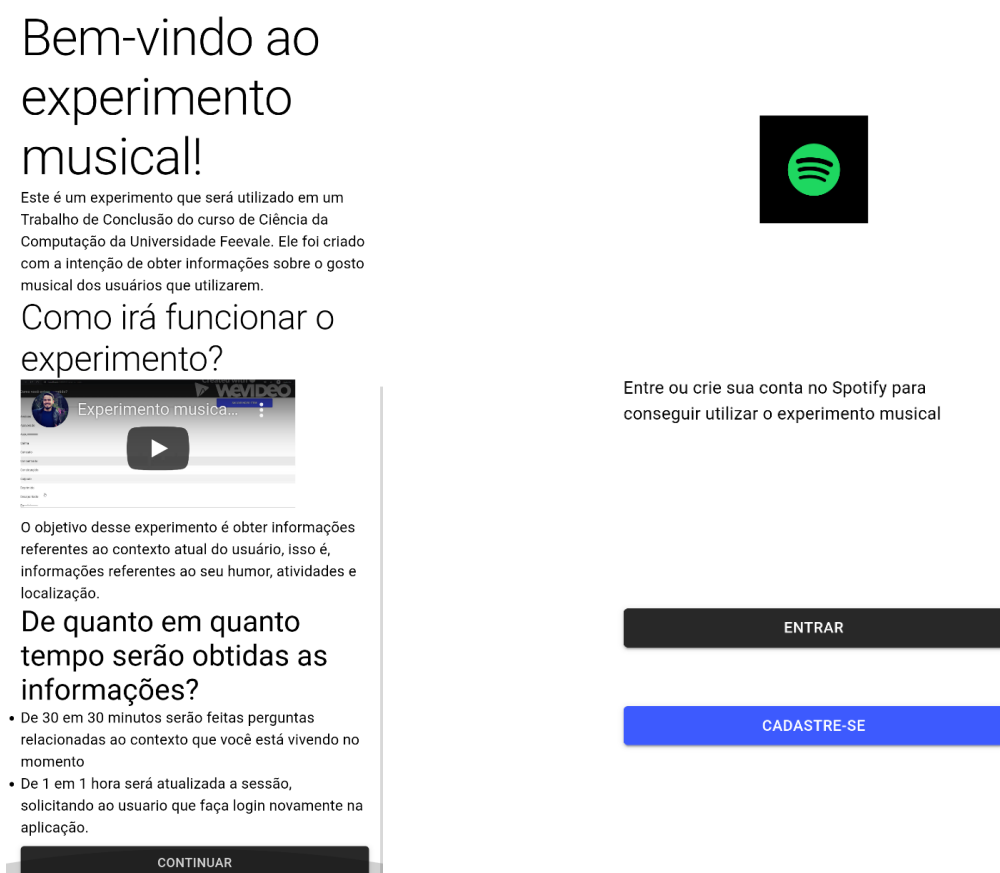
³ Problema relacionado a falta de dados em um RecSys

“Opções de respostas meio confusas” que ao recebê-la, entrou-se em contato para retirar a dúvida e aperfeiçoar o questionário.

3.3 DESENVOLVIMENTO DO PLUGIN

Para obter os dados dos usuários, o projeto apresenta uma aplicação web⁴ que utilizava do SDK Web do Spotify para reprodução das músicas e captura dos eventos gerados pelo usuário. Para utilizá-la, o usuário poderia escolher suas músicas na aplicação do Spotify, adicioná-las a lista de reprodução e então ela tocá-las na aplicação. Onde é salvo os eventos do *player*, gosto e desgosto da música em reprodução.

Figura 10 - A esquerda, tela introdutória da aplicação. A direita, tela de login da aplicação



Fonte: Elaborado pelo autor (2020)

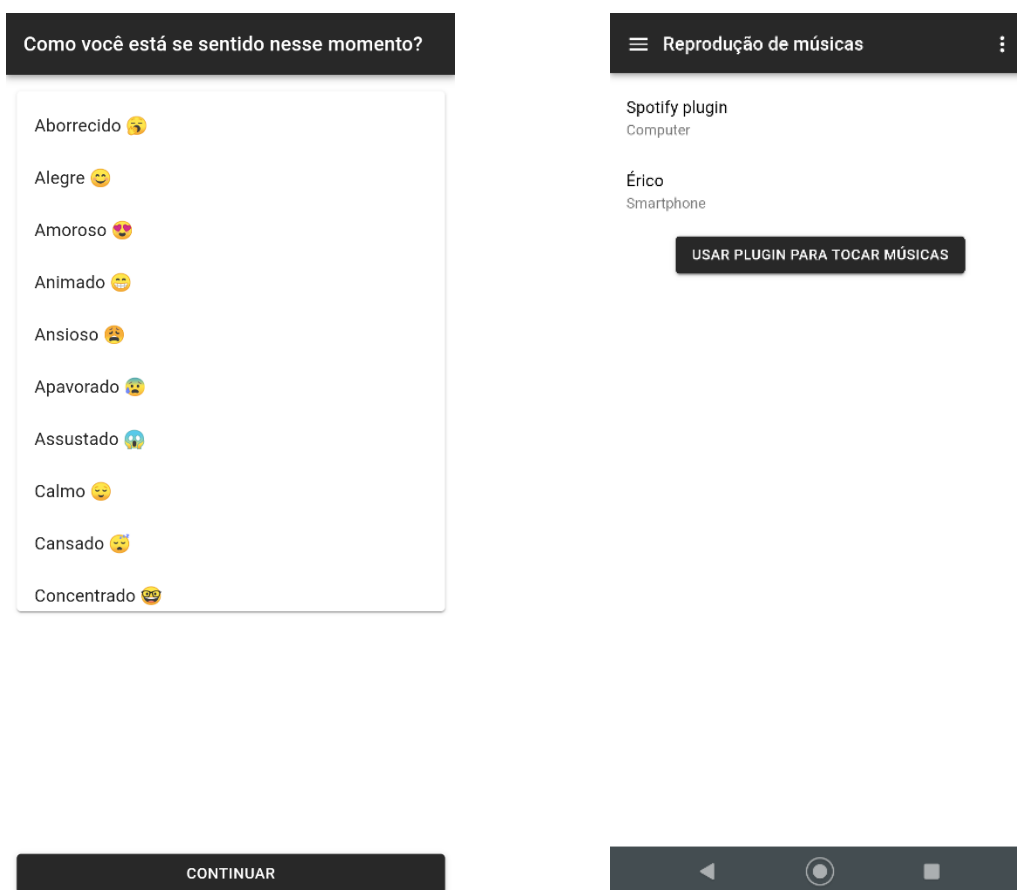
⁴ Disponível em: <https://ericoloewe.github.io/computer-science-tcc/>

3.3.1 Telas da aplicação (*plugin*)

A aplicação é dividida em 5 telas, iniciada na Figura 10 a esquerda, a qual apresenta instruções para os usuários de como utilizar a aplicação e terminada na segunda tela. É representada pela Figura 10 a direita, disponibilizando opções de login no Spotify.

A Figura 11 a esquerda apresenta o cadastro do contexto na aplicação. O processo é dividido em três etapas: (i) “Como você está se sentindo nesse momento?”; (ii) “O que você está fazendo nesse momento?”; (iii) “Onde você está nesse momento?”. Essas perguntas tornaram realizável entender o contexto atual do usuário naquele período por serem solicitadas a cada 30min.

Figura 11 - A esquerda, tela de preenchimento do contexto. A direita, tela da lista de dispositivos do Spotify



Fonte: Elaborado pelo autor (2020)

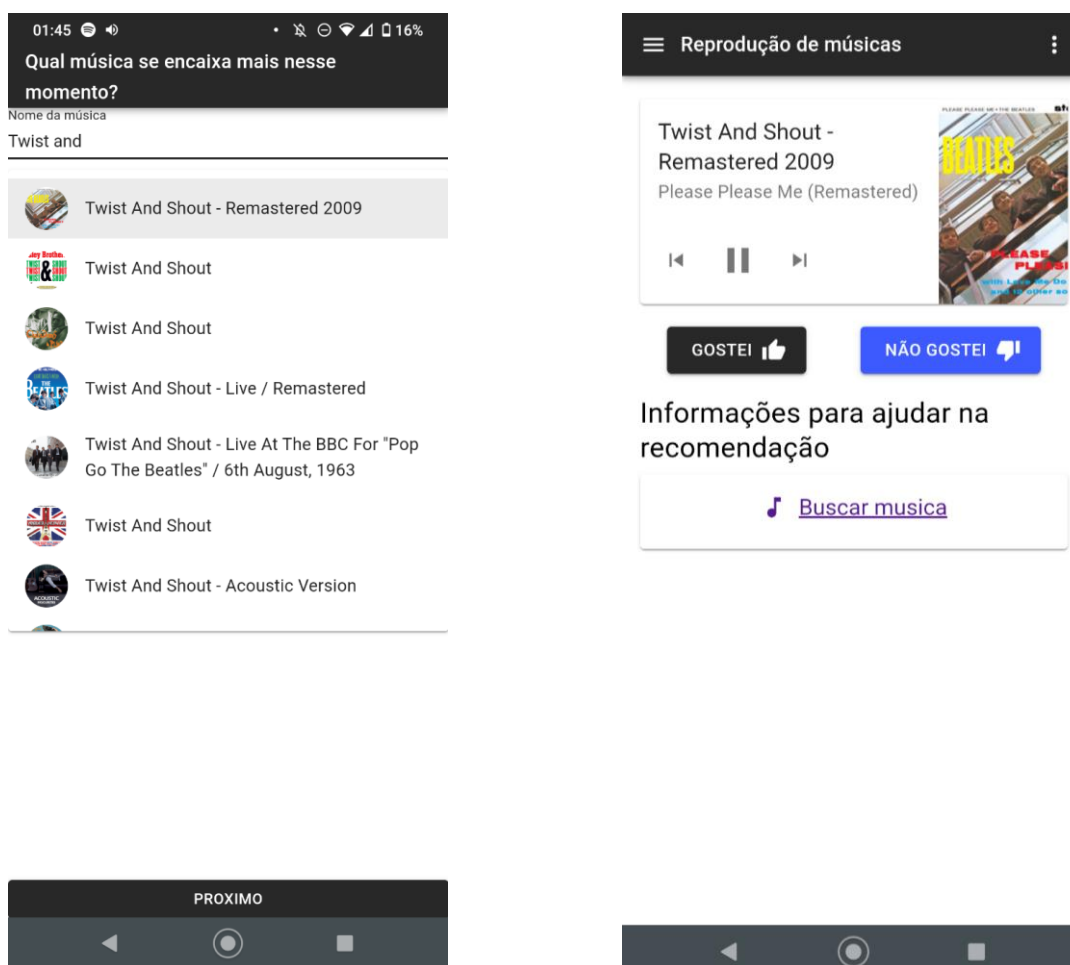
Para realizar a reprodução musical, é necessário exigir do Spotify que reproduza as músicas no *plugin*. Tendo isso em mente, foi criada a tela apresentada na Figura 11 a direita, contando com um botão “USAR PLUGIN PARA TOCAR MÚSICAS” que, ao ser pressionado, habilita a reprodução no *plugin*.

Por fim, a Figura 12 a esquerda apresenta a tela principal suscitada. Nela, é realizado toda a interação do usuário no período em que ele está ouvindo as músicas; as possíveis interações estão listadas abaixo.

- Gostar da música
- Não gostar da música
- Passar / Voltar música
- Buscar música
- Pausar / Tocar música

Ao clicar no botão “gostei”, é salvo a informação de que o usuário gostou da música naquele contexto, assim como no oposto. “não gostei” faria o programa entender que a pessoa possuidora do produto, a que tivesse a conta, não apreciou aquele determinado estilo musical no contexto em si. Ele seria levado à tela de busca de música (Figura 12 a direita), para apresentar uma música que se identifique melhor com o momento.

Figura 12 - A esquerda, tela principal, a qual apresenta a música sendo reproduzida ao usuário. A direita, tela de busca de músicas que encaixem melhor no momento



Fonte: Elaborado pelo autor (2020)

A ação de buscar música, de ter a opção em relação a um tempo específico, o levaria para a tela apresentada na Figura 12 a direta, possibilitando o cliente a apresentar uma música que se enquadre ao melhor conteúdo musical de acordo com seu contexto. Ao selecionar as composições e clicar em próximo, é salvo as informações de sua relação.

3.3.2 Tecnologias utilizadas no desenvolvimento

Para desenvolver a aplicação web, utilizou-se a biblioteca *React* como auxílio na construção de componentes e interfaces. Com o desígnio de estilizar os componentes e páginas do React, houve a necessidade do *framework* Material ui, por estilos prontos baseados no Material (interface do Android) que possuía.

O Google Analytics (uma ferramenta específica para eventos) serviria como mecanismo para persistir os eventos do usuário. Devido à falta de customização dele, achou-se plausível o substituir pelo *Realtime Database* do Firebase (*Realtime DB*), tendo a vantagem de uma vasta opção de customização, o que tornaria a adição do *timestamp* a cada evento uma opção. Com ela foi possível persistir os eventos em um formato NoSQL (*Not Only SQL*).

No início, a fim de enviar o evento à plataforma, o programa contou com o GTM (Google Tag Manager) para fazer esse intermédio. Porém, por causa de algumas limitações da ferramenta, deixou-se de ter tal dependência. Foram enviados os eventos diretamente do *Javascript*.

3.4 DISTRIBUIÇÃO DA APLICAÇÃO E COLETA DE DADOS

A aplicação esteve disponibilizada, do dia 28/09 até 02/10, através de um e-mail com instruções de como utilizar a aplicação, enviado para os 144 usuários que participaram do questionário e optaram por participar da pesquisa. Assim, ela irá salvar os dados que serão utilizados como teste na classificação desenvolvida nesse trabalho.

3.4.1 Pré-teste

Com a aplicação finalizada e hospedada, o protótipo chegou às mãos do professor orientador para validar o desenvolvimento feito. Nos testes produzidos, certos ajustes precisaram ser feitos antes de divulgar a aplicação. Corrigido a aplicação, cinco pessoas testaram novamente, encontrando mais pontos a corrigir. Enviado o e-mail a um grupo

supervisionado de 8 pessoas, para validar sua aceitação e entendimento do funcionamento da aplicação, pôde-se ter uma verificação do que era e do que poderia ser o *plugin*. Por fim, o e-mail foi enviado para a base completa de usuários optantes por participar do teste.

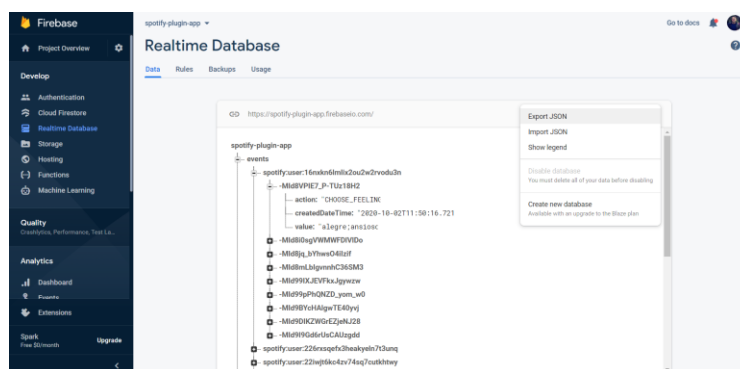
3.4.2 Hospedagem

A aplicação⁵ - publicada na ferramenta disponível no Github chamada *Github Pages* - é gratuita, e possibilita a publicação de páginas estáticas. Os eventos das músicas foram salvos em outra plataforma chamada Firebase, que é pago; nesse trabalho, está na versão gratuita, que suporta o acesso de até 100 usuários simultâneos. Ademais, eventos como “quantidade de usuários acessando o *webapp*” foram salvos utilizando as aplicações GTM e Google Analytics.

3.4.3 Coleta do Firebase

Ao final do experimento, foram exportados os eventos dos usuários em um JSON através do console do *Realtime Database* do Firebase. A Figura 13 apresenta o console, a estrutura de dados dos eventos e o botão de exportar do *Realtime DB*.

Figura 13 - Console do Realtime Database do Firebase



Fonte: Elaborado pelo autor (2020)

Com o JSON e a estrutura de dados pronta, datou-se o início de alguns estudos em *python* para adquirir o conhecimento necessário e obter os dados necessários do Spotify, rodando assim, o algoritmo KNN nos dados obtidos. Os primeiros testes do algoritmo KNN utilizaram a base de íris disponível no *sklearn*. Após obter o conhecimento do funcionamento do algoritmo no *python*, foi aplicado o mesmo sobre a base extraída e preparada do JSON.

⁵ Link de acesso a aplicação: <https://ericoloewe.github.io/computer-science-tcc/>

Após ser feito a exportação dos dados do Firebase no formato JSON, foi realizado um levantamento dos dados obtidos, chegando então no Quadro 3. Onde é apresentado uma relação dos usuários com o número de eventos registrados no uso da aplicação.

Quadro 3 Número de eventos registrados por usuário

Spotify Id	Número de eventos registrados
16nxkn6lmlix2ou2w2rvodu3n	9
226rxsqefx3heakyeln7t3unq	27
22iwjt6kc4zv74sq7cutkhtwy	9
3152wu7mz2aoxfrg5mtqov77lseu	19
31bfdxg5fe2335adqfcg4xpugpcq	10
3ka2awymoso1wgdlwuq50uz8h	16
4i3jdhv6vubcjdpswn38iv8u4	376
8q3uk0rwypu5r7dsq48476qak	5
andressltz	162
b8r2mhyhep5t0np1keaqmvi0	20
gabrielcartelli	3
ggkonzen	12
iisa1999	326
iortim	174
jyangalonga	229
maiconunzer	7
o16tnkq56zdt2obwii1vgbs4o	5
tiagoterme	65

Fonte: Elaborado pelo autor (2020)

Devido a uma restrição do SDK do Spotify para somente usuários premium, houve uma baixa aceitação da aplicação. De 144 pessoas que optaram por participar da pesquisa do plugin, apenas 18 delas realmente utilizaram a aplicação. Devido a um curto período de utilização, obteve-se um número de registros relativamente baixo. Onde com 376 eventos, o usuário que mais apresentou 4i3jdhv6vubcjdpswn38iv8u4, foi escolhido para realizar os testes do RecSys apresentados no próximo capítulo.


4 SISTEMA LORS

Com a estrutura dos dados pronta e a pesquisa dos dados dos usuários, levantou-se um tratamento específico para cada informação, realizando, dessa forma, o estudo da técnica de recomendação escolhida nos trabalhos anteriores, o KNN. Com isso, surgiu o algoritmo do sistema LORS, que utiliza de uma análise recorrente do contexto, para realizar as recomendações dinâmicas às mudanças do contexto. Serão apresentadas mais informações das etapas de modelagem e desenvolvimento do sistema nas seções a seguir.

4.1 O ALGORITMO KNN

O *k-Nearest Neighbor* (KNN) é um método de classificação, seu algoritmo de aprendizado supervisionado foi introduzido por AHA; KIBLER; ALBERT, 1991. Ele busca os k pontos dos dados de treino mais próximos do item de teste. Uma classe é atrelada a esse ponto através de uma votação majoritária dos k pontos vizinhos. Na Figura 14 é exemplificado graficamente o funcionamento do algoritmo.

Figura 14 - Representação gráfica da classificação do algoritmo KNN sobre um plano x_1 e x_2 . No plano, os pontos amarelos são a representação da classe A, roxos classe B e vermelho é o ponto de teste



Fonte: (JOSÉ, 2018)

Como apresentado (Figura 14), o algoritmo funciona mediante a disposição das características (atributos) X_1 e X_2 sobre um plano, atribuindo classes a eles (no caso: classe A e classe B). Então, a partir da predição do ponto de teste, baseado na distância deste para os demais k pontos, é encontrado a classe que o representa. Para rodar o algoritmo de

classificação KNN nesse trabalho foi utilizada a implementação da biblioteca em *python* do *scikit-learn* encontrada na classe *KNeighborsClassifier* do módulo *sklearn.neighbors* (PEDREGOSA et al., 2011).

4.1.1 Preparação dos dados para o KNN

Planejando salvar os eventos da aplicação, uma lista chamada *events*, composta pelo catálogo de usuários, onde cada usuário possui uma lista de eventos dentro, teve sua concepção. Cada evento é composto pela seguinte estrutura: (i) *action*, ação realizada pelo usuário, apresentadas no Quadro 4; (ii) *createdDateTime*, data e tempo da execução do evento; (iii) *value*, valores do evento separados por “;”.

A ação *LOAD_LOCATION* foi ignorada nesse momento, ela se trata de dados de geolocalização e nesse momento, devido à falta de recursos, não foi preparado esse dado para o KNN abrindo oportunidades para um trabalho futuro. Já as ações *CHANGE_MUSIC_TIME*, *CHOOSE_FEELING_TO_BE_LIKE*, *LIKED_ARTIST*, *LIKED_GENRE*, ficaram nos eventos do *plugin*, mesmo que não sejam utilizadas devido ao tempo limitado de desenvolvimento. As ações *HIDE_DETAILS*, *PAUSE_MUSIC*, *PLAY_MUSIC*, *SHOW_DETAILS* são contabilizadas como registro do contexto musical, contudo não foram utilizadas no algoritmo devido ao tempo de desenvolvimento. Demais ações são contabilizadas e apresentadas no Quadro 4.

Quadro 4 - Lista de ações possíveis nos eventos

Ação (Action)	Descrição
<i>CHANGE_MUSIC_TIME</i>	Altera o tempo da música durante a reprodução
<i>CHANGE_TO_NEXT_MUSIC</i>	Passa para próxima música da lista
<i>CHANGE_TO_PREVIOUS_MUSIC</i>	Volta para música anterior da lista
<i>CHOOSE_ACTIVITY</i>	Registro da atividade
<i>CHOOSE_FEELING</i>	Registro do humor atual
<i>CHOOSE_FEELING_TO_BE_LIKE</i>	Registro do humor que gostaria de estar
<i>CHOOSE_LOCATION</i>	Registro da localização
<i>HATED_MUSIC</i>	Não gostou da música que está tocando
<i>HIDE_DETAILS</i>	Escondeu os detalhes da música (plugin)

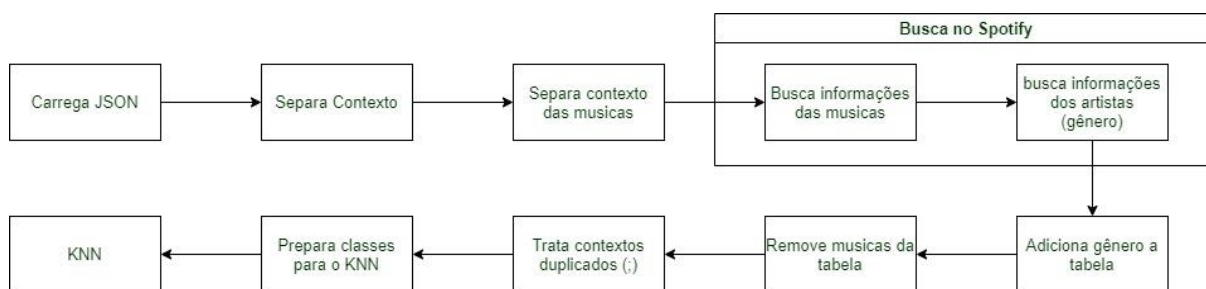
LIKED_ARTIST	Gostou do artista
LIKED_GENRE	Gostou do gênero
LIKED_MUSIC	Gostou da música
LOAD_LOCATION	Carregou a localização (latitude, longitude)
PAUSE_MUSIC	Pausou a música
PLAY_MUSIC	Tocou a música
RESTART_MUSIC	Reiniciou a música
SHOW_DETAILS	Abriu os detalhes da música

Fonte: Elaborado pelo autor (2020)

Salvou-se o *timestamp* do navegador no campo *createdDateTime* durante a criação do evento. Esse dado poderá ser utilizado em trabalhos futuros buscando melhorias nas recomendações através de uma leitura em sequência.

A Figura 15 apresenta as etapas de preparação dos dados, desde o carregamento do arquivo exportado do Firebase, que contém as informações dos eventos, até a execução do algoritmo KNN. É na etapa “Carrega JSON” que se tem o *upload* dos dados a partir da biblioteca padrão do *python* “open”. Para a interpretação do arquivo JSON, existe a biblioteca *json*, que carrega os dados em um dicionário, do qual obtém os usuários e seus eventos e os transforma em outro dicionário *users*, cuja *key* é o id do usuário e o conteúdo sua lista de eventos.


Figura 15 - Visão macro das etapas para transformar os eventos registrados no firebase na tabela que sera rodado o KNN



Fonte: Elaborado pelo autor (2020)

Na segunda etapa “Separa Contexto”, representada pela Figura 16, é realizada a quebra dos eventos de cada usuário por seus contextos, criando assim, uma relação com as músicas reproduzidas. Isso está representado na Figura 17.

Figura 16 - Representação dos eventos salvos no Firebase



Fonte: Elaborado pelo autor (2020)

A Figura 18 traz a etapa “Separa contexto das músicas”. Na reprodução das músicas, são gerados tanto os eventos separadamente, quanto uma relação da música escutada, com os eventos registrados - gerando, no fim, uma tabela semelhante à Figura 19 das músicas e seus contextos.


Figura 17 - Representação das listas geradas na etapa “Separa contexto”



Fonte: Elaborado pelo autor (2020)

Visando uma relação, é realizado um loop em cima dos eventos de cada contexto, criando uma lista chamada *musicTable*. Tal, é preenchida dos seguintes valores: *uri*, *like*, *hate* e *restart*, relacionados ao contexto da música, e *feeling*, *activity* e *location*, e relacionados ao contexto do usuário. Ademais, os termos *like*, *hate* e *restart* são representados pelo número de vezes que cada evento desse tipo aconteceu durante a reprodução.

Figura 18 - Representação das listas geradas na etapa “separa contexto das músicas”



Fonte: Elaborado pelo autor (2020)

Nas duas etapas seguintes (“busca informações das músicas” e “busca informações dos artistas (gênero)”), direcioná-lo-ia, o cliente, a uma busca nas APIs do Spotify, utilizando os *uris* da música e artistas, a fim de obter os gêneros musicais. O resultado dela é um dicionário chamado *artistsMap* relacionando os *uris* com os dados de cada artista. Devido a uma limitação do Spotify, a busca se fará de 50 em 50 *uris*.

Figura 19 - Representação da tabela na etapa “separa contexto das músicas”

	Contexto			Contexto musical			
	Sentimento	Atividade	Lugar	Gostei	Não gostei	Repetiu	Pausou
Musica 1	Feliz	Estudando	Casa	Sim	-	Sim	-
Musica 2	Feliz	Estudando	Casa	Sim	-	-	-
Musica 3	Feliz	Estudando	Casa	-	Sim	-	Sim
Musica 1	Triste	Trabalhando	Trabalho	-	Sim	-	-
Musica N

Fonte: Elaborado pelo autor (2020)

Os dados no Spotify, nos seus devidos processos, obtiveram a lista dos gêneros das músicas através dos artistas. A posteriori, adiciona-o à lista de músicas *musicTable* representada na Figura 19. Foram separados os gêneros, um por linha e, no fim, removida a música, pois ela iria atrapalhar o resultado do algoritmo. Com isso, surgiu, propositalmente, a lista *genreTable*, deixando, assim, o *musicTable* em desuso.

Gozando da completude da tabela, principiou um tratamento dos valores dos eventos que eram múltiplos. Tais continham mais de uma informação nos mesmos eventos, através do

“;” ou possuíam uma quantidade maior do que 1 nos campos de *like*, *hate* e *restart*. Nesse tratamento, foi quebrado os valores dos eventos um a um em mais linhas. Um exemplo do uso do “;” é o caso de um *feeling* conter o valor “feliz;triste”, que foi transformado em duas linhas, uma para “feliz”, outra para “triste”. Um exemplo do campo *like*, no caso de possuir o valor 3, é quebrado o evento em 3 linhas e trocado por 1.

Figura 20 - *head()* do *dataframe* criado a partir da variável *genreTable*

	like	hate	restart	feeling	activity	location	genre
0	1	0	0	1	3	1	contemporary country
1	1	0	0	10	3	1	contemporary country
2	1	0	0	1	3	1	country
3	1	0	0	10	3	1	country
4	1	0	0	1	3	1	country road

Fonte: Elaborado pelo autor (2020)

No fim, era necessário a biblioteca *preprocessing* do *sklearn*, caso quisesse transformar as características e classes de cada evento da tabela em números inteiros; isso é necessário para rodar o algoritmo KNN. O resultado da tabela é apresentado na Figura 20.

4.1.2 Testes com KNN

No final, o *genreTable*, convertido em um *data frame* da biblioteca *pandas*, sofreu certa separação da coluna gênero da tabela, obtendo variáveis de X (características) e y (classes). As duas são utilizadas na função *train_test_split*, adquirindo, tanto características de treino (*X_train*) e de teste (*X_test*), quanto classes de treino e teste (*y_train*, *y_test*). O tamanho da base de teste pode ser informado para o *train_test_split* através do parâmetro *test_size* que, nesse caso, foi de 0,3 (30% de teste e 70% de treinamento, respectivamente 533 e 1242).

A classe *KNeighborsClassifier* da biblioteca *sklearn.neighbors* serviu de base para o êxito no funcionamento do KNN. Nela, pode ser informado o número de vizinhos levados em consideração a partir do parâmetro *n_neighbors* que nesse caso foi decidido através de testes para descobrir o melhor *k*, resultando em 9, com menor erro de classificação (MSE) de 0.572475.

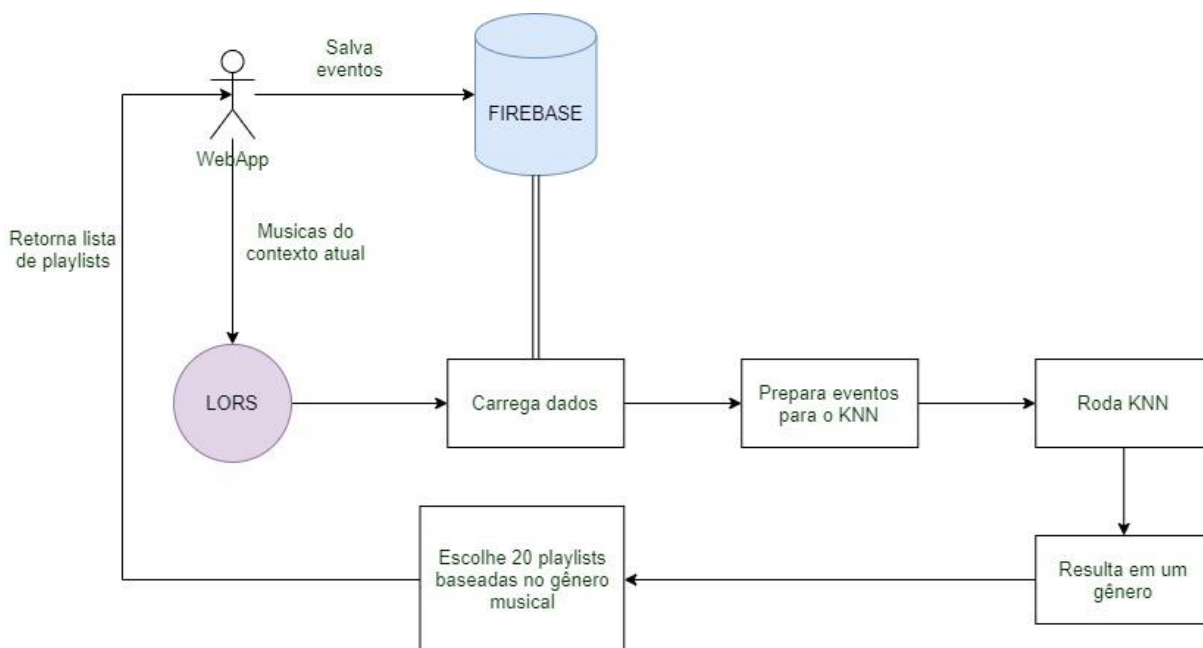
Iniciando a classe, obtemos a variável *model*. Com ela, põe-se os dados de treino (X_{train} , y_{train}) através do método *fit*, de modo que suporte dois parâmetros: (i) dados de treino; (ii) valores alvo. Assim sendo, já é iminente utilizar o melhor k analisado (9), para prever os próximos alvos que, no *sklearn*, é rodado através do método *predict*. Ele transfere os valores para realizar a predição (X_{test}), que tem como retorno a classe que se adequa melhor aos dados de teste.

Em suma, um teste, efetuado através do método *score* na performance da predição do algoritmo KNN e da base informada ao *sklearn*, recebeu por parâmetro suas características, retiradas de X_{test} e classes, retiradas de y_{test} e retornaram à acurácia do algoritmo KNN. Os resultados do teste são apresentados na seção 0.

4.2 PREDIÇÃO NO SISTEMA LORS

O sistema LORS, desenvolvido para, através do conhecimento do contexto dos usuários, aperfeiçoar as recomendações musicais do Spotify, é realizada a predição do gênero musical baseando-se no contexto e o histórico de músicas reproduzidas. O resultado correspondente passa a ser entregue através de uma API, podendo ser consumida por qualquer usuário que utilize o *plugin Web* desenvolvido nesse trabalho.

Figura 21 - Visão macro do sistema LORS



Fonte: Elaborado pelo autor (2020)

O *plugin* (representado na Figura 21 como o “WebApp”) é responsável por, a cada 30 minutos, solicitar ao usuário uma atualização de contexto, isso é, abrir um formulário. Dessa forma, ele possibilita o preenchimento do humor, atividades e localização atual do usuário. As informações são salvas e relacionadas às próximas músicas reproduzidas ou salvas pelo usuário.

4.2.1 POC (Proof of Concept)

Na elaboração de uma POC em *python* utilizando o *Jupyter Notebook*, utilizou-se somente dos dados do usuário que tiveram mais registros salvos na base. Todo tratamento e preparação dos dados apresentados na seção 0 foram concebidos nessa POC. Os três testes ((i) escolher o melhor número de vizinhos (k) para rodar o algoritmo; (ii) avaliar o score do algoritmo; (iii) analisar a matriz de confusão obtida.) serviram de apoio para o aperfeiçoamento no uso do algoritmo.

4.2.2 Servidor

Com a lógica desenvolvida na POC, composto de uma exportação do código para scripts *python*, um servidor progrediu em sua criação. Tal, utiliza a biblioteca *Flask* e integra o algoritmo KNN exportado à rota. A rota do tipo GET / elaborada recebe 4 parâmetros: (i)

uri, o *id* do Spotify do usuário; (ii) *feeling*, o sentimento registrado; (iii) *activity*, a atividade registrada; (iv) *location*, a localização registrada. Ela também detém como retorno o gênero resultado da predição e a acurácia do algoritmo KNN.

4.2.3 Hospedagem

O servidor⁶, publicado na ferramenta disponível no Azure chamada App Service, utilizando *container Docker*, é uma ferramenta paga que possibilita a publicação de servidores de diversas tecnologias.

4.2.4 Recomendação

No momento em que o servidor recebe uma requisição, é feito o tratamento dos parâmetros. O mesmo transforma a *string* em um valor numérico através da biblioteca *preprocessing*, e, no caso de a característica não existir anteriormente, é feito um tratamento para valores padrões, conforme apresenta o Quadro 5. Os campos *like*, *hate* e *restart* estão com valores fixos devido a busca de músicas que foram curtidas (*like*=1), as não marcadas como “Não gostei” (*hate*=0) junto daquelas colocadas para repetir (*restart*=1).

É utilizado o *LabelEncoder* para gerar o valor numérico dos campos *feeling*, *activity*, *location*. Para isso, foi rodado o método *fit* apresentando os dados a base e então realizado o *transform*. Ao rodar, é estourado uma exceção se for passado uma característica desconhecida pelo *fit*. Devido a esse comportamento, os campos possuem um valor padrão no caso de a característica enviada não existir na base.

Quadro 5 - Campos e seus respectivos valores utilizados na recomendação

Campo	Valor padrão
Like	1
hate	0
restart	1
feeling	0
activity	0
location	0

Fonte: Elaborado pelo autor (2020)


⁶ O link de acesso ao servidor: <https://lors.azurewebsites.net/>

Com o algoritmo pronto (Seção 4.1.1) e os parâmetros tratados, fez-se mister a predição através do método *predict* do *sklearn*, devolvido a classe resultante. Isso é, ter o gênero resultante como resposta à requisição.

4.2.5 Resultado da recomendação (integração *webapp*)

Uma integração no *plugin* se deu como necessário no servidor pronto e publicado, obtendo informações de contexto e solicitando ao LORS o gênero recomendado. Com o retorno do gênero, é feita uma nova requisição de busca ao Spotify das principais 20 *playlists* que o contenham no nome.

Figura 22 – A direita, parte superior da tela de recomendações. A esquerda, parte inferior da tela de recomendações



Fonte: Elaborado pelo autor (2020)

No fim, é apresentado o gênero recomendado na tela, tratando do retorno do Spotify, apresentado as *playlists* a tela (Figura 22), permitindo ao usuário escolher uma das *playlists* para reproduzir.

4.2.6 Resultados do experimento

Nessa seção são discutidas a acurácia e matriz de confusão da aplicação do KNN sobre o conjunto de testes. O algoritmo inicialmente obteve uma acurácia de 0,15, o que é muito baixo. A hipótese estaria na quantidade de gêneros (classes); diminuí-los poderia

umentar a precisão do experimento. Foi realizado uma taxonomia dos gêneros, mantendo somente os principais. Com essa alteração, a acurácia do algoritmo passou de 0,15 para 0,46, um acréscimo de 206%, tendo em vista o 0,15 como um valor de acurácia baixo.

O principal problema para realizar a taxonomia foi encontrar uma lista que supria a dos gêneros do Spotify ao ponto de conseguir fazer a relação com os existentes no algoritmo e substituí-los pelo base, pois nele não dispõe dessa relação. A relação dos gêneros com seus subgêneros foi encontrada em um *showcase* do Spotify chamado Music Popcorn (SPOTIFY, 2020). Ele possui uma lista de 1107 gêneros, 4 vezes menos do que o Spotify possui hoje, porém já auxiliou na taxonomia dos gêneros, trazendo uma redução de 70 para 40 classes na base do usuário de teste.

Quadro 6 - relação dos gêneros e a classe utilizada no KNN

GENERO	CLASSE GERADA PELO LABEL ENCODER	GENERO	CLASSE GERADA PELO LABEL ENCODER
arkansas country	0	heartland rock	20
atl hip hop	1	hip hop	21
australian country	2	indie cafe pop	22
australian indie folk	3	melodic rap	23
australian reggae fusion	4	metal	24
bandinhas	5	miami hip hop	25
beatlesque	6	musica gaucha	26
brazilian rock	7	musica gaucha tradicionalista	27
canadian pop punk	8	musica maranhense	28
canadian punk	9	neo mellow	29
canadian rock	10	nyc rap	30
channel pop	11	oklahoma country	31
country	12	pop	32
country dawn	13	post-teen pop	33
country pop	14	punk	34

country road	15	r&b	35
dfw rap	16	redneck	36
electro house	17	rock	37
folk	18	sertanejo pop	38
harlem hip hop	19	trap	39

Fonte: Elaborado pelo autor (2020)

A matriz de confusão do usuário utilizado nos testes, está disponível no Quadro 8. Nela, é possível verificar que o algoritmo somente obteve sucesso na recomendação da categoria de número 12. Acontece devido ao curto período de uso da aplicação e ao gosto musical do usuário estar mais voltado aquele estilo musical. Encontrada no Quadro 6, ela apresenta a relação dos gêneros com as classes geradas para o KNN.

Quadro 7 - matriz confusão da classe 12, gênero musical country

		CLASSE REAL	
		POSITIVO	NEGATIVO
CLASSIFICAÇÃO OBTIDA	POSITIVO	184	180
	NEGATIVO	46	38

Fonte: Elaborado pelo autor (2020)

Para uma análise mais aprofundada, utilizou-se o gênero de maior quantidade de recomendações, o de 230 itens, isso é o *country* (classe 12). Pela análise, o Quadro 7, para avaliar os dados de precisão, *recall* e *f-measure*. A precisão do KNN ao realizar a recomendação dessa classe, é de 0,51, ou seja, está com dificuldades de classificar o gênero *country* e acaba na maioria das vezes interpretando como outro gênero. O *recall* foi de 0,80, o que mostra ele está classificando instâncias da classe 12 (*country*) em outras classes. Outra métrica interessante é o *f-measure*, que é utilizado para analisar o *recall* com a precisão em uma única medida. O gênero *country* ficou 0,62.

Quadro 8 - Matrix confusão do usuário spotify:user:4i3jdhv6vubcjdpsn38iv8u4

	0-11	12	13-14	15	16-20	21	22-26	27	28-31	32	33-36	37	38-39
0	0	0	0	0	0	0	0	0	0	0	0	0	0
1	0	0	0	0	0	1	0	0	0	0	0	0	0
2	0	1	0	0	0	0	0	0	0	0	0	0	0
3	0	0	0	0	0	0	0	0	0	1	0	0	0
4	0	0	0	0	0	0	0	0	0	0	0	0	0
5	0	9	0	0	0	0	0	0	0	0	0	0	0
6-10	0	0	0	0	0	0	0	0	0	0	0	0	0
11	0	0	0	0	0	0	0	0	0	0	0	2	0
12	0	184	0	24	0	1	0	0	0	17	0	4	0
13-14	0	0	0	0	0	0	0	0	0	0	0	0	0
15	0	64	0	5	0	1	0	0	0	5	0	1	0
16	0	0	0	0	0	0	0	0	0	0	0	0	0
17	0	0	0	4	0	3	0	0	0	2	0	0	0
18	0	0	0	0	0	0	0	0	0	0	0	0	0
19	0	0	0	1	0	0	0	0	0	0	0	0	0
20	0	0	0	0	0	0	0	0	0	1	0	0	0
21	0	0	0	5	0	10	0	0	0	8	0	0	0
22	0	0	0	0	0	0	0	0	0	0	0	0	0
23	0	0	0	2	0	1	0	0	0	0	0	0	0
24	0	2	0	0	0	0	0	0	0	0	0	0	0
25	0	0	0	0	0	1	0	0	0	0	0	0	0
26	0	0	0	0	0	0	0	1	0	0	0	0	0
27	0	11	0	3	0	0	0	4	0	0	0	0	0
28	0	0	0	0	0	0	0	0	0	0	0	0	0
29	0	2	0	0	0	0	0	0	0	2	0	0	0
30	0	1	0	1	0	0	0	0	0	0	0	0	0
31	0	2	0	0	0	0	0	0	0	1	0	2	0
32	0	24	0	9	0	4	0	0	0	17	0	1	0
33	0	2	0	0	0	1	0	0	0	1	0	0	0
34	0	0	0	0	0	0	0	0	0	1	0	0	0
35	0	1	0	0	0	0	0	0	0	0	0	0	0
36	0	0	0	0	0	0	0	0	0	0	0	0	0
37	0	55	0	4	0	1	0	0	0	10	0	2	0
38	0	4	0	0	0	0	0	0	0	0	0	0	0
39	0	2	0	1	0	3	0	0	0	0	0	0	0

Fonte: Elaborado pelo autor (2020)

Com sucesso foi desenvolvido o sistema de recomendação e apresentado nesse capítulo, iniciou-se apresentado o algoritmo, então a preparação dos dados do *plugin*, testes, desenvolvimento do servidor que hospeda os scripts *python*, a integração dele no *webapp* e por fim, é apresentado os resultados obtidos com as recomendações do algoritmo.

5 CONCLUSÃO

Nesse trabalho foi realizada uma revisão sobre trabalhos da *ACM*, de *RecSys* musical, que utilizam o contexto do usuário. Na pesquisa apareceram poucos trabalhos que buscam unir a recomendação musical com o contexto do usuário. Sendo assim, esse trabalho desenvolveu um *RecSys* musical, o qual analisa o contexto do usuário em tempo real, para realizar novas recomendações a ele.

No desenvolvimento desse trabalho, foram encontradas diversas dificuldades em lidar com músicas, pois desde o momento que se iniciou o estudo, foi visto que a área é muito maior do que aparenta. Com o questionário foi possível entender que o gosto musical de um público é algo bastante abrangente.

No *plugin* foram encontradas dificuldades em seu desenvolvimento. Inicialmente a aplicação foi desenvolvida em Flutter, uma plataforma para desenvolvimento mobile e foi visto que devido à falta de suporte ao *streaming (Web Playback SDK)* na biblioteca do Spotify para Flutter, ela não supriria as necessidades desse trabalho, então houve uma migração para a plataforma Web.

Ao realizar a primeira publicação do *plugin*, foram encontrados problemas como, navegadores diferentes, sistemas operacionais diferentes, contas do Spotify com contrato diferente. E tudo isso, levou ao entendimento de que o desenvolvimento e manutenção dessa aplicação Web é bastante complexo.

Com o sistema desenvolvido, foi enviado e-mail a todos que optaram por participar da pesquisa no questionário. Nisso foi visto que os usuários não têm uma boa aderência a estudos enviados via e-mail, pois dos 144 optantes, somente 6 deles o receberam e utilizaram da aplicação. Portanto, foram escolhidos respondentes com mais afinidade com o autor, um total de 8, solicitado pessoalmente que utilizassem a aplicação para auxiliar no trabalho. No fim, o sistema obteve um total de 14 usuários que utilizaram o sistema período estipulado.

Mesmo solicitando pessoalmente, foi obtido um baixo uso na aplicação, gerando assim uma base muito pequena para aplicação do algoritmo KNN. Esse problema é conhecido como *Cold Start*, que acontece geralmente quando as aplicações estão iniciando e não tem um histórico de dados muito grande. Para lidar melhor com a acurácia inicial do KNN muito baixa, foi desenvolvida a taxonomia dos gêneros, mantendo somente os principais gêneros, e com isso, reduzindo o número de resultados possíveis, o que melhorou a acurácia do KNN em prever um melhor resultado.

Porém, mesmo com a redução das classes, o algoritmo obteve uma baixa acurácia nas recomendações. Logo, há a necessidade de uma melhoria nas características coletadas dos usuários, bem como um aumento na base de dados. Posterior a isto, será possível também avaliar acurácia do KNN em relação a outros algoritmos de *Machine Learning*.

5.1 TRABALHOS FUTUROS

Abaixo são apresentadas algumas melhorias e continuidade nos estudos relativos ao sistema de recomendação apresentado.

- Desenvolver uma extensão mais simples para conectar ao Spotify, como uma extensão do Google Chrome;
- Encontrar uma base mais completa para realizar a taxonomia dos gêneros;
- Realizar a leitura da emoção através dos batimentos cardíacos de um *wearable*;
- Carregar histórico do Spotify para auxiliar o *Cold Start* do KNN;
- Realizar perguntas sobre gêneros, músicas e artistas para auxiliar no *Cold Start* do KNN;
- Aperfeiçoar atributos do algoritmo para aumentar a acurácia, precisão e *recall*;
- Utilizar latitude e longitude para assimilar a localização em *label* e facilitar o seu preenchimento;
- Aplicar uma leitura sequencial ao algoritmo das recomendações (uso do *createdDateTime*);
- Contabilizar ações apresentadas no Quadro 4 que não estão sendo utilizadas no algoritmo;
- Inserir *feature* “amigos ou sozinho” ao plugin e utilizar no algoritmo;
- Utilizar outras características das músicas;
- Utilizar como contexto “grandes épocas” (carnaval, natal, São João, ...).

REFERÊNCIAS BIBLIOGRÁFICAS

- ACM. **Advanced Search**. Disponível em: <<https://dl.acm.org/search/advanced>>. Acesso em: 5 maio. 2020.
- ACM RECSYS COMMUNITY. **RecSys – ACM Recommender Systems**. Disponível em: <<https://recsys.acm.org/>>. Acesso em: 28 abr. 2020.
- AHA, D. W.; KIBLER, D.; ALBERT, M. K. Instance-based learning algorithms. **Machine Learning**, v. 6, n. 1, p. 37–66, jan. 1991.
- ALIAGA, W. K. DESENVOLVIMENTO DE UM SISTEMA DE RECOMENDAÇÃO MUSICAL SENSÍVEL AO CONTEXTO. 2018.
- BHATNAGAR, V. Collaborative filtering using data mining and analysis. [s.l: s.n.].
- BORJA, K.; DIERINGER, S. Streaming or stealing? The complementary features between music streaming and music piracy. **Journal of Retailing and Consumer Services**, v. 32, p. 86–95, 2016.
- DIETMAR, J. et al. **Recommendation system -An Introduction**. [s.l: s.n.]. v. 91
- EDITORA MELHORAMENTOS LTDA. **Sobre o dicionário | Michaelis On-line**. Disponível em: <<https://michaelis.uol.com.br/>>. Acesso em: 6 jun. 2020.
- ERIKSSON, M. et al. **Spotify Teardown**. [s.l.] MIT Press, 2019.
- FALK, K. Practical Recommender Systems. [s.l: s.n.].
- IFPI. **IFPI Global Music Report 2019**. Disponível em: <<https://www.ifpi.org/news/IFPI-GLOBAL-MUSIC-REPORT-2019>>.
- JOSÉ, I. **KNN (K-Nearest Neighbors) #1**. Disponível em: <<https://medium.com/brasil-ai/knn-k-nearest-neighbors-1-e140c82e9c4e>>. Acesso em: 4 out. 2020.
- L'HUILLIER, A. The new challenges when modeling context through diversity over time in recommender systems. **UMAP 2016 - Proceedings of the 2016 Conference on User Modeling Adaptation and Personalization**, p. 341–344, 2016.
- LUDEWIG, M. et al. Effective nearest-neighbor music recommendations. **ACM International Conference Proceeding Series**, 2018.
- LUINI, B. J. R.; WHITMAN, A. E.; DATE, P. **Streaming Audio: The FezGuys' Guide**. [s.l: s.n.].
- MURARO, R. M. Os avanços tecnológicos e o futuro da humanidade Querendo ser Deus, , 2009.
- NIWA, H. **Streaming Systems**. [s.l.] O'Reilly Media, 2018. v. 134

- PEDREGOSA, F. et al. Scikit-learn: Machine Learning in {P}ython. **Journal of Machine Learning Research**, v. 12, p. 2825–2830, 2011.
- RÄTSCH, G. A brief introduction into machine learning. **21st Chaos Communication Congress**, p. 1–6, 2004.
- RESNICK, PAUL AND VARIAN, H. R. Recommender Systems. **Communications of the ACM**, v. 40, n. 4, p. 56–58, 1997.
- RICCI, F.; ROKACH, L.; SHAPIRA, B. **Recommender Systems Handbook**. [s.l.: s.n.].
- SPOTIFY. **Music Popcorn | Spotify for Developers**. Disponível em: <<https://developer.spotify.com/community/showcase/music-popcorn/>>. Acesso em: 9 nov. 2020.
- TKALČIČ, M. et al. Prediction of music pairwise preferences from facial expressions. **International Conference on Intelligent User Interfaces, Proceedings IUI**, v. Part F1476, p. 150–159, 2019.
- UNIVERSIDADE FEDERAL DO CEARA. **A Magnetorresistência Gigante**. Disponível em: <<https://seara.ufc.br/tintim-por-tintim/tecnologia/a-magnetorresistencia-gigante/>>. Acesso em: 12 mar. 2020.
- VOLOKHIN, S.; AGICHTEIN, E. Towards intent-aware contextual music recommendation: Initial experiments. **41st International ACM SIGIR Conference on Research and Development in Information Retrieval, SIGIR 2018**, p. 1045–1048, 2018.
- YANG, Y. H.; TENG, Y. C. Quantitative study of music listening behavior in a smartphone context. **ACM Transactions on Interactive Intelligent Systems**, v. 5, n. 3, 2015.