

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ  
CÂMPUS CORNÉLIO PROCÓPIO  
DIRETORIA DE GRADUAÇÃO E EDUCAÇÃO PROFISSIONAL  
DEPARTAMENTO DE COMPUTAÇÃO  
ENGENHARIA DE COMPUTAÇÃO

JOÃO GABRIEL BRACAIOLI ARAÚJO VITÓRIO

**SISTEMA DE RECOMENDAÇÃO DE MÚSICA  
PARA AMBIENTES COMPARTILHADOS**

TRABALHO DE CONCLUSÃO DE CURSO

**CORNÉLIO PROCÓPIO**

**2016**

**JOÃO GABRIEL BRACAIOLI ARAÚJO VITÓRIO**

**SISTEMA DE RECOMENDAÇÃO DE MÚSICA  
PARA AMBIENTES COMPARTILHADOS**

Trabalho de Conclusão de Curso apresentada ao Programa de Graduação em Engenharia de Computação da Universidade Tecnológica Federal do Paraná como requisito parcial para obtenção do do título de Bacharel em Engenharia de Computação.

Orientador: Prof. Dr. Carlos N. Silla Jr.

**CORNÉLIO PROCÓPIO**

**2016**



Ministério da Educação  
Universidade Tecnológica Federal do Paraná  
Câmpus Cornélio Procópio  
Diretoria de Graduação e Educação Profissional  
Programa de Graduação em Engenharia de Computação  
Engenharia de Computação



---

## **TERMO DE APROVAÇÃO**

### **SISTEMA DE RECOMENDAÇÃO DE MÚSICA PARA AMBIENTES COMPARTILHADOS**

por

João Gabriel Bracaioli Araújo Vitório

Este Trabalho de Conclusão de Curso foi julgado adequado para obtenção do Título de “Bacharel em Engenharia de Computação” e aprovado em sua forma final pelo Programa de Graduação em Engenharia de Computação da Universidade Tecnológica Federal do Paraná.

Cornélio Procópio, 14/06/2016

---

Prof. Dr. Carlos N. Silla Jr.  
Universidade Tecnológica Federal do Paraná

---

Prof. M.e Francisco Pereira Jr.  
Universidade Tecnológica Federal do Paraná

---

Prof. Dr. André Endo  
Universidade Tecnológica Federal do Paraná

Dedicado aos meus pais que sempre me apoiaram.

Ao meu filho Rafael Henrique que com seus sorrisos não me permitiu desistir.

## RESUMO

Bracaioli Araujo Vítório, João Gabriel. SISTEMA DE RECOMENDAÇÃO DE MÚSICA PARA AMBIENTES COMPARTILHADOS. 65 f. Trabalho de Conclusão de Curso – Engenharia de Computação, Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2016.

Pesquisas sobre Sistemas de Recomendação têm crescido diante do grande número de informações que os indivíduos tem a sua disposição. No contexto de recomendação musical, esses sistemas tentam ajudar o indivíduo a filtrar e a descobrir músicas de acordo com seu gosto. Diversas empresas do ramo musical, em sua maioria, utilizam recomendação com base nas características das músicas ouvidas pelo indivíduo, mas recomendação de música para grupos é pouco explorada. Para ambientes compartilhados onde há música, a seleção dessas será mais eficiente se utilizar um sistema de recomendação para grupo. Desta forma, o objetivo desse trabalho é desenvolver um sistema de recomendação de música para grupos que compartilham o mesmo ambiente, levando em consideração o contexto. Para atingir esse objetivo será utilizada a API do Spotify para recuperar as *playlists* ouvidas pelo indivíduo, obtendo-se suas preferências musicais, que serão agregadas com as demais.

**Palavras-chave:** Sistemas de Recomendação para Grupos, Recomendação de Música, Recomendação de Música para Grupo

## ABSTRACT

Bracaioli Araujo Vitório, João Gabriel. MUSIC RECOMMENDATION SYSTEM FOR SHARED ENVIRONMENTS. 65 f. Trabalho de Conclusão de Curso – Engenharia de Computação, Universidade Tecnológica Federal do Paraná. Cornélio Procópio, 2016.

Research about recommendation systems has increased due to the amount of information that it is available to individuals. In the music context these systems help the individual to filter and discover new songs according the individual's taste. Most of the business music companies use a recommendation system, based on the characteristics of a song listened by an individual, but a group recommendation system is still underexplored. For a shared environment when there is music, the songs selection will be more efficient if a group recommendation system is used. The goal of this project is to develop a music recommendation for a group that, is sharing the same environment, taking into consideration the context. For this reason, in this work we will employ the Spotify API to recover the data of playlists that were listened by an individual, collecting its preferences and adding them to the others individuals playlists.

**Keywords:** Recommender Systems for Groups, Music recommendation, Music recommendation for Group

## LISTA DE FIGURAS

FIGURA 2	– Telas do protótipo <i>Tag String</i> .....	16
FIGURA 3	– APIs de música em 2013 .....	18
FIGURA 5	– Kanban com as tarefas da semana .....	26
FIGURA 6	– Diagrama de Sequência: Interação do indivíduo na criação do perfil ...	27
FIGURA 7	– Relacionamento do indivíduo com as músicas .....	28
FIGURA 8	– Diagrama de Sequência: Criação do perfil .....	29
FIGURA 9	– Relação do artista com gêneros .....	30
FIGURA 10	– Exemplo de relacionamento geral .....	31
FIGURA 11	– Fluxograma do processo de agregação. ....	32
FIGURA 12	– Modelo para agregação de gêneros e músicas .....	33
FIGURA 13	– Relacionamento Grupo, Indivíduo e Músicas .....	34
FIGURA 14	– Relacionamentos utilizados para agregação de artistas .....	35
FIGURA 15	– Relacionamentos utilizados para agregação dos gêneros .....	36
FIGURA 16	– Diagrama de Caso de Uso do SRMAC .....	37
FIGURA 17	– <i>Wireframe</i> , esboço inicial do aplicativo .....	38
FIGURA 18	– SRMAC: Login e Principal .....	38
FIGURA 19	– SRMAC: Criar grupo. ....	39
FIGURA 20	– SRMAC: Processo de recomendação. ....	40
FIGURA 21	– SRMAC: Grupo .....	41
FIGURA 22	– Principais tecnologias utilizadas .....	43
FIGURA 23	– Distribuição dos serviços. ....	44
FIGURA 25	– Questionário para validação do contexto .....	45
FIGURA 26	– Ambientes onde ouve-se música em grupo .....	46
FIGURA 27	– Resultado da avaliação de satisfação da recomendação no ambiente de academia .....	47
FIGURA 28	– Resultado da avaliação de quão adequadas foram as recomendação para o ambiente de academia .....	47
FIGURA 29	– Resultado da avaliação de satisfação da recomendação no ambiente de bar/restaurante .....	48
FIGURA 30	– Resultado da avaliação de quão adequadas foram recomendação para o ambiente de bar/restaurante .....	48
FIGURA 31	– Resultado da avaliação de satisfação da recomendação no ambiente de festa .....	49
FIGURA 32	– Resultado da avaliação de quão adequadas foram recomendação para o ambiente de festa .....	49
FIGURA 33	– Resultado da satisfação do primeiro grupo da recomendação no ambiente de trabalho .....	50
FIGURA 34	– Resultado da avaliação do primeiro grupo, para quão adequadas foram as recomendações para o ambiente de trabalho .....	50
FIGURA 35	– Resultado da avaliação de satisfação do segundo grupo da recomendação no ambiente de trabalho .....	51
FIGURA 36	– Resultado da avaliação do segundo grupo, para quão adequadas foram as	

	recomendações no ambiente de trabalho .....	51
FIGURA 37	– Resultado das avaliação do primeiro grupo, para as recomendação no ambiente de viagem .....	52
FIGURA 38	– Resultado das avaliação do primeiro grupo, para quão adequadas as recomendações foram no ambiente de viagem .....	53
FIGURA 39	– Resultado das avaliação do segundo grupo, para as recomendação no ambiente de viagem .....	53
FIGURA 40	– Resultado das avaliações do segundo grupo, para quão adequadas as recomendações foram no ambiente de viagem .....	53
FIGURA 41	– Nível de satisfação das recomendações realizadas .....	54
FIGURA 42	– Níveis de adequação das músicas recomendadas ao ambiente .....	54
FIGURA 43	– Nível de satisfação das recomendações realizadas no contexto Academia	55
FIGURA 44	– Nível de satisfação das recomendações realizadas no contexto Trabalho	56



## LISTA DE TABELAS

TABELA 2	– Avaliação dos Livros .....	15
TABELA 3	– Resumo dos trabalhos relacionados .....	23

## LISTA DE SIGLAS

REST	Representational State Transfer
KNN	k-Nearest Neighbors algorithm
HTTP	Hypertext Transfer Protocol
URI	Uniform Resource Identifier
NoSQL	Not Only Structured Query Language
SRMAC	Sistema de Recomendação de Música para Ambiente Compartilhado

## SUMÁRIO

<b>1 INTRODUÇÃO</b> .....	<b>11</b>
1.1 MOTIVAÇÃO .....	12
1.2 OBJETIVOS .....	12
1.2.1 Objetivo Geral .....	12
1.2.2 Objetivos Específicos .....	12
1.3 ORGANIZAÇÃO DO TEXTO .....	13
<b>2 FUNDAMENTAÇÃO TEÓRICA</b> .....	<b>14</b>
2.1 MÉTODOS DE RECOMENDAÇÃO .....	14
2.1.1 Filtro Colaborativo .....	15
2.1.2 Filtro baseado em conteúdo .....	16
2.1.3 Filtro baseado em contexto .....	17
2.1.4 Filtros Híbridos .....	17
2.2 APIS .....	18
2.3 BANCO DE DADOS DE GRAFOS .....	19
2.4 TRABALHOS RELACIONADOS .....	19
2.5 SISTEMAS DE RECOMENDAÇÃO PARA GRUPOS .....	24
2.5.1 Estratégia de agregação .....	25
<b>3 DESENVOLVIMENTO</b> .....	<b>26</b>
3.1 FONTE DE INFORMAÇÃO .....	27
3.2 AGREGAÇÃO E RECOMENDAÇÃO .....	31
3.3 PROTÓTIPO E EXPLICAÇÃO DA RECOMENDAÇÃO .....	36
3.4 TECNOLOGIAS UTILIZADAS .....	42
<b>4 EXPERIMENTOS</b> .....	<b>45</b>
4.1 VALIDAÇÃO DO CONTEXTO DOS INDIVÍDUOS .....	45
4.2 VALIDAÇÃO DAS RECOMENDAÇÕES PARA DIFERENTES CONTEXTOS ...	46
4.2.1 Academia .....	46
4.2.2 Bar/Restaurante .....	47
4.2.3 Festa .....	48
4.2.4 Trabalho .....	49
4.2.5 Viagem .....	52
4.2.6 Análise Geral dos Resultados .....	53
4.3 VALIDAÇÃO DOS PARÂMETROS DE CONTEXTO .....	54
<b>5 CONSIDERAÇÕES FINAIS E TRABALHOS FUTUROS</b> .....	<b>57</b>
<b>REFERÊNCIAS</b> .....	<b>59</b>
<b>Apêndice A – DIAGRAMA DE CLASSE DO NEO4J</b> .....	<b>62</b>
<b>Apêndice B – DIAGRAMA DE CLASSE DOS SERVIÇOS</b> .....	<b>64</b>

## 1 INTRODUÇÃO

Ao adentrar em bares, restaurantes, carros, festas de finais de semana, ou churrasco entre amigos, os indivíduos normalmente estarão ouvindo música. Em geral, nem sempre os indivíduos que compartilham o mesmo ambiente ficam satisfeitos com as escolhas musicais uns dos outros, gerando assim um certo desconforto.

Devido ao grande número de músicas disponíveis aos usuários, torna-se difícil lembrar tantos títulos e selecioná-los um a um acaba consumindo muito tempo. Dessa forma, o desenvolvimento de um sistema capaz de recomendar músicas através do perfil de todos presentes em um mesmo ambiente minimizaria o trabalho e resultaria em uma maior chance de satisfação. Sistemas de recomendação auxiliam no aumento da capacidade e eficácia deste processo de indicação, já bastante conhecido na relação social entre seres humanos (RESNICK; VARIAN, 1997).

Os sistemas de recomendação vêm se tornando cada vez mais importantes, facilitando aos indivíduos em suas escolhas, em um cotidiano que cada vez mais, lida-se com grande volume de informações. Sistemas de Recomendação surgiram em meados dos anos 90, e eram denominados filtros colaborativos (GOLDBERG DAVID NICHOLS, 1992). Resnick e Varian (1997) propuseram chamar como Sistema de Recomendação, por ser um termo mais genérico, e por ser um conceito mais amplo e aperfeiçoado do que os abordados anteriormente.

Diversas empresas do ramo da música perceberam a dificuldade dos indivíduos para decidir suas escolhas musicais (PICHL et al., ). Diante desse panorama, muitas começaram a trabalhar com recomendação de música tais como *Last.fm*<sup>1</sup>, *Spotify*<sup>2</sup>, *The Echo Nest*<sup>3</sup>, *Pandora*<sup>4</sup>. Em sua maioria são recomendações individuais, ou seja, com base nas características musicais ouvidas por um indivíduo. Essas empresas constroem o perfil de cada usuário através das músicas ouvidas e utilizam diferentes técnicas de sistemas de recomendação, como análise de similaridade, filtro colaborativo, análise de contexto para determinar quais músicas serão

---

<sup>1</sup>www.last.fm/

<sup>2</sup>spotify.com

<sup>3</sup>the.echonest.com

<sup>4</sup>pandora.com

apresentadas aos usuários destes sistemas.

## 1.1 MOTIVAÇÃO

McCarthy e Anagnost (1998) ressaltam que qualquer ambiente com indivíduos reunidos, por um período de tempo significativo, é um local com potencial para sistema de recomendação de música para grupo. Sugerem ainda que quaisquer locais públicos, onde há música, seriam mais eficientes se ao invés de, ouvirem músicas selecionadas por funcionários, pudessem ouvir as que realmente gostam.

Em Carvalho e Macedo (2014), ressaltam que sistemas de recomendação para grupos ainda são pouco explorados e destacam alguns contextos onde podem ser aplicados, como por exemplo, para filmes, restaurantes, comunidades *online* e a música. Destes cenários, a música é um campo especial de recomendação, pois com duração média de 4 minutos, é necessário recomendar múltiplas canções.

A motivação deste trabalho foi desenvolver um algoritmo voltado para recomendação musical para grupos de indivíduos.

## 1.2 OBJETIVOS

### 1.2.1 OBJETIVO GERAL

O objetivo geral deste trabalho foi desenvolver um sistema de recomendação de música para indivíduos que compartilham um mesmo ambiente. Para isso, é considerando o perfil musical individual para recomendar uma *playlist* adequada para o grupo, levando em consideração o contexto em que será ouvida.

### 1.2.2 OBJETIVOS ESPECÍFICOS

- Desenvolver um algoritmo de recomendação para grupo.
- Desenvolver um serviço Web, que receba as *playlists* individuais, utilizar o algoritmo criado, e disponibilizar por meio de APIs REST, a *playlist* recomendada para o grupo.
- Publicar o método desenvolvido e apresentar os resultados.

### 1.3 ORGANIZAÇÃO DO TEXTO

O trabalho está estruturado da seguinte forma: no Capítulo 2 são apresentados os principais conceitos sobre métodos de recomendação e uma discussão sobre trabalhos relacionados com foco na recomendação de música para grupos. No Capítulo 3 está descrito o desenvolvimento deste trabalho e as tecnologias utilizadas na implementação. Os experimentos e resultados são apresentados no Capítulo 4. No Capítulo 5 são feitas as considerações finais.

## 2 FUNDAMENTAÇÃO TEÓRICA

Nesse capítulo são apresentados os principais conceitos sobre os mecanismos de recomendação baseado em aprendizado de máquina (*machine learning*), APIs, Banco de dados de Grafos e trabalhos relacionados que serão utilizados.

### 2.1 MÉTODOS DE RECOMENDAÇÃO

Os sistemas de recomendação estão presentes no cotidiano dos indivíduos, por exemplo, ao realizar buscas em sites de pesquisas, ou compras on-line. A *Amazon*<sup>1</sup> virou referência em venda de produtos pela Internet, e um dos motivos foi a recomendação de produtos, usando como estratégia, a recomendação de produtos que estejam alinhados ao interesse do consumidor, sendo assim, mais provável que ele venha a adquiri-lo. Também é utilizado pelo *Google*<sup>2</sup>, que com base nas pesquisas anteriores e gostos pessoais, altera a ordem dos resultados da busca.

Esses tipos de sistemas têm por objetivo sugerir itens a um indivíduo, baseado nas similaridades dos dados obtidos, de forma a identificar padrões, permitindo descobrir o que determinado indivíduo pode desejar ou não. Essa abordagem diminui significativamente a sobrecarga de informações, mostrando ou recomendando somente o que o usuário possivelmente quer ver.

As preferências dos indivíduos podem ser obtidas implicitamente ou explicitamente. Na forma implícita, informações são obtidas através de histórico de compras, histórico de sites visitados, sites acessados ou *cookies* do *browser*. Na forma explícita o indivíduo deve realizar *feedbacks* efetivos, como por exemplo notas dadas a um determinado item (SOUZA, 2014).

Existem quatro métodos básicos de recomendação: Filtragem Colaborativa, Baseado em Conteúdo, Baseado em Contexto e Sistemas Híbridos.

---

<sup>1</sup>amazon.com

<sup>2</sup>google.com

### 2.1.1 FILTRO COLABORATIVO

Utilizando técnicas de similaridade entre os indivíduos, pode-se prever as suas preferências através da relação indivíduo-item. Uma possível abordagem, é a modelagem de uma matriz  $A$  de dimensão  $N \times M$ , onde  $N$  representa os indivíduos e  $M$  os itens, e cada posição de  $A\{i,j\}$  contém uma avaliação. Conforme exemplificado na Tabela 2, onde se apresentam:

- Indivíduo X, compre os livros A, B, C, D e os avalia como: A, B e D - 10 e C - 4.
- Indivíduo Y, compre os livros A, B, e C, e os avalia como: A-10, B-9 e C-1.

**Tabela 2:** Avaliação dos Livros

Indivíduos	Livros			
	A	B	C	D
X	10	10	4	10
Y	10	9	1	?

Utilizando métodos de classificação, por exemplo KNN que é um algoritmo que através dos itens disponíveis e sua classificação, quando há um novo item, utilizando um valor para  $K$  vizinhos, e calcula-se sua similaridade (utilizando por exemplo a distância euclidiana) com esses vizinhos, desta forma classificando o novo item. Pode-se observar partindo desse princípio que o livro D será recomendado para Y, pois os indivíduos X e Y avaliaram os livros A, B, C de forma similar tornando-se vizinhos próximos. Esse tipo de abordagem é largamente utilizado de forma parecida pelos sites que utilizam recomendação, tais como *Amazon* e *netflix*.

Em geral, filtro colaborativo é subdividido em três partes: baseado em modelo, baseado em memória e híbrido.

**Baseado em modelo:** também conhecido como baseado em heurística ou de vizinhança. Utilizando algoritmos de aprendizado de máquina e mineração de dados, fazendo um pré-processamento de uma matriz de avaliação, que permite treinar o sistema para modelar as preferências dos indivíduos (HU, 2014).

**Baseado em memória:** este tipo de abordagem utiliza a premissa de que semelhanças entre avaliações feitas no passado podem se repetir no futuro. Cada indivíduo é agrupado por avaliações semelhantes, e o novo item é produzido ao encontrar o vizinho com afinidade mais próximo. Essa abordagem é mais utilizada, por ser mais simples (SONG et al., 2012).

**Híbrido:** abordagem que combina-se as características do filtro colaborativo baseado em memória, com o baseado em modelo, para realizar as previsões de similaridade (WANG et al., 2006).



Uma melhora no filtro colaborativo é a utilização do filtro de conteúdo, que será apresentado no próximo tópico, com uma função de similaridade de dados da filtragem colaborativa (MCFEE et al., 2010). Este princípio vem sendo investigado por várias redes sociais, incluindo a *Last.fm*.

**Limitações:** muitos sistemas de filtro colaborativo baseiam-se em grandes conjuntos de dados. Como resultado, a matriz indivíduo-item usado pode ser extremamente grande e esparsa, o que traz desafios na performance da recomendação. Quando há um novo item, ou item sem classificação, torna-se impossível gerar recomendação, pois não haverá condições de calcular a similaridade e encontrar o vizinho com afinidade próxima.

No contexto de recomendação musical, por exemplo, esse problema se acentua, pois apenas uma pequena porcentagem é classificada, assim, músicas populares que recebem mais classificações são recomendadas, enquanto que lançamentos não são. Pela subjetividade da música é possível que indivíduos possuam comportamentos semelhantes, mas tenham gosto musical totalmente opostos.

### 2.1.2 FILTRO BASEADO EM CONTEÚDO

A recomendação baseada em conteúdo extrai as características relevantes a um item e as compararam com outros itens determinando um grau de semelhança para realizar a sua recomendação. No caso de filmes, livros e música, os sistemas de recomendação utilizam *tags* (rótulos, em Português). Especificamente, no caso da música, essas *tags* podem ser o título, o artista, o gênero e a letra, que serão utilizados para encontrar músicas similares.



**Figura 2:** Telas do protótipo *Tag String*

**Fonte:** (YAMASHITA, 2013)

Yamashita (2013) utiliza as mesmas *tags* para melhorar usabilidade e experiência do indivíduo com recomendação através da visualização *Tag Strings*, com a exibição dos gêneros mais relevantes ligando as músicas sugeridas, conforme podemos verificar na Figura (2), facilitando o entendimento de como a recomendação foi gerada.

A abordagem proposta por Cano Markus Koppenberger (2005), é extrair as características acústicas da música, como métrica, timbre, ritmo, e batidas por minutos (BPM), e as que tiverem características similares são recomendadas. Logan (2004) usando análise de similaridade acústica, propôs quatro soluções usando em suas recomendações: com base nas características de um conjunto de música é calculada a similaridade entre elas; através da distância euclidiana entre as ondas sonoras da música; através da distribuição gaussiana e pelo método de Monte Carlo.

**Limitações:** ocorre quando o indivíduo não sabe as informações básicas da música como título, artistas e gênero, ou não há informações especificadas sobre o item, ou as preferências dos indivíduos. O resultado da recomendação é pobre uma vez que os itens recomendados através de semelhança torna-se repetitivo e a opinião do indivíduo não é levada em consideração.

Em certa parte, o modelo resolve os problemas de filtragem colaborativa, pois não é necessário nenhuma classificação humana. No entanto, esse método não foi totalmente investigado em termos de satisfação dos usuários (SONG et al., 2012).

### 2.1.3 FILTRO BASEADO EM CONTEXTO

Abordagem baseada em contexto leva em consideração o ambiente ao redor do indivíduo, sua localização física, além de fatores como: humor atual e a atividade (que está praticando). Recomendar música depende muito do contexto, pois o interesse do indivíduo pode mudar de acordo com a situação ou momento (SU HSIN-HO YEH, 2010). Uma melhoria nas recomendações do filtro colaborativo é agrupar usuários por informações de contexto, tais como local, calendário, ruído, situação (SU HSIN-HO YEH, 2010). Diante dessas adaptações, foi possível gerar melhores *feedbacks*, indicando que o contexto é uma informação útil e relevante para facilitar a recomendação de música.

### 2.1.4 FILTROS HÍBRIDOS

Filtros híbridos tentam misturar dois ou mais métodos de recomendação, na tentativa de suprir as limitações existentes em cada um. Por exemplo, usando filtro colaborativo para

agrupar os indivíduos com gostos semelhantes e combinar com filtro de conteúdo buscando músicas que tenham características acústicas semelhantes (BALABANOVIĆ; SHOHAM, 1997) (YOSHII et al., 2008).

## 2.2 APIS

API (*Application Programming Interface*) ou em Português, Interface de Programação de Aplicação, é um conjunto de protocolos, funcionalidades e padrões estabelecidos por um software, para permitir ao desenvolvedor incorporar funcionalidades como um serviço, sem se envolver com detalhes de implementação.

Nesse trabalho foi usado o REST (*REpresentational State Transfer*), que é um estilo arquitetural inovador, que definem as *Web Standards* (normas para internet) como os HTTP e as URIs devem ser utilizadas, alavancando assim os padrões Web já existentes (TILKOV, 2008).

O termo REST foi apresentado na tese de doutorado de Fielding e Taylor (2002), sendo um dos principais desenvolvedores de protocolos Web. Um serviço Web RESTful expõe um conjunto de recursos que são identificados por URIs e realizam as seguintes operações: PUT, GET, POST, e DELETE. Em particular, estes serviços podem integrar-se facilmente em diversas aplicações, incluindo as APIs de música.



**Figura 3:** APIs de música em 2013

**Fonte:** (LAMERE, 2013)

Existem diversas APIs de música, como podemos observar na Figura 3. Em sua maioria são baseadas nos princípios do REST, com por exemplo as APIs *Echo Nest*, *Spotify* e *Last.fm* que trabalham de forma que possibilite a integração com outras APIs de música, retornando metadados em formato JSON. A API Spotify fornece acesso a dados relacionados ao usuário,

tais como listas de reprodução e músicas salvas em sua biblioteca pessoal. O Spotify conta com 60 milhões de usuários ativos (SPOTIFY, 2015).

A API *Echo Nest* suporta múltiplos espaços de identificação, incluindo naturalmente, IDs Spotify. Isso abre uma ampla gama de aplicações, que fazem uso de dados de ambos os serviços. Além disso, permite obter uma análise detalhada de qualquer faixa musical, como atributos acústicos, artistas similares, estimativa de popularidade, comentários recentes sobre o artista, entre outras funcionalidades.

### 2.3 BANCO DE DADOS DE GRAFOS

Banco de dados de grafos é um tipo de banco de dados não relacional - NoSQL (*Not Only Structured Query Language*) baseado na teoria dos grafos que estuda objetos combinatoriais (HAN et al., 2011). São capazes de armazenar e processar grandes conjuntos de dados com alto desempenho comparado a banco de dados relacional (HAN et al., 2011). Com a vantagem de um grafo, descreve relações entre vários conjuntos de entidades simbolizadas por nós interligados por arestas, facilitando entendimento por meio da representação dos dados em estrutura de conjuntos (ANGLES; GUTIERREZ, 2008).

Formalmente um grafo  $G$  é uma coleção de vértices e arestas, podendo ser expresso como  $G=(V,E)$ , sendo  $V$  um conjunto finito de vértices (nós) e  $E$  um conjunto finito de arestas. A aresta representa a relação entre dois vértices, ou seja, a maneira como um vértice se relaciona com outros vértices (ANGLES; GUTIERREZ, 2008).

Entre as distribuições existentes para banco de dados de grafos, o Neo4J<sup>3</sup> é amplamente utilizado (HARRIS, 2013), utilizada nesse trabalho. Neo4j utiliza a linguagem exclusiva denominada Cypher. Embora existam várias linguagens de consultas a grafos, Cypher é uma linguagem projetada para ser facilmente compreendida por desenvolvedores (ROBINSON et al., 2015), pois possui suporte a algoritmos de grafos importantes, como caminho mais curto e técnicas analíticas (ROBINSON et al., 2015).

### 2.4 TRABALHOS RELACIONADOS

Ouvir música pode ser relaxante, motivador e emocionante. Essas características aliadas ao fato que pode-se ouvir música com outros indivíduos num jantar, bar, festa ou dirigindo o carro, podem contribuir para uma atmosfera mais harmoniosa. Recomendação de música é

---

<sup>3</sup><http://neo4j.com>

a solução que ajuda o usuário a encontrar músicas de sua preferência sem a necessidade de procurar manualmente.

Uma utilização é a recomendação de música para um grupo de indivíduos ao longo de uma viagem (CUNNINGHAM et al., 2014). O aplicativo reúne o conjunto de músicas previamente carregados para a viagem a partir de reprodutores de música dos indivíduos e então solicita a duração aproximada da próxima viagem assim uma lista de reprodução é então construída com base nas preferências dos usuários e as características da música (gênero, ritmo, artista e etc).

**Avaliação:** realizada com 22 alunos da turma de *Human Computer Interaction* (HCI) de Nova Zelândia dividido em grupos de 4 membros. Os participantes receberam uma breve explicação sobre o funcionamento do protótipo que foi instalado em seus veículos e os experimentos foram realizados em diversas viagens de curta duração (10 a 30 minutos), e em outras mais longas (50 min a 2 horas). Com métodos da teoria fundamentada, foram tomando nota e pontuando as recomendações. Cunningham et al. (2014) também relata que dada a dificuldade para realização dos testes, algumas avaliações foram realizadas com dois grupos com o veículo estacionado.

McCarthy e Anagnost (1998) propõem a utilização de recomendadores de música para grupos que realizam exercícios físicos em uma academia, utilizando a classificação prévia dos indivíduos referente a suas preferências sobre 92 gêneros, classificando-os como: "gênero agrada" ou "gênero não agrada". Construindo uma tabela  $M \times N$ , onde  $M$  é o número de gêneros musicais e  $N$  o número de indivíduos.

**Avaliação:** realizada através de *feedback* explícito do indivíduo, porém sem interferência nas recomendações geradas. McCarthy e Anagnost (1998) não deixam claro quantos membros em cada grupo e qual a quantidade de grupos que foram utilizados para os testes realizados.

Com uma abordagem parecida com a de McCarthy e Anagnost (1998), Carolis et al. (2014) combina além da classificação prévia, os dados obtidos através do perfil dos indivíduos em redes sociais para gerar as recomendações de músicas na academia durante o período de cada turma.

**Avaliação:** através de *feedback* explícito, onde cada indivíduo classificou as canções que gostaram ou não, durante seis semanas com grupo médio de 10 pessoas. Os *feedbacks* positivos são usados para melhorar a classificação dos gêneros, artistas e canções específicas.

Campos et al. (2009) propõe em seu trabalho realizar as recomendações para grupo ba-

seado em Redes Bayesianas, que consistem em um conjunto de variáveis, modeladas de forma gráfica para verificar qual a influência probabilística não direta de uma variável para as demais, sendo adequada para tratar a incerteza em informação incompleta, onde os nós representam as variáveis e os arcos representam conexões diretas entre eles. Usando essa metodologia é possível modelar as incertezas que apresentam em ambas as interações entre os membros do grupo e os processos que levam a escolha final da recomendação.

A dificuldade sobre a avaliação é ressaltada por Campos et al. (2009). Para ele essa dificuldade se deve a duas razões. Primeiramente, um dos critérios utilizados para medir o desempenho das recomendações é a satisfação do participante, enquanto os outros sistemas de recomendação para grupo, o objetivo é explorar a capacidade do sistema em mesclar os perfis ou chegar em um consenso. A segunda razão é a ausência de um conjunto de dados públicos com as preferências dos grupos, não focado apenas nas avaliações individuais. A combinação desses fatores torna extremamente difícil comparar o desempenho entre diferentes sistemas de recomendação para grupo (CAMPOS et al., 2009).

**Avaliação:** Campos et al. (2009) utilizou a base da MovieLens, um conjuntos de dados de filmes e classificação. Usando técnica de avaliação cruzada, foram realizados os testes em dois grupos distintos. O primeiro levando em consideração indivíduos que tenham ao menos classificado um filme em comum, e o segundo que tenham avaliados quatro filmes em comuns. Com base nesses critérios formaram-se 115 grupos. Os resultados obtidos foram comparados com os resultados com algoritmos de filtragem colaborativa clássica (CAMPOS et al., 2009).

Vieira e Andrade (2015) propõem três formas de compartilhar música para grupo. A primeira permitindo ao grupo compartilhar um lista de canções onde os membros podem contribuir adicionando canções do *YouTube*<sup>4</sup> ou votar nas músicas presentes na lista, desta forma as músicas mais votadas serão tocadas primeiro. A outra forma foi exibir uma lista de canções individualmente para as canções serem avaliadas em "gostei e "não gostei". Ao final é exibida ao grupo uma lista com as músicas que possuam avaliações de gostei em comum. A última forma consiste em uma *playlist* sugerida onde os membros deveriam solicitar para pular a canção caso ela os desagradassem, e se atingisse um número suficiente de pedidos, a música era trocada.

**Avaliação:** com três grupos, ao qual dois grupos foram formados por alunos de graduação ou pesquisadores da universidade de Vieira e Andrade (2015). Outro grupo, formado por colegas que utilizaram o sistema durante o tempo de lazer. Cada experimento teve duração de 5 dias, todos os participantes receberam orientação de como o sistema funcionava. Durante a realização dos experimentos o sistema solicitava uma avaliação de satisfação a cada 30 mim.

---

<sup>4</sup>[www.youtube.com](http://www.youtube.com)

Posteriormente os participantes participaram de uma entrevista semi estruturada.

Carvalho e Macedo (2014) e Hu (2014) fazem uma discussão sobre aspectos importantes na recomendação para grupo, tais como, estratégia de agregação, formas de avaliação e recomendação de sequência de itens. Carvalho e Macedo (2014) propõem também uma nova estratégia de agregação das preferências do grupo, utilizando Média Harmônica para recomendar filmes para grupos.

**Avaliação:** a nova estratégia foi testada com filtro colaborativo através da base *MovieLens*, e comparado com o método de K-Means<sup>5</sup>. Ainda foram gerados 28 grupos de 3 a 7 membros, e para cada recomendação gerada foi realizada uma comparação média de satisfação da recomendação de forma semelhante a Campos et al. (2009).

Hu (2014) utiliza filtros colaborativos baseados em modelo, usando rede neurais artificiais treinadas para classificar as preferências individuais assim criando um perfil para grupo, que é utilizado para produzir a recomendação de música.

**Avaliação:** Através de uma base *Taste Profile Dataset* que é um conjunto de dados de músicas reproduzidas por usuários da *Echo Nest*. Para cada canção recomendada, escolheram aleatoriamente 10 indivíduos para o grupo, considerando que estavam juntos pois possuíam músicas ouvidas em comum, tratando-as assim como se fossem as músicas ouvidas pelo grupo. A canção recomendada é avaliada por meio da quantidade de reproduções por cada indivíduo, tomando como métrica de satisfação, através da *Affinity Propagation* (propagação de afinidade, em português) onde o método de agrupamento das pontuações individuais é medido pela satisfação do grupo. Os resultados foram comparados com os do filtro colaborativo baseado em memória.

A Tabela 3 é um resumo dos trabalhos relacionados:

---

<sup>5</sup>Algoritmo de agrupamento e classificação de itens através de um conjunto K parâmetros

**Tabela 3:** Resumo dos trabalhos relacionados

TRABALHO	MÉTODO	AGREGAÇÃO	BASE UTILIZADA	AVALIÇÃO	GRUPOS
(CUNNINGHAM et al., 2014)	Filtro Baseado em Conteúdo	Técnica de MIR	Própria	<i>Feedback Explícito</i>	22 alunos formando 4 grupos
(MCCARTHY; ANAGNOST, 1998)	Filtro Baseado em conteúdo	Somatório das preferências individuais	Própria	<i>Feedback Explícito</i>	Não informado
(CAROLIS et al., 2014)	Filtro Colaborativo Baseado em Memória	Média Aritmética, da pontuação do questionário prévio	Própria	<i>Feedback Explícito</i>	8 turmas de 10 indivíduos
(CAMPOS et al., 2009)	Filtro Colaborativo Baseado em Memória	Redes Bayesianas	MovieLens	Técnica de Avaliação Cruzada	28 grupos criados através de critérios de filmes assistidos
(VIEIRA; ANDRADE, 2015)	Filtro Baseado em conteúdo	Através de votos	Própria	<i>Feedback Explícito</i> e entrevista	18 participantes divididos em 3 grupos
(CARVALHO; MACEDO, 2014)	Filtro Colaborativo Baseado em Memória	Média Harmônica	MovieLens	Comparação média das satisfações de recomendações anteriores	28 grupos de 3 a 7 membros
(HU, 2014)	Filtro Colaborativo Baseado Em Modelo	Rede Neural - URP Model	<i>Taste Profile</i> <i>Echo Nest</i>	<i>Affinity Propagation</i>	Grupos com 10 indivíduos aleatórios, comparando a satisfação das canções ouvidas anteriormente



## 2.5 SISTEMAS DE RECOMENDAÇÃO PARA GRUPOS

Neste capítulo, serão apresentados as principais características sobre recomendação especificamente para grupo. O fato da recomendação para grupo ter que considerar todas as preferências individuais dos membros do grupo torna-se um desafio maior que os sistemas tradicionais (CARVALHO; MACEDO, 2014) (MIRANDA; GONÇALVES, 2015)(CARVALHO, 2013).

Na literatura os autores dividem a problemática que é a recomendação para grupo em alguns critérios a serem tomados como orientação, que são: elicitación das informações de preferências do usuário, estratégia de agregação, explicação da recomendação e suporte a tomada de decisão final pelos usuários.

- **Elicitación das informações de preferências do usuário:** os sistemas de recomendação necessitam de informações dos membros do grupo sobre suas preferências com entrada. Essas preferências podem ser obtidas de forma direta (classificação, opinião, compras) ou de forma indireta, através de avaliação implícita (pesquisas realizadas, cliques, itens navegados).
- **Estratégia de agregação:** a escolha da forma de agregação é a mais estudada para sistema de recomendação para grupo (CARVALHO; MACEDO, 2014). Algumas estratégias precisam ser utilizadas e a escolha não é tarefa trivial (CARVALHO, 2013). A agregação é tão importante que será tratada com especial atenção na seção 2.5.1.
- **Explicação da recomendação:** A explicação da recomendação tem um papel importante, e deve ser usada para aumentar a credibilidade e aprovação (YAMASHITA, 2013). Ainda por Yamashita (2013), estudos com cinco sistemas de recomendação de música mostraram que os resultados de satisfação e credibilidade aumentaram quando utilizado algum mecanismo de explicação da recomendação. Observou-se então que não é um mecanismo para os membros do grupo aceitarem as recomendações realizadas, mas sim para melhorar a vista das informações para a tomada da decisão final.
- **Suporte à tomada de decisão final:** atualmente é a área menos estudada por pesquisadores, a maioria dos sistemas deixam a cargo do grupo a tomada de decisão final (CARVALHO, 2012). Os sistemas de recomendação em sua maioria tem mais papel de dar suporte à escolha do grupo ao invés de tomar a decisão (CARVALHO; MACEDO, 2014).

### 2.5.1 ESTRATÉGIA DE AGREGAÇÃO

A escolha deve tentar maximizar a satisfação, minimizar o desagrado, assegurar um grau de justiça satisfazendo igualmente todos do grupo e não permitir a manipulação forçando uma recomendação e assegurando compreensão e aceitabilidade (MIRANDA; GONÇALVES, 2015). Existem três formas de agregação (BORATTO; CARTA, 2010) (CARVALHO; MACEDO, 2014) (CARVALHO, 2013):


1. **Agregação de recomendação individual:** é a forma mais simples de resolver o problema de agregação, realizando a recomendação de uma pequena lista de itens para um indivíduo e posteriormente mesclando as recomendações adotando-as como geradas para grupo. Esta estratégia é utilizada por *Polylens* (O'CONNOR et al., 2001).
2. **Agregação de preferências individuais:** mais complexo que a anterior. Criando um pseudo perfil com todas as preferências dos indivíduos e gerando a recomendação (CARVALHO, 2013). Estratégia utilizada por *MusicFX* (MCCARTHY; ANAGNOST, 1998).
3. **Agregação de modelo de preferência:** utilizando todos os dados possíveis sobre as preferências dos indivíduos é criado um modelo representativo. Posteriormente esse modelo é utilizado para realizar a seleção dos itens a serem recomendados utilizando as referências das preferências semelhantes de recomendação anteriores (BORATTO; CARTA, 2010). Essa abordagem é próxima à aprendizagem automática (MIRANDA; GONÇALVES, 2015). E utilizada por (HU, 2014).

Existem outras estratégias que foram propostas, como a criação de um agente negociador, todos com o mesmo comportamento, onde cada agente pode aceitar ou recusar a recomendação, iniciando o processo de negociação (CARVALHO, 2013). Outra forma é a utilização de votos para aumentar a probabilidade de um item ser escolhido (VIEIRA; ANDRADE, 2015).

### 3 DESENVOLVIMENTO

No capítulo anterior, foram apresentados os principais critérios, a serem levados em considerações ao desenvolverem um sistema de recomendações para grupo. Nesse capítulo é exposto como foram empregados esses critérios no desenvolvimento da aplicação, capaz de recomendar música para um grupo de pessoas que compartilham o mesmo ambiente.

Por se tratar de uma aplicação que tem uma abordagem inovadora, é difícil prever todas as tarefas necessárias e dificuldades que serão encontradas durante o desenvolvimento. Por esse motivo os requisitos foram semanalmente definidos, criando uma lista de tarefas a serem realizadas para alcançar a meta da semana. Cada nova tarefa que possivelmente surja durante o desenvolvimento será então adicionada na lista de tarefas da próxima semana. Para controlar essas tarefas, foi utilizado o método de *Kanban*<sup>1</sup>, utilizando-se de cartões (*post-it*) para cada tarefa, e as separando em: “para executar”, “em andamento” ou “finalizado” conforme pode-se observar na Figura 5.



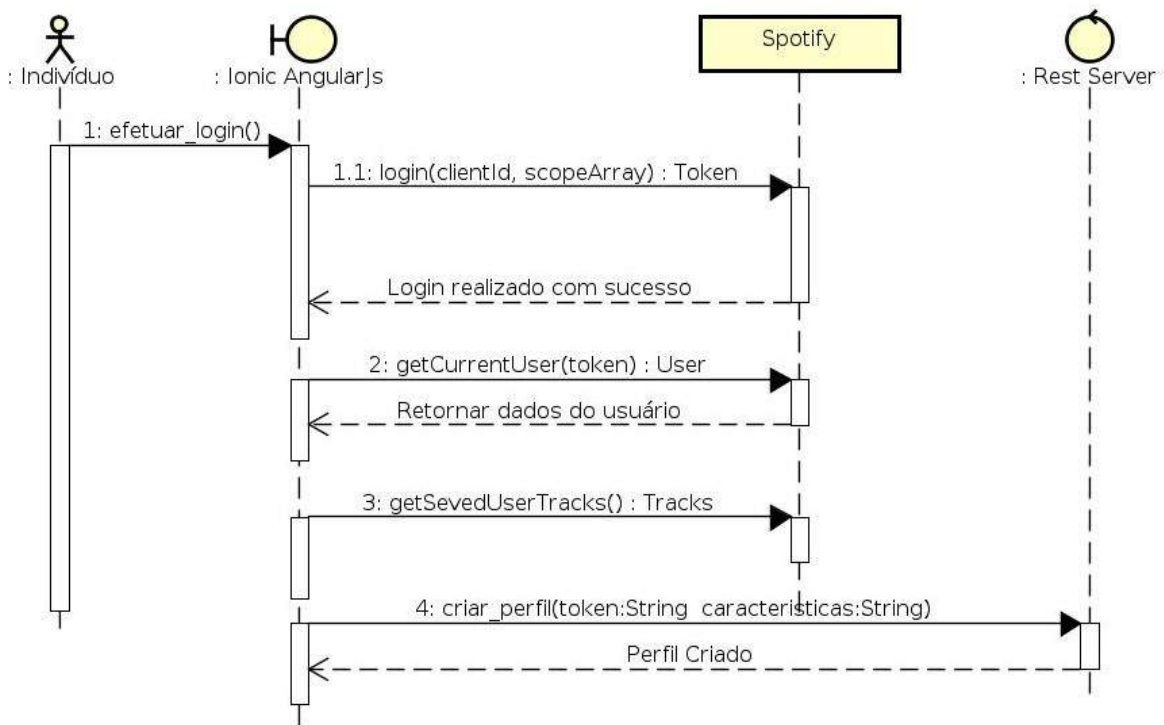
**Figura 5:** Kanban com as tarefas da semana

---

<sup>1</sup>Kanban originou-se nas fábricas de automóveis da Toyota para gestão das etapas de montagem do veículos e controle de estoque de forma visual através de cartões (KNIBERG; SKARIN, 2009).

### 3.1 FONTE DE INFORMAÇÃO

Como fonte de informações das preferências musicais dos indivíduos, foram utilizadas as canções salvas na biblioteca de músicas do indivíduo presentes no *Spotify*, recuperadas através da API do *Spotify*, como mostrado na Figura (6).



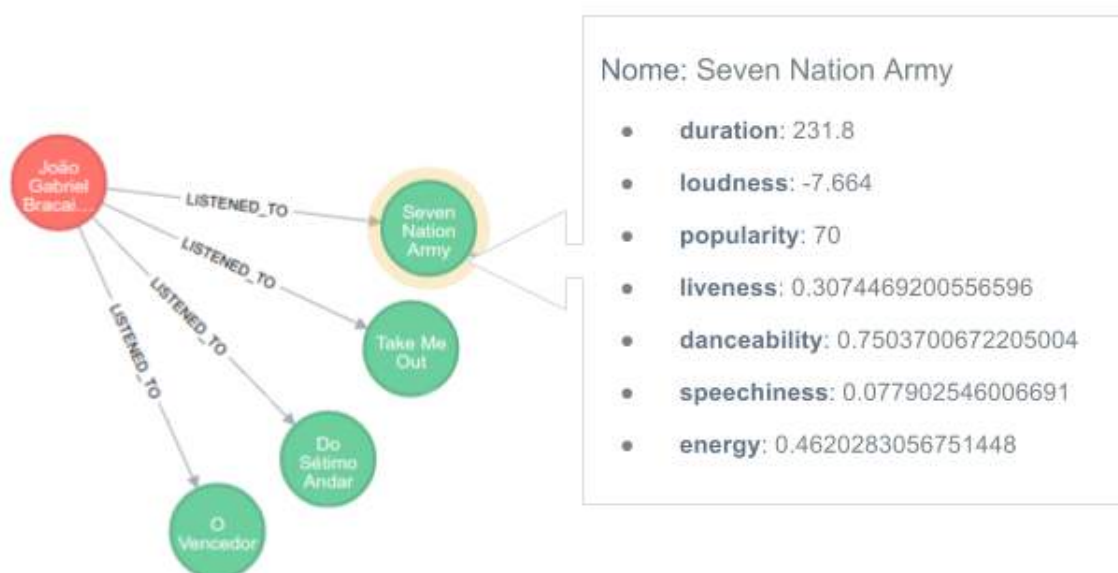
**Figura 6:** Diagrama de Sequência: Interação do indivíduo na criação do perfil

Essas canções foram definidas como as que mais agradam o indivíduo. Após a obtenção, as canções foram salvas em uma base de dados de grafos. Devido ao grau de relacionamento entre as canções ouvidas, artistas e gêneros, essa modelagem em grafo apresentou-se ser menos complexa do que uma base tradicional.

Conforme observado na Figura 7 cada canção ouvida foi armazenada com as seguintes métricas, obtidas através da API do *Spotify*:

- *Duration*: duração da música em milissegundo.
- *Danceability*: descreve o quão adequada uma faixa é para dançar. Com base em uma combinação de elementos musicais, incluindo tempo, ritmo, batidas fortes e regularidade em geral. Um valor de 0,0 é menos dançante e 1,0 é mais dançante (SPOTIFY, 2016). Essa informação é importante pois está diretamente relacionada com análise de contexto na recomendação.

- **Energy:** A energia é uma medida de 0.0 a 1.0 e representa uma medida de percepção de intensidade. Normalmente, canções energéticas são mais rápidas, com alta intensidade, e "barulhentas". Por exemplo death metal tem alta energia, enquanto uma pontuação de Bach tem baixa escala (SPOTIFY, 2016). Canções com alto nível energético são melhores aceitas no contexto de academia por exemplo (CAROLIS et al., 2014).
- **Popularity:** A popularidade é calculada pelo algoritmo e baseia-se, na maior parte, sobre o número total de execuções e quão recentes são. A popularidade é um valor entre 0 e 100, com 100 sendo o mais popular (NEST, 2016). A popularidade é a forma mais simples de recomendação, pois há uma boa chance de que canções mais populares combinem com as preferências de um grande número de indivíduos (VASILOUDIS, 2014).
- **Loudness:** do volume sonoro através de toda a música de uma faixa em decibéis (dB). São úteis para comparar volume relativo de faixas.
- **Speechiness:** detecta a presença de palavras faladas, por exemplo um *talk show*<sup>2</sup>, áudio livro, poesia, o valor será mais próximo de 1,0. Valores acima de 0,66 descrevem canções que provavelmente são feitas inteiramente de falas. Valores entre 0,33 e 0,66 descrevem canções que podem conter música e discurso, por exemplo músicas de rap. Valores abaixo de 0,33 representam, provavelmente, canções não-faladas (SPOTIFY, 2016).



**Figura 7:** Relacionamento do indivíduo com as músicas

<sup>2</sup>Tipo de programa televisivo ou programas de rádio em que são discutidos vários assuntos que são sugeridos possuindo um moderador

O Diagrama de Sequência consiste em um diagrama temporal que mostra mensagens trocadas entre objetos para realização de uma operação. A Figura 8 demonstra todo o processo envolvido na criação do perfil do indivíduo e os relacionamentos com suas músicas, artistas e gêneros.


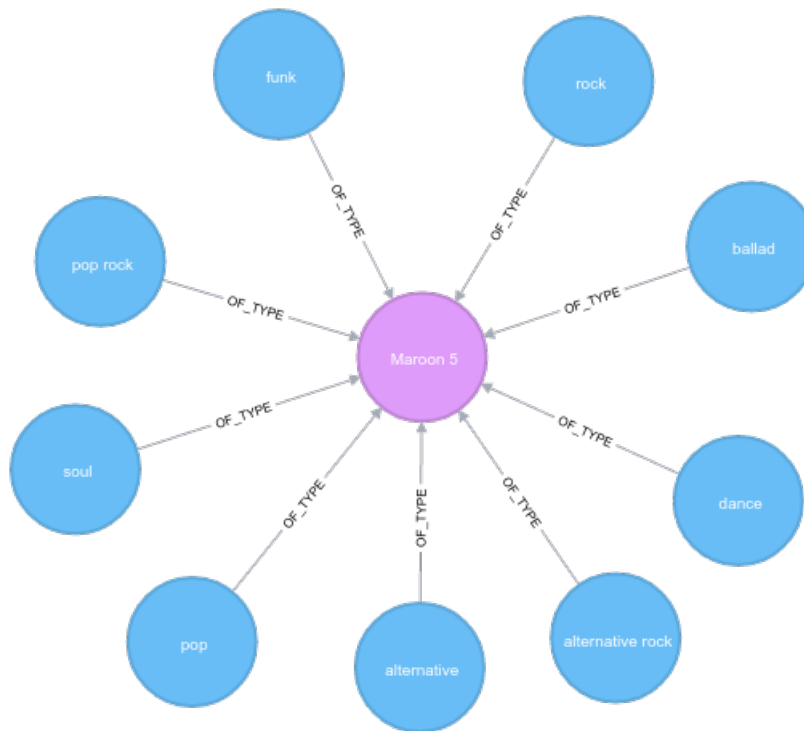


Figura 8: Diagrama de Sequência: Criação do perfil

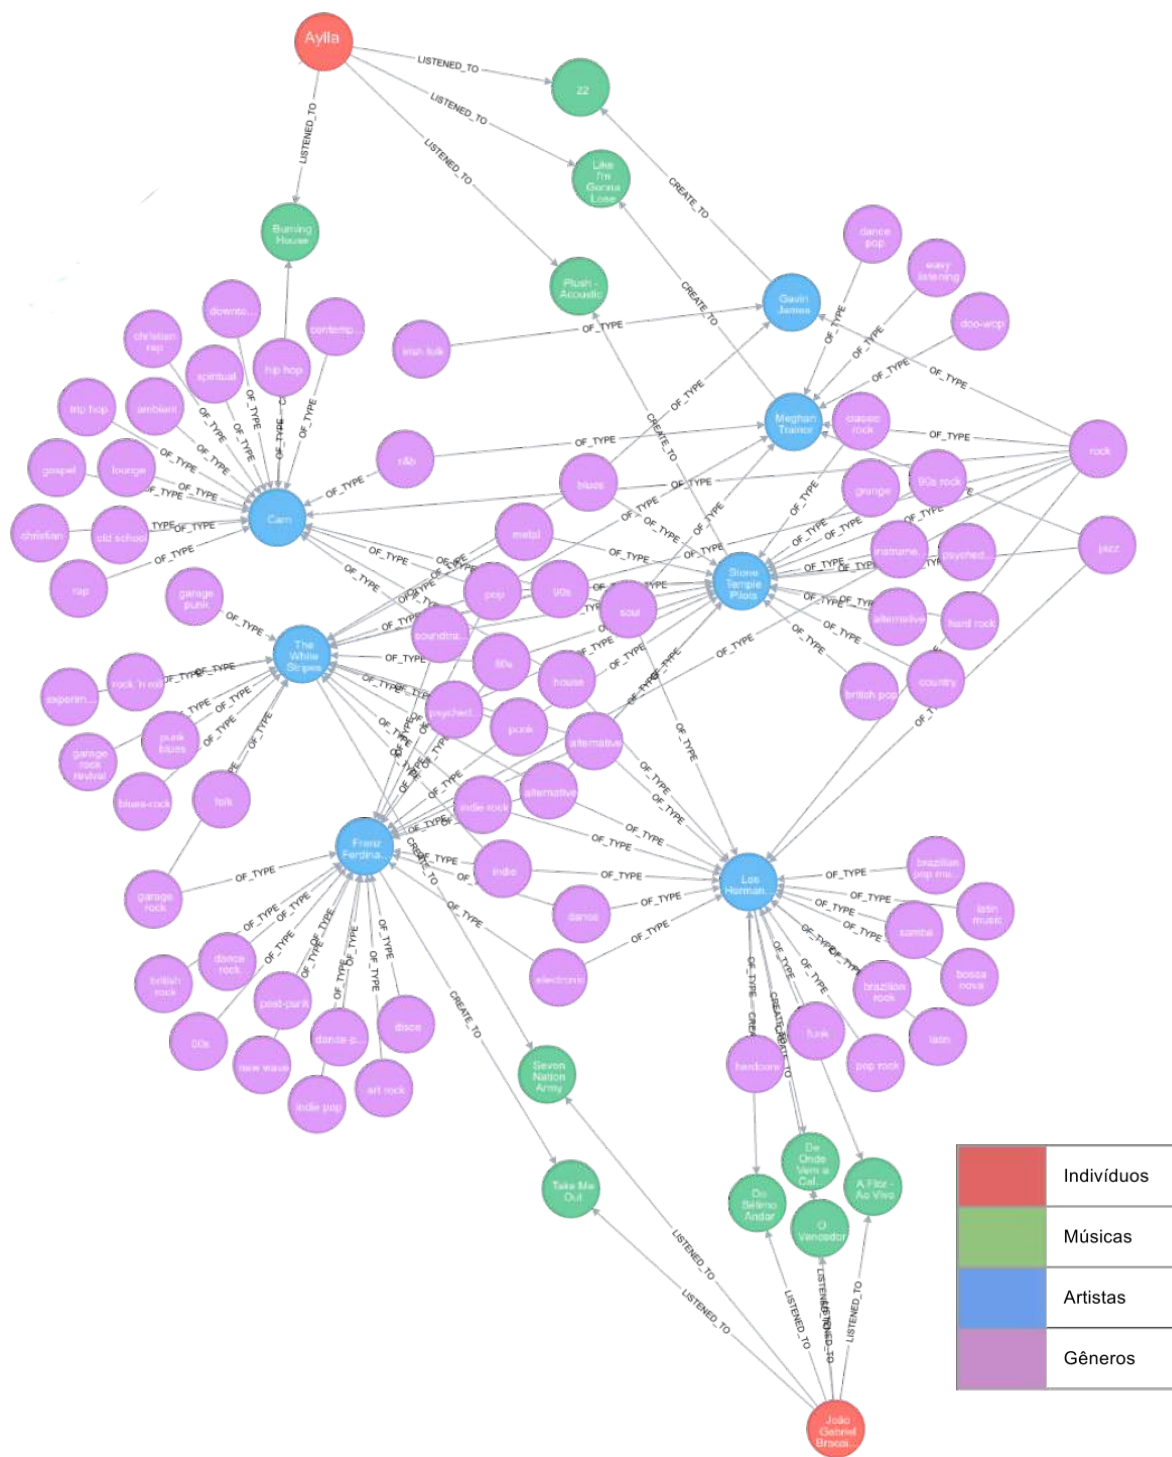
Cada canção é relacionada com seu artista através da aresta “OF TYPE”, que possui um peso que define a afinidade que o artista tem com o gênero, utilizando gêneros derivados fornecidos pela *Echo Nest*, obtendo maior distinção e melhor refinamento. Cada artista pode possuir *familiarity* e *hottness*, que são estimativas numéricas de quão popular o artista é atualmente na Internet. Essas informações também são fornecidas pela *Echo Nest*.

Podemos observar na Figura 9 o relacionamento criado entre artista e gênero derivados. Essas informações relacionadas farão parte de uma série de parâmetros para identificar características em comum entre os membros de um grupo.



**Figura 9:** Relação do artista com gêneros

Na Figura 10 mostra como as informações salvas no banco de dados de grafos estão interligadas e apresenta o retorno de uma consulta no Neo4j para dois indivíduos seus relacionamentos. Podemos observar as músicas ouvidas pelos indivíduos em verde, se relacionando com os artistas, que por sua vez possuem os artistas possuem gêneros. Como alguns artistas possuem gêneros em comum, podemos utilizar essas informações dos relacionamentos no processo de agregação.



**Figura 10:** Exemplo de relacionamento geral

### 3.2 AGREGAÇÃO E RECOMENDAÇÃO

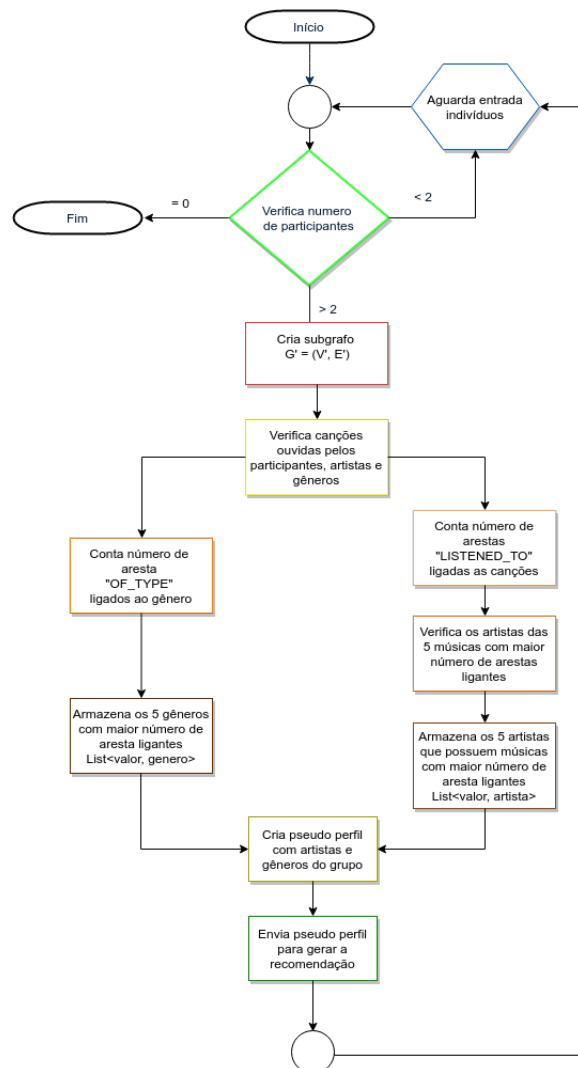
No processo de agregação, é necessário definir o que é um grupo e a estratégia de agregação mais adequada. Tomando o referencial teórico, grupo é um conjunto de dois ou mais



indivíduos reunidos no mesmo local ou que possuem interesses em comum (CARVALHO; MACEDO, 2014) (MIRANDA; GONÇALVES, 2015). Considera-se que essas pessoas partilham o mesmo ambiente num determinado momento, sem interesse explícito que as una umas às outras (MIRANDA; GONÇALVES, 2015).

Para a escolha de uma estratégia de agregação, faz-se necessário considerar as características do grupo e as vantagens e desvantagens de cada forma de agregação citadas na sessão 2.5.1. Através dos autores referenciados verifica-se, por estarmos tratando de preferências musicais, a agregação de preferências individuais criando um pseudo perfil para o grupo, mostrando-se a melhor forma de agregação.

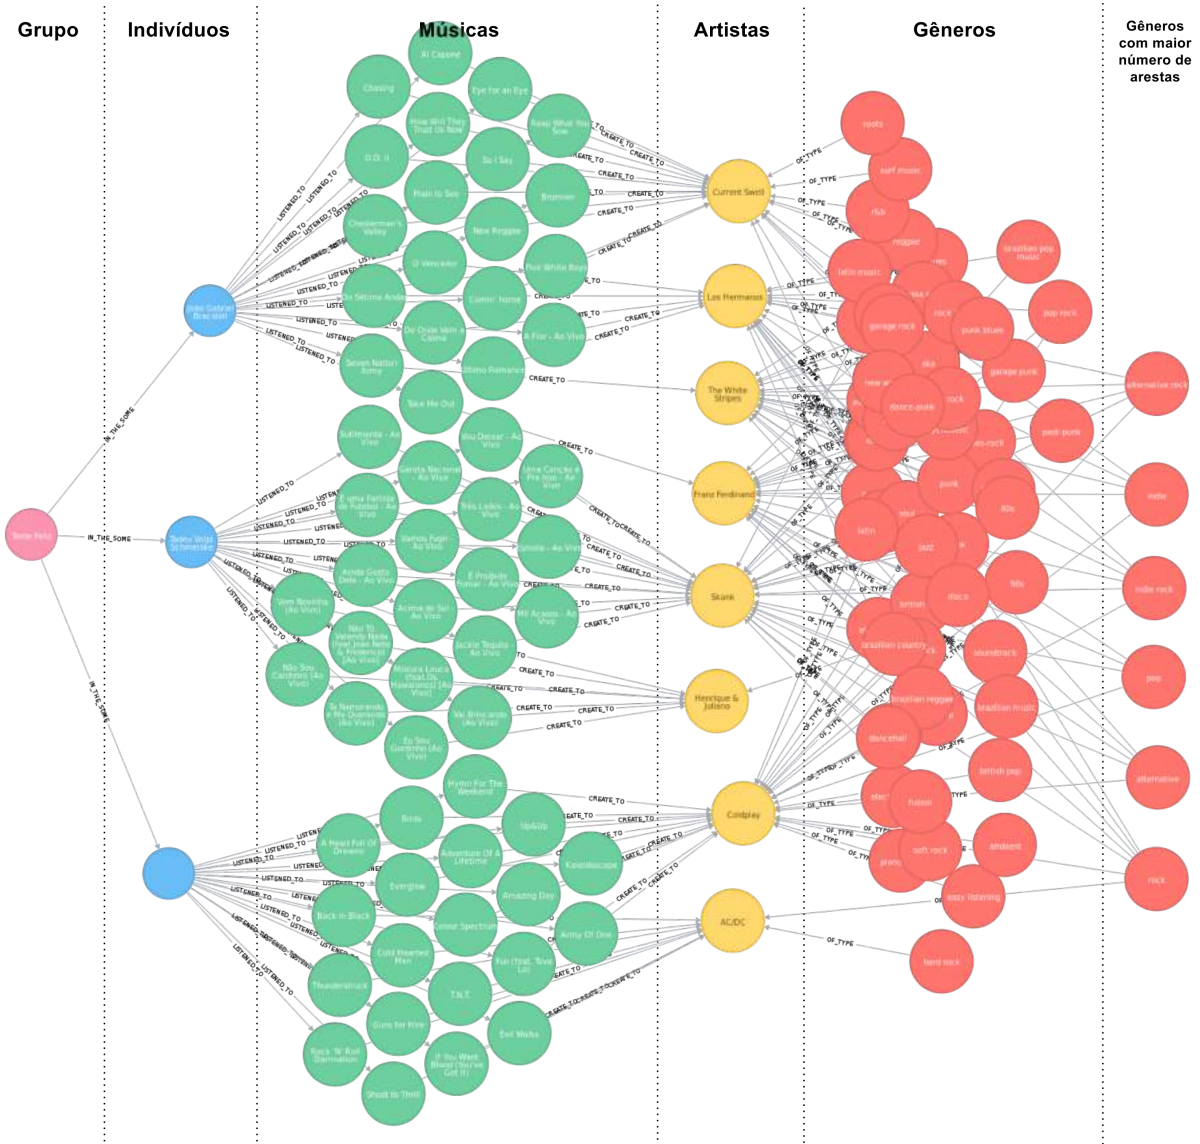
Na Figura 11 está exemplificado através de um fluxograma processos envolvidos na agregação, que inicia-se quando um indivíduo cria um grupo.



**Figura 11:** Fluxograma do processo de agregação.

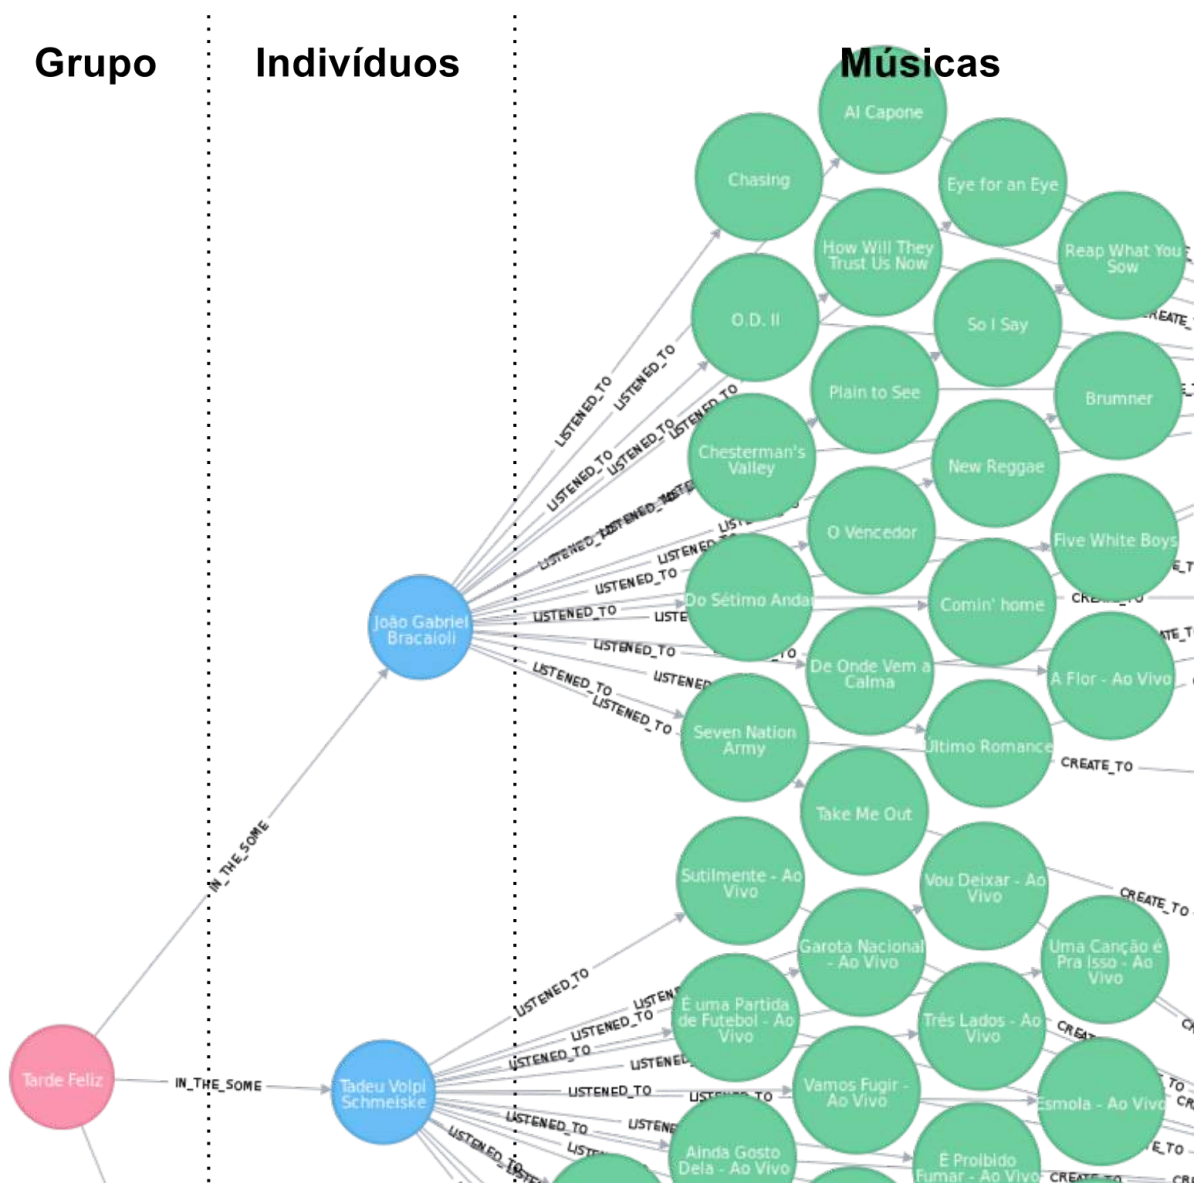
O processo de agregação inicia-se quando há dois ou mais participantes, criando-se um subgrafo  $G'=(V', E')$ , onde  $V'$  são todos os vértices pertencentes a esse grupo, ou seja, participantes, músicas ouvidas por esses indivíduos, artistas e gêneros e  $E'$  são as arestas que os ligam.

Na Figura 12 é demonstrado o subgrafo  $G'$  criado para o processo de agregação, com três indivíduos. A modelagem dos dados em forma grafo nos auxiliou através de ferramentas da linguagem Chypher Neo4j no processo de agregação.



**Figura 12:** Modelo para agregação de gêneros e músicas

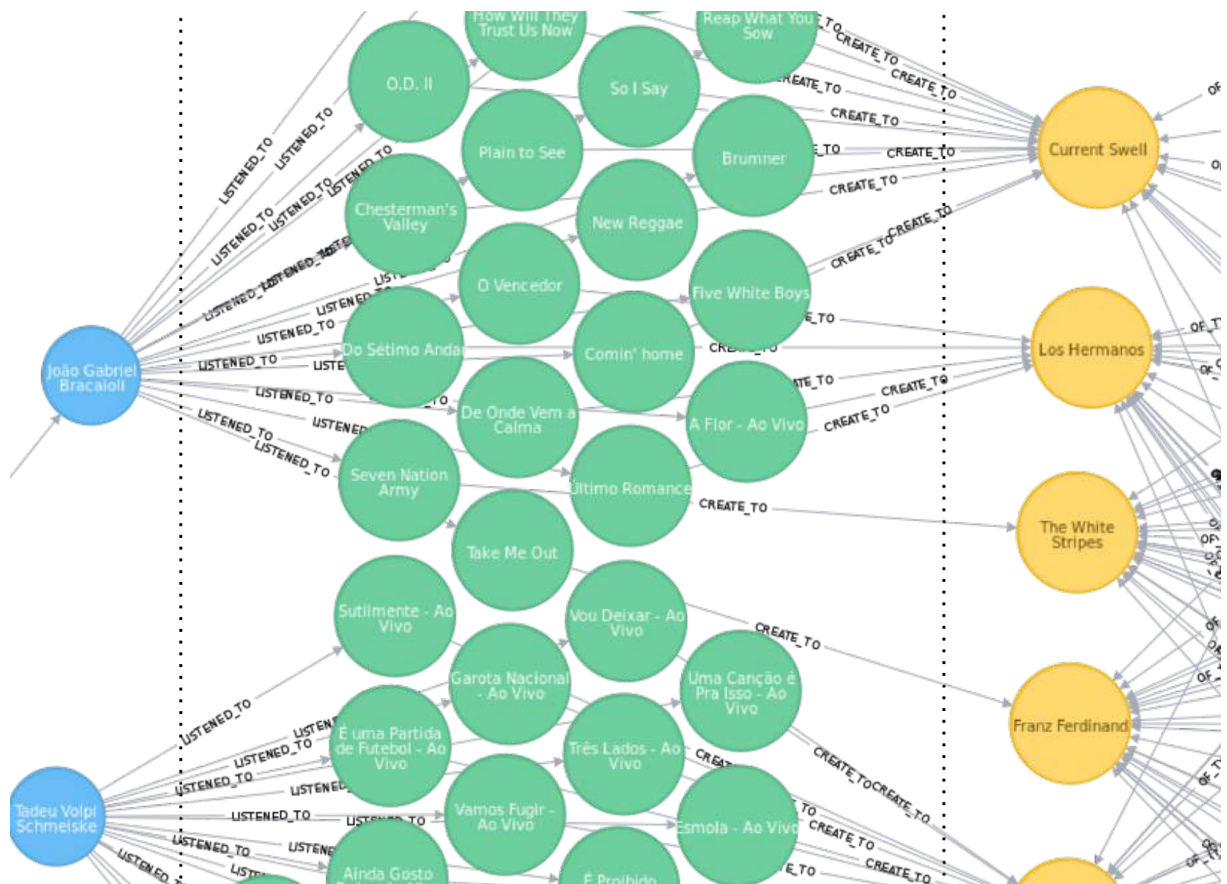
Podemos verificar na Figura 13 o resultado da criação do subgrafo  $G'$  em uma ponta de um vértice grupo, com três indivíduos ligados pela aresta “IN THE SOME” com as músicas ouvidas por eles.



**Figura 13:** Relacionamento Grupo, Indivíduo e Músicas

Para o processo de agregação das canções verifica-se quantos relacionamentos do tipo “LISTENED TO” (canções ouvidas pelo indivíduo) existem. Nesse caso, se uma canção tiver mais que uma aresta, significa que essa canção é ouvida por mais de um indivíduo do grupo. Das cinco canções que tiverem maior número de relacionamento, verifica-se quais são os artistas, utilizando assim os artistas ao invés das músicas ouvidas. Os artistas são utilizados ao invés das canções, pois pode-se obter mais informações, e um artista pode ter mais de uma música que possa agradar os indivíduos participantes desse grupo.

Na Figura 14 está demonstrado o relacionamento música com artistas. Nesse grupo os participantes não possuíam músicas em comum.

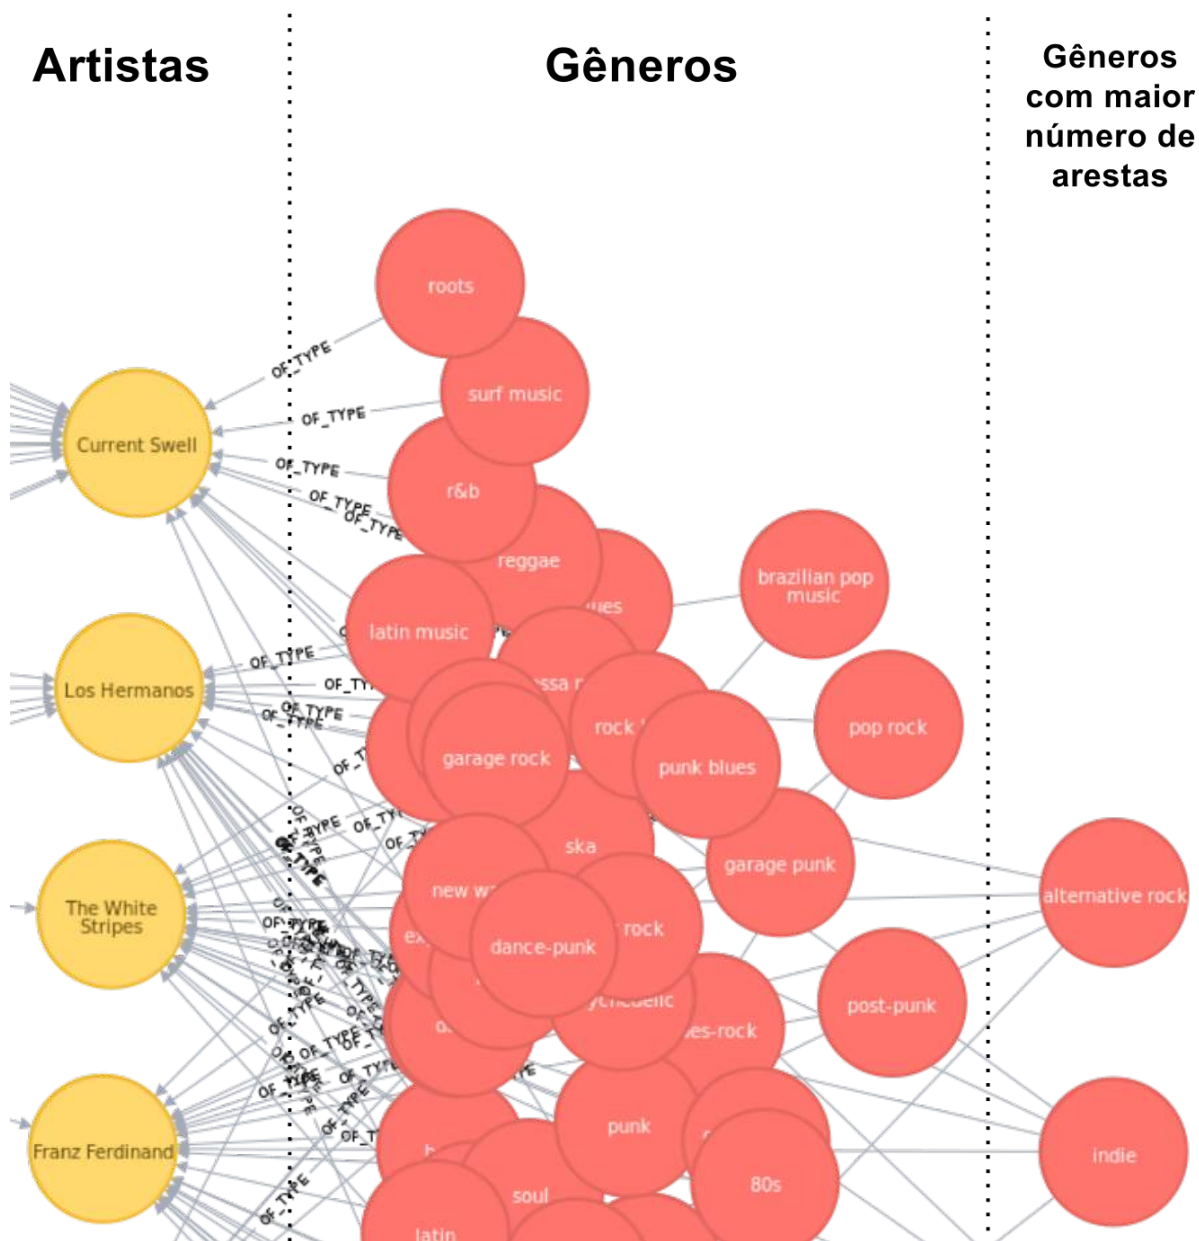


**Figura 14:** Relacionamentos utilizados para agregação de artistas

No processo de agregação por vértices gêneros verifica-se os que possuem maior número de arestas ligantes do tipo “OF TYPE”, são os vértices que os artistas possuem mais em comum, adotando os cinco gêneros com maior relacionamento como os que possuem maior afinidade com o grupo.

Na Figura 15 podemos verificar que para esse grupo, os gêneros que os artistas possuem mais em comum e serão considerados para o pseudo do perfil do grupo são: rock, alternative rock, alternative, indie rock e pop, sendo assim os que possuem maior afinidade para esse grupo. Cria-se então um pseudo perfil para o grupo com os cinco gêneros e artistas que possuem maior número de arestas ligantes, para ser utilizado posteriormente na recomendação.

No processo de agregação e recomendação, a seleção do contexto funciona como um filtro prévio à recomendação, fixando valores mínimos para as métricas das músicas. Nesse trabalho utilizamos o contexto através de feedback explícito separados nas seguintes categorias: Academia, Festa, Jantar, Restaurante e Viagem. Exemplificando o funcionamento do filtro pelo contexto, em um ambiente de festa, faz mais sentido músicas com alto nível de *danceability*, portanto ao selecionar festa, os valores mínimos de *danceability* é maior do que se selecionado



**Figura 15:** Relacionamentos utilizados para agregação dos gêneros

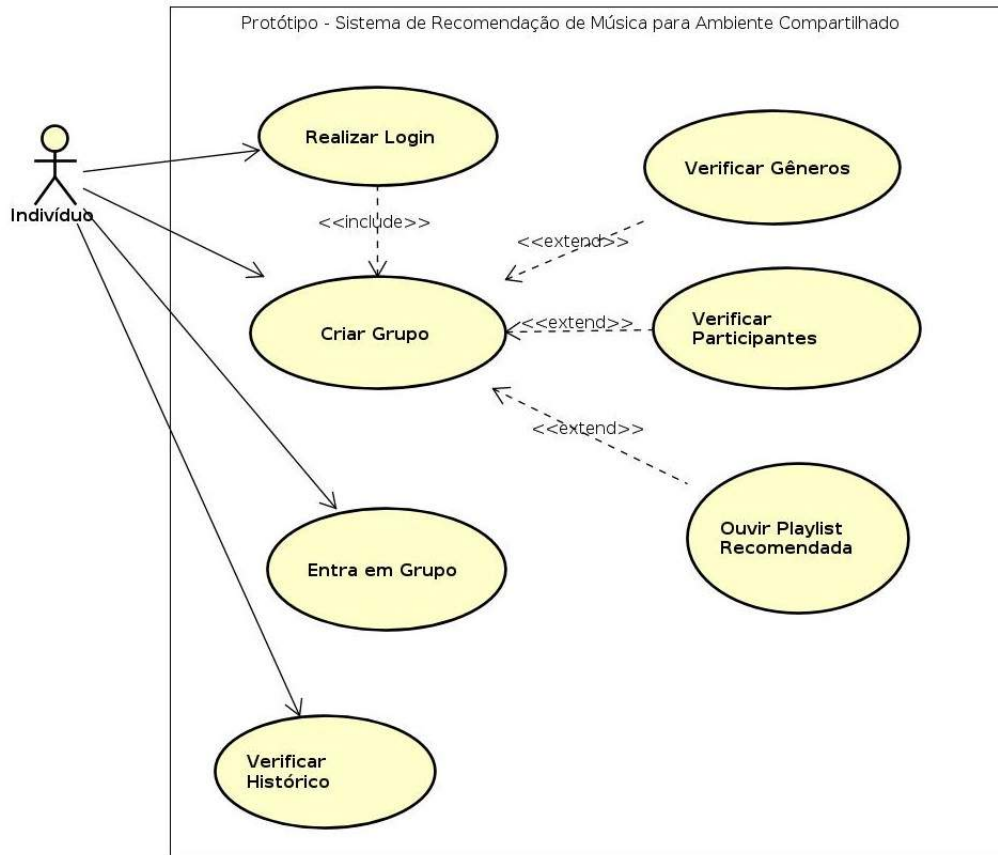
o contexto de viagem. Através das informações recolhidas, as recomendações são geradas utilizando o Spotify. Havendo informações suficientes, uma *playlist* será reproduzida. A definição de um contexto melhora a recomendação gerada (VASILOUDIS, 2014).

### 3.3 PROTÓTIPO E EXPLICAÇÃO DA RECOMENDAÇÃO

Um protótipo foi desenvolvido para viabilizar os testes e validar a forma de agregação, construída de forma híbrida, possibilitando o uso em *smartphones* (Android, iOS, Windows Phone) e Web.

A aplicação desenvolvida será denominada nesse trabalho pela abreviação SRMAC (Sistema de Recomendação de Música para Ambiente Compartilhado).

Na Figura 16 é demonstrado os casos de uso desenvolvido inicialmente para essa aplicação.



**Figura 16:** Diagrama de Caso de Uso do SRMAC

Utilizando a técnica de prototipagem rápida por meio de *Wireframe*, que são diagramas, ou esboços, com algum grau de detalhamento, que ajudam a entender de forma visual a organização e interação do seu software (SOLAZZI, 2004). Os *wireframes* do SRMAC foram realizados em papel para agilizar e flexibilizar o processo criativo. A Figura 17 mostra o *wireframe* criado para esse trabalho em conjunto com Davi Kawasaki, que possui maior experiência nessa técnica de prototipação.

A Figura 18 mostra a tela de entrada, onde o indivíduo tem a opção de baixar o aplicativo ou entrar com a conta do Spotify e a tela principal do sistema. A tela principal possui apenas três campos onde os indivíduos podem criar ou entrar em um grupo que está em sua proximidade geográfica, ou além disso, verificar o histórico de músicas.

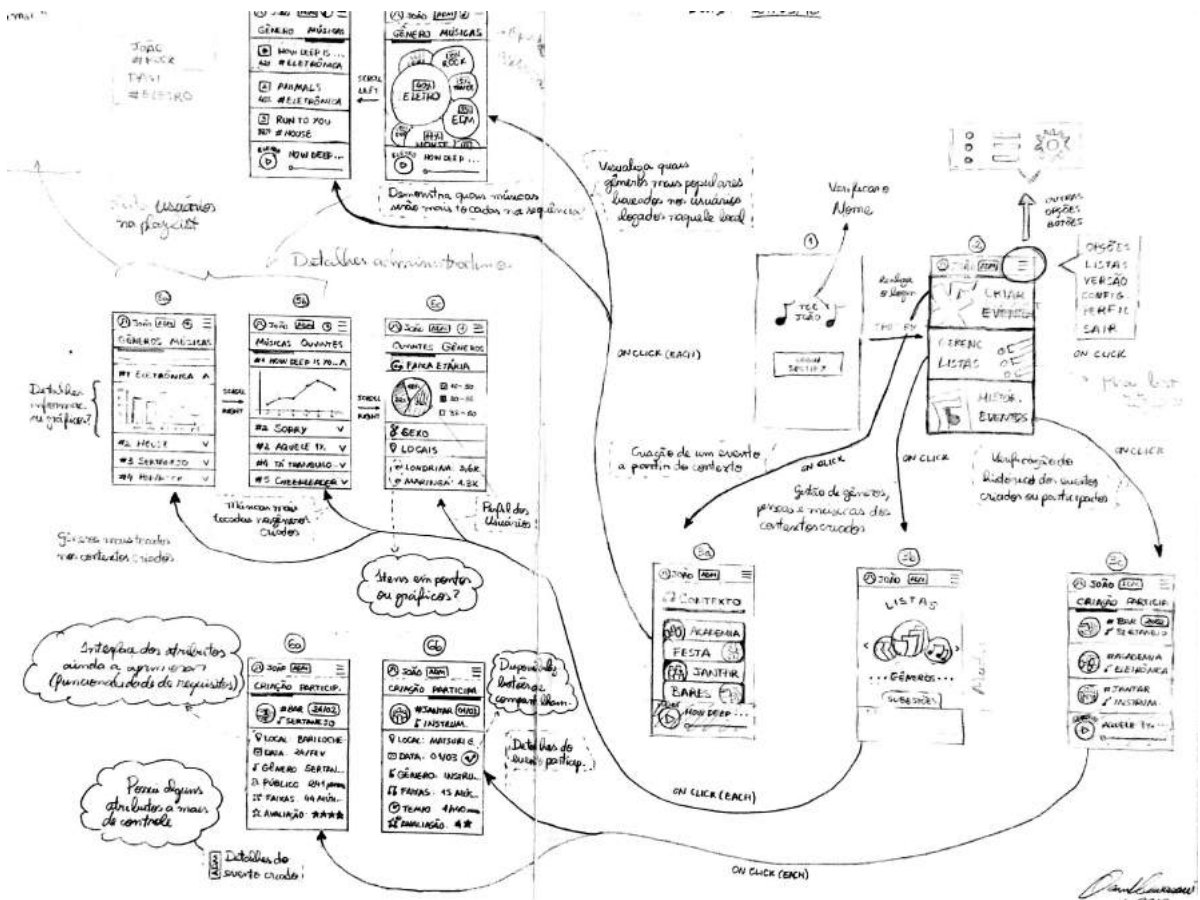


Figura 17: Wireframe, esboço inicial do aplicativo  
 Autor: Davi Kawasaki

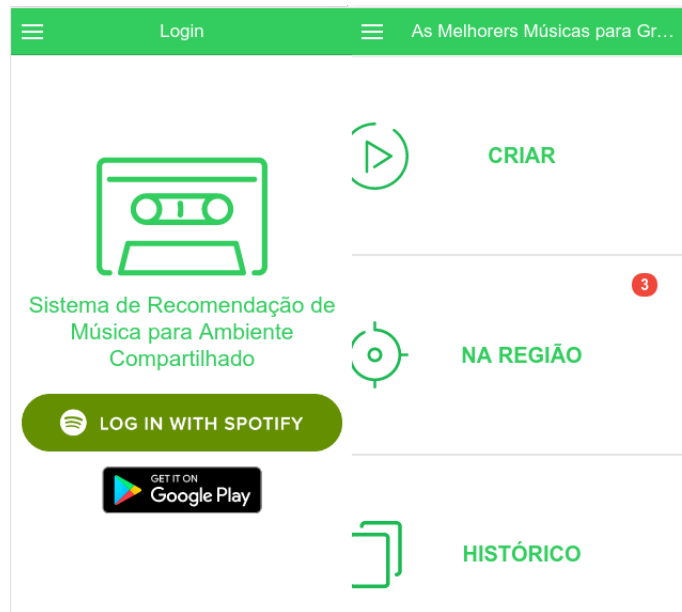


Figura 18: SRMAC: Login e Principal

**Figura 19:** SRMAC: Criar grupo.

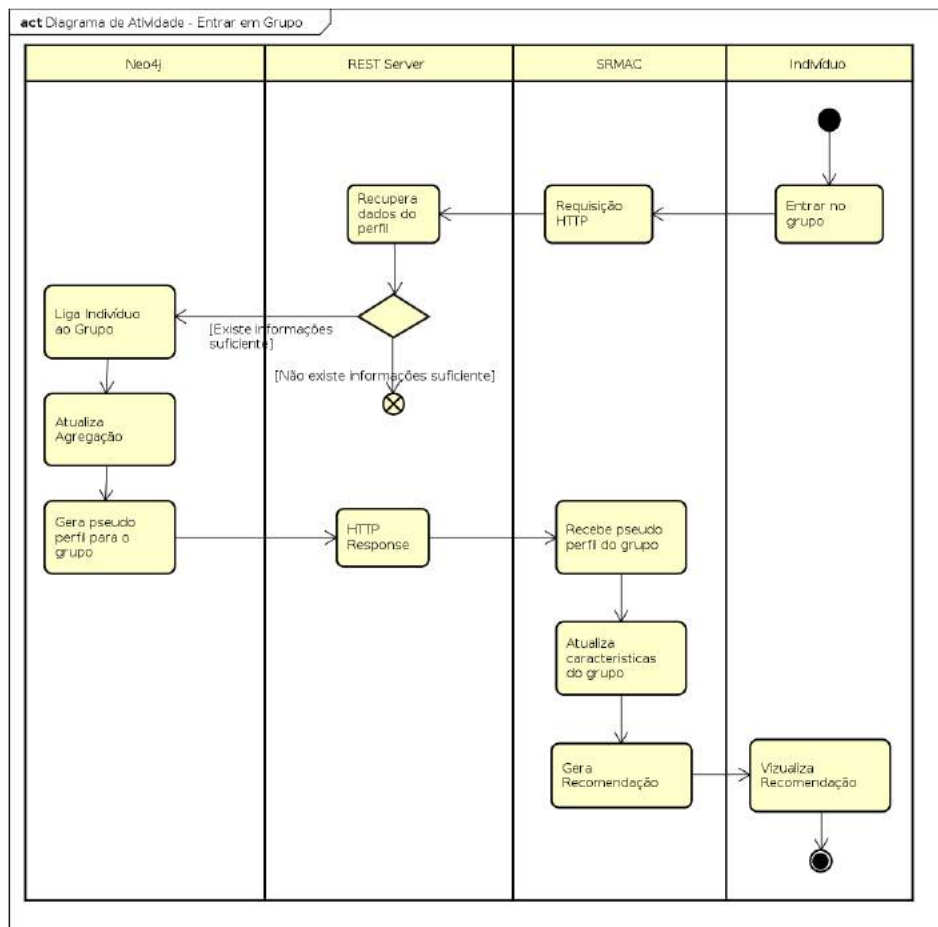
Na Figura 19 é demonstrado a tela de criação de um grupo possibilitando que os indivíduos se informem sobre o contexto, e a quantidade em horas que a *playlist* deverá ter. Após criar um grupo, ele fica disponível para outros membros acessarem o ambiente. Ao adentrar em um grupo, inicia-se uma série de processos para criar uma recomendação, para demonstração desse processo utilizo o Diagrama de Atividades.

O Diagrama de Atividades apresenta uma série de ações envolvidas em uma determinada operação mostrada de forma visual. A Figura 20 mostra o diagrama de atividades na operação de entrar no grupo, e essa operação integra todas as operações envolvidas no processo de recomendação.

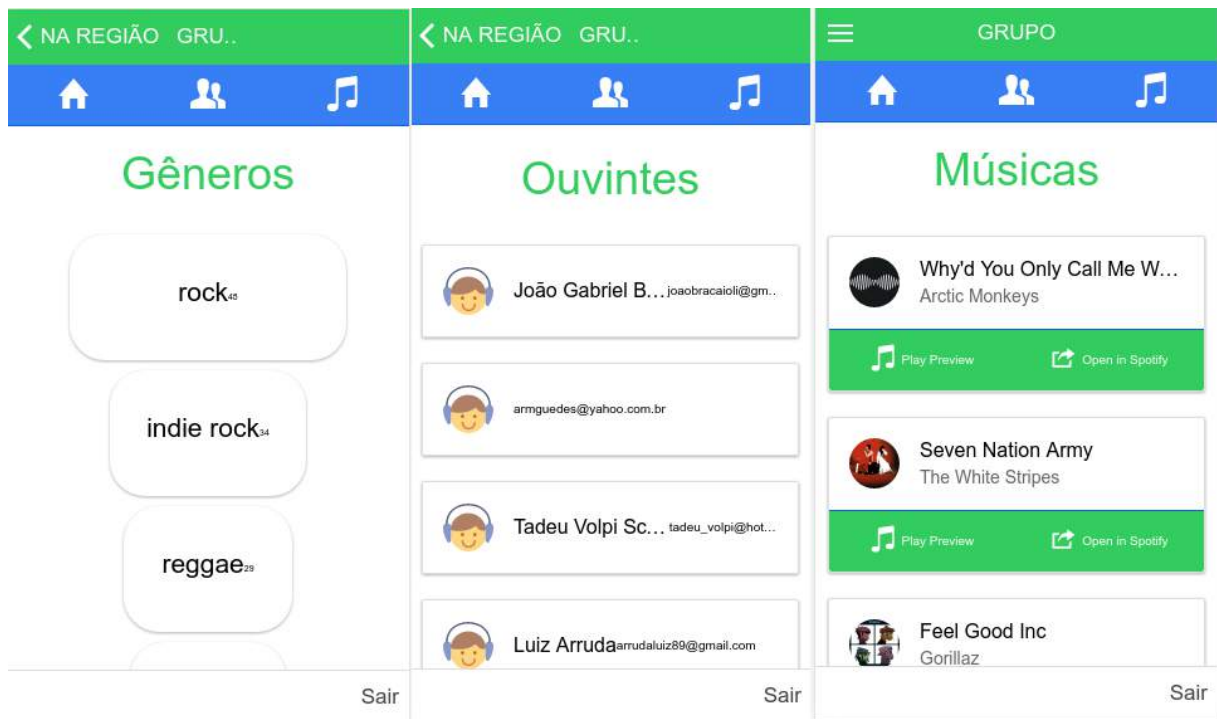
A recomendação é então gerada quando obtiver a quantidade suficiente de membros necessários, considerado um grupo. A cada novo membro, a *playlist* em execução é salva e uma nova *playlist* é gerada para que sejam consideradas as preferências do novo integrante, criando assim um histórico de recomendações para cada grupo que pode ser utilizado por trabalhos futuros.

A Figura 21 demonstra as telas do SRMAC ao adentrar em um grupo. Podemos verificar que, após a recomendação, o *player* apresenta o módulo de visualização, exemplificando cada gênero musical por um semi-círculo com número de relacionamento, e o tamanho do raio do semi-círculo, significa o peso que o gênero influenciou na recomendação, melhorando a usabilidade e aceitação dos indivíduos.





**Figura 20:** SRMAC: Processo de recomendação.



**Figura 21:** SRMAC: Grupo

### 3.4 TECNOLOGIAS UTILIZADAS

O serviço RESTful e o algoritmo de agregação foram desenvolvidos utilizando a linguagem de programação Java, por ser uma linguagem robusta, segura e amplamente consolidada, sobre tudo para os dispositivos móveis e web, além da familiaridade do autor com a mesma. O *framework* Java Spring MVC foi utilizado por possuir uma estrutura Web RESTful, suporte ao banco de dados grafo Neo4j, e por suas características de injeção de dependência, contribuindo para acelerar o processo de desenvolvimento.

Para trabalhar com as bases de grafo, foi escolhido o Neo4j, apesar de no começo do desenvolvimento ter sido utilizado o TitanDB<sup>3</sup> com Tinkerpop<sup>4</sup>, que é um conjunto de ferramentas que auxiliam na implementação de grafo. TitanDB até o presente momento está no processo de transição de versão e apresenta material de referência desconexo, o que dificultou o início dos trabalhos. Por sua vez o Neo4j apresenta um referencial melhor, auxiliando e facilitando o desenvolvimento. Outras bases como Cassandra<sup>5</sup> foram utilizadas como *storage layer* da aplicação, para gerenciamento dos dados, por ter escalabilidade e alta disponibilidade sem comprometer o desempenho. E a base MySQL foi escolhida para armazenar os *feedbacks* das avaliações.

Visando utilizar boas práticas de desenvolvimento de software, como integração contínua, análise do código e Deploy automático (MESO; JAIN, 2006) para melhorar a qualidade do código, foram utilizadas as seguintes ferramentas: Repositório Git<sup>6</sup>, Travis-CI<sup>7</sup>, Codacy<sup>8</sup> e Heroku<sup>9</sup>.

O Git é uma ferramenta de controle de versão, que registra alterações em arquivos, criando um histórico de alterações possíveis de reverter arquivos para o estado anterior e comparar mudanças ao longo do tempo (BIRD et al., 2009). Outra facilidade no uso dessa ferramenta é a utilização em conjunto com um repositório online, possibilitando ter um backup dos arquivos na Web. Para tanto, foi usando o GitHub<sup>10</sup> por ser *open-source*.

Integração contínua é uma prática para desenvolver software onde deve-se integrar seu trabalho com frequência, levando a múltiplas integrações por dia. Cada integração é verificada por meio de teste e compilação automatizada para detectar erros de integração o mais rápido

---

<sup>3</sup><http://titan.thinkaurelius.com/>

<sup>4</sup><http://tinkerpop.incubator.apache.org/>

<sup>5</sup><http://cassandra.apache.org/>

<sup>6</sup>[git-scm.com/](http://git-scm.com/)

<sup>7</sup>[travis-ci.org/](http://travis-ci.org/)

<sup>8</sup>[codacy.com/](http://codacy.com/)

<sup>9</sup>[herokuapp.com/](http://herokuapp.com/)

<sup>10</sup>[github.com/](http://github.com/)

possível (FOWLER; FOEMMEL, 2006). Travis-CI trata-se de uma ferramenta para auxiliar a integração contínua no desenvolvimento de software, certificando-se quando há atualização no software, como, por exemplo, é realizado os testes e compilação em ambiente construído a partir do zero, verificando o sucesso da execução (CI, 2012) .

Na Figura 22 são demonstradas as principais tecnologias utilizadas para melhorar o desenvolvimento e a aplicação.



**Figura 22:** Principais tecnologias utilizadas

Codacy é um serviço de revisão de código automatizado, que utiliza previsão para estimar a confiabilidade dos componentes de software, com seleção de padrão de código, fornecendo relatórios da qualidade do código e sugestões de melhorarias. Essas métricas são essenciais para melhorar a qualidade do código. Heroku é uma plataforma de serviços online, que permite a desenvolvedores executarem aplicações em nuvem, disponibilizando ferramentas para melhor performance e monitoramento (SCHNEEMAN, 2013), no qual o serviço criado está hospedado.

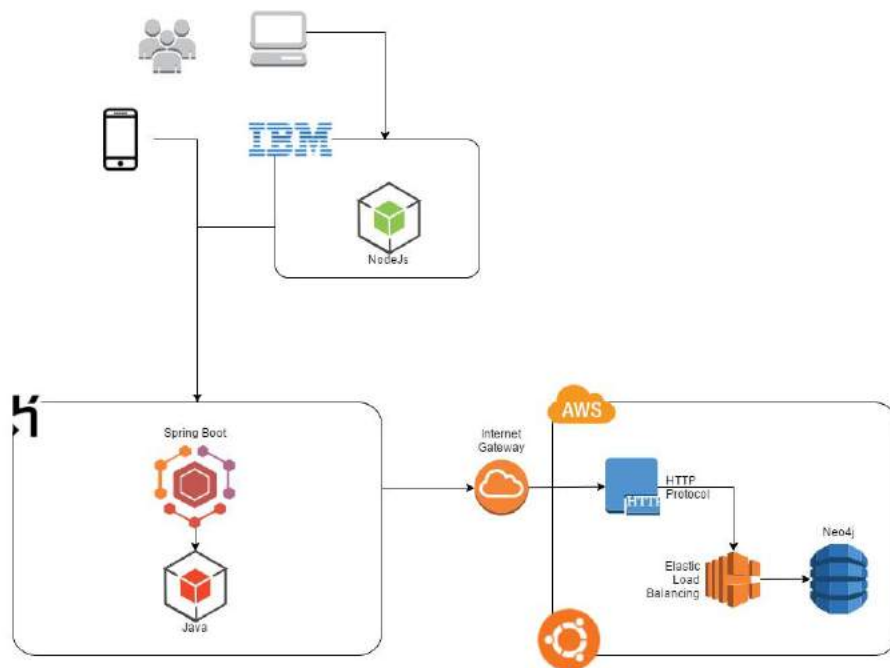
Para o desenvolvimento do SRMAC, foi utilizado o *framework* Ionic SDK, que possibilita a construção de aplicativos móveis de forma híbrida usando tecnologias Web como HTML, CSS, JavaScript com Cordova, sendo escolhido por ter sua construção utilizando bibliotecas do AngularJS, ao qual o autor possui conhecimento. AngularJS é um *framework* JavaScript *open-source* desenvolvido pela Google, com o intuito de simplificar o desenvolvimento de aplicações,

apresentando um nível maior de abstração para o desenvolvedor *single-page application*.

A API do *Spotify* foi escolhida para a aplicação, pois trata-se de um *player* de música que está em expansão (SPOTIFY, 2015), além de apresentar uma boa implementação em Java e documentação de apoio ao seu uso. A API da Echo Nest também foi escolhida por possuir uma ampla variedade de recursos e informações sobre músicas e artistas. Ambas as APIs são de fácil integração com outras aplicações REST.

Sendo o objetivo deste trabalho disponibilizar um serviço Web, o mesmo estará disponível através do endereço `musicaparagrupo.com.br`, ficando hospedado em servidores NodeJs da IBM<sup>11</sup>. A parte do Serviço REST está hospedada no Heroku, e toda a parte de banco de dados na AWS Elastic EC2 da *Amazon*<sup>12</sup>, que oferecem capacidade de computação em nuvem redimensionável, isolando a aplicação de situações de falhas comuns.

A Figura 23 mostra a distribuição como os serviços por trás da aplicação ficaram distribuídos.



**Figura 23:** Distribuição dos serviços.

<sup>11</sup>[console.ng.bluemix.net](https://console.ng.bluemix.net)

<sup>12</sup>[aws.amazon.com/pt/ec2](https://aws.amazon.com/pt/ec2)

## 4 EXPERIMENTOS

No intuito de avaliar o desempenho do sistema desenvolvido foram realizados alguns experimentos com usuários em ambientes controlados. Os experimentos foram realizados com grupos compostos por estudantes de graduação da Universidade Tecnológica Federal do Paraná.

### 4.1 VALIDAÇÃO DO CONTEXTO DOS INDIVÍDUOS


Nesta seção são apresentados os experimentos realizados que têm como objetivo validar os contextos apresentados nesse trabalho, se eles são condizentes com os quais os indivíduos normalmente costumam ouvir músicas em grupo. Para fazer essa avaliação foi realizado um questionário apresentado na Figura 25.



The image shows a web form for a music recommendation system. The title is "Sistema de Recomendação de Música para Ambientes Compartilhados". Below the title, there is a red asterisk and the word "Obrigatório" (Mandatory). The form contains three input fields: "Nome:" with a placeholder "Sua resposta", "Data de nascimento:" with a date format "dd/mm/aaaa", and "E-mail:" with a placeholder "Sua resposta". Below these fields is a question: "Em quais desses ambientes você costuma ouvir música com grupos?". This is followed by a list of six options, each with a checkbox: "Bares/Restaurantes", "Festas", "Almoços/Jantares", "Academia", "Viagens", and "Outros".

**Figura 25:** Questionário para validação do contexto

Participaram do questionário 20 indivíduos, sendo 17 do sexo masculino, 3 do sexo feminino, com idade média de 23 anos. Na Figura 26 são apresentados os resultados do questionário.



**Figura 26:** Ambientes onde ouve-se música em grupo

Podemos observar na Figura 26 que os ambientes presentes no SRMAC estão de acordo com ambientes onde costuma-se ouvir música em grupo com mais frequência.

## 4.2 VALIDAÇÃO DAS RECOMENDAÇÕES PARA DIFERENTES CONTEXTOS

Nesta seção são apresentados os experimentos realizados que têm como objetivo validar as recomendações realizadas em cada contexto (Academia, Festa, Restaurante, Trabalho, Viagem).

Os participantes receberam instruções básicas do funcionamento do SRMAC e como funcionaria a dinâmica do experimento. Nenhum dos participantes tinha conhecimento dos detalhes específicos, da forma como as recomendações são geradas e como as preferências foram agregadas. Todos os participantes concordaram em usar o sistema para a execução do experimento, e terem seus dados coletados durante este tempo.

Durante as experiências, uma *playlist* de 20 músicas era gerada para o administrador do grupo e essas músicas sugeridas eram ouvidas com os demais participantes. Ao final, os participantes avaliaram a satisfação geral com o sistema e a recomendação.


Participaram desses experimentos 20 indivíduos, sendo 16 do sexo masculino, 4 do sexo feminino, com idade média de 23 anos.

### 4.2.1 ACADEMIA

No contexto Academia foram realizados os experimentos com 4 indivíduos do sexo masculino com idade média de 24 anos, que frequentam diariamente a academia no mesmo horário. Para realização dos experimentos os participantes foram divididos em dois grupos e ouviram a *playlist* recomendada durante a realização dos exercícios através do *smartphone* do


administrador do grupo, com duração de 1 hora.

Na Figura 27 estão apresentados os resultados das avaliações realizadas por esses indivíduos para as recomendações realizadas no contexto Academia. Esses votos (onde 0 representa insatisfeito e 5 significa muito satisfeito) foram realizados com relação ao nível de satisfação com as músicas recomendações.



**Figura 27:** Resultado da avaliação de satisfação da recomendação no ambiente de academia

A Figura 28 apresenta os resultados das avaliações realizadas por esses indivíduos em relação ao quanto eles consideraram adequado as músicas de acordo com o contexto (onde 0 representa inadequadas e 5 significa adequadas).



**Figura 28:** Resultado da avaliação de quão adequadas foram as recomendação para o ambiente de academia


#### 4.2.2 BAR/RESTAURANTE

Neste contexto, foi utilizado o ambiente de Bar/Restaurante com 3 indivíduos, 2 do sexo masculino e 1 do sexo feminino, com idade média de 22 anos, que frequentaram um restaurante próximo a universidade e ouviram as recomendações durante o período de lazer, com duração de aproximadamente 1 hora.

Na Figura 29 estão apresentados os resultados das avaliações realizadas por esses indivíduos para as recomendações realizadas no contexto Bar/Restaurante. Os indivíduos votaram




(onde 0 representa insatisfeito e 5 significa muito satisfeito) em relação ao nível de satisfação com as músicas recomendadas.



**Figura 29:** Resultado da avaliação de satisfação da recomendação no ambiente de bar/restaurante

A Figura 30 apresenta os resultados das avaliações realizadas por esses indivíduos em relação ao quanto eles consideraram adequadas as músicas recomendadas de acordo com o contexto (onde 0 representa inadequadas e 5 significa adequadas).



**Figura 30:** Resultado da avaliação de quão adequadas foram recomendação para o ambiente de bar/restaurante


#### 4.2.3 FESTA

Os experimentos no contexto Festa foram realizados durante o período de lazer dos amigos do autor em um ambiente de festa, com 8 indivíduos, sendo 6 do sexo masculino e 2 do sexo feminino, com idade média de 23 anos. Foram realizadas três recomendações diferentes, onde na primeira recomendação o grupo estava formado por 4 indivíduos, 3 do sexo masculino e 1 do sexo feminino. Após o período de 30 minutos, outra recomendação foi gerada com a entrada de mais dois integrante no grupo do sexo masculino.

Por fim, uma terceira recomendação foi gerada com a chegada de um integrante do sexo masculino e outro do sexo feminino no grupo. O experimento teve duração aproximada de


3 horas, e foram ouvidas nesse caso 50 músicas recomendadas no total.

Na Figura 31 estão apresentados os resultados das avaliações realizadas para as recomendações de músicas no contexto Festa. Os indivíduos votaram (onde 0 representa insatisfeito e 5 significa muito satisfeito) em relação ao nível de satisfação com as músicas recomendadas.



**Figura 31:** Resultado da avaliação de satisfação da recomendação no ambiente de festa

A Figura 32 apresenta os resultados das avaliações realizadas por esses indivíduos em relação ao quanto eles consideraram adequadas as músicas recomendadas de acordo com o contexto (onde 0 representa inadequadas e 5 significa adequadas).



**Figura 32:** Resultado da avaliação de quão adequadas foram as recomendações para o ambiente de festa


#### 4.2.4 TRABALHO

Neste contexto, foi utilizado o ambiente de trabalho, onde os experimentos foram realizados com dois grupos.

O primeiro grupo é composto por pesquisadores que trabalham no Laboratório de Computação e Tecnologia Musical da Universidade Tecnológica Federal do Paraná, com 5


indivíduos, sendo 3 do sexo feminino e 2 do sexo masculino, com idade média de 22 anos. O grupo ouviu as recomendações durante uma tarde em que estavam reunidos no laboratório, realizando as suas atividades.

Na Figura 33 estão apresentados os resultados das avaliações realizadas por este grupo, para as recomendações de músicas no contexto Trabalho. Os indivíduos votaram (onde 0 representa insatisfeito e 5 significa muito satisfeito) em relação ao nível de satisfação com as músicas recomendadas.



**Figura 33:** Resultado da satisfação do primeiro grupo da recomendação no ambiente de trabalho

A Figura 34 apresenta os resultados das avaliações realizadas pelo primeiro grupo em relação ao quanto eles consideraram adequadas as músicas recomendadas de acordo com o contexto (onde 0 representa inadequadas e 5 significa adequadas).




**Figura 34:** Resultado da avaliação do primeiro grupo, para quão adequadas foram as recomendações para o ambiente de trabalho

O segundo grupo são da empresa chamada Rais Data, incubada na universidade, com três indivíduos, 2 do sexo masculino e 1 do sexo feminino, com idade média de 21 anos. Os


grupos ouviram as *playlists* durante um dia normal de trabalho, onde o experimento teve duração aproximadamente de 1 hora.

Na Figura 35 estão apresentados os resultados obtidos das avaliações realizadas pelo segundo grupo, para as recomendações de músicas no contexto Trabalho. Os indivíduos votaram (onde 0 representa insatisfeito e 5 significa muito satisfeito) em relação ao nível de satisfação com as músicas recomendadas.



**Figura 35:** Resultado da avaliação de satisfação do segundo grupo da recomendação no ambiente de trabalho

A Figura 36 apresenta os resultados das avaliações realizadas pelo segundo grupo em relação ao quanto eles consideraram adequadas as músicas recomendadas de acordo com o contexto (onde 0 representa inadequadas e 5 significa adequadas).




**Figura 36:** Resultado da avaliação do segundo grupo, para quão adequadas foram as recomendações no ambiente de trabalho

#### 4.2.5 VIAGEM

Neste contexto foi utilizado o ambiente de viagem, onde foram realizados dois experimentos com dois grupos de três indivíduos, todos do sexo masculino com idade média de 23 anos. Os experimentos foram efetuados durante uma viagem de ida e volta a Londrina-PR, com duração média de 50 minutos em cada viagem, gerando uma recomendação na ida, e outra outra recomendação na volta.

Na Figura 37 estão apresentados os resultados obtidos das avaliações realizadas pelo primeiro grupo para as recomendações de músicas realizadas no contexto Viagem. A avaliação ocorreu somente ao término da viagem de volta. Os indivíduos votaram (onde 0 representa insatisfeito e 5 significa muito satisfeito) em relação ao nível de satisfação com as músicas recomendadas.




**Figura 37:** Resultado das avaliação do primeiro grupo, para as recomendação no ambiente de viagem


A Figura 38 apresenta os resultados das avaliações realizadas pelo primeiro grupo em relação ao quanto eles consideraram adequadas as músicas recomendadas de acordo com o contexto (onde 0 representa inadequadas e 5 significa adequadas).

Na Figura 39 estão apresentados os resultados obtidos das avaliações realizadas pelo primeiro grupo para as recomendações de músicas realizadas no contexto Viagem. A avaliação ocorreu somente ao término da viagem de volta. Os indivíduos votaram (onde 0 representa insatisfeito e 5 significa muito satisfeito) em relação ao nível de satisfação com as músicas recomendadas.


A Figura 40 apresenta os resultados das avaliações realizadas pelo segundo grupo em relação ao quanto eles consideraram adequadas as músicas recomendadas de acordo com o contexto (onde 0 representa inadequadas e 5 significa adequadas).



**Figura 38:** Resultado das avaliação do primeiro grupo, para quão adequadas as recomendações foram no ambiente de viagem



**Figura 39:** Resultado das avaliação do segundo grupo, para as recomendação no ambiente de viagem



**Figura 40:** Resultado das avaliações do segundo grupo, para quão adequadas as recomendações foram no ambiente de viagem

#### 4.2.6 ANÁLISE GERAL DOS RESULTADOS


Nesta seção estão apresentados os resultados consolidados dos experimentos realizados. Na Figura 41, são apresentados os dados obtidos sobre o nível de satisfação das recomendações

geradas durante todos os experimentos. Pode-se observar que no geral, as recomendações realizadas para cada ambiente teve um nível de satisfação alto, o que valida que as recomendações geradas satisfazem os indivíduos.



**Figura 41:** Nível de satisfação das recomendações realizadas

Na Figura 42, são apresentados os dados consolidados obtidos na pesquisa que indicam se as músicas são condizentes com o contexto que estão ouvindo-as. Pode-se observar, que mesmo com as recomendações geradas para diferentes ambientes, obtive um nível de adequação alto.



**Figura 42:** Níveis de adequação das músicas recomendadas ao ambiente

Em todos os grupos o objetivo foi estudar o uso da recomendação de música para grupo na rotina dos indivíduos.

#### 4.3 VALIDAÇÃO DOS PARÂMETROS DE CONTEXTO

Nesta seção são apresentados os experimentos realizados que tm como objetivo validar se os parâmetros utilizados na seleção do contexto, que funcionam como um filtro prévio, fixando valores mínimos para métricas das músicas, realmente influenciavam na satisfação das músicas recomendadas. Para tanto, foram escolhidos dois contextos sendo possível executar os testes diariamente, portanto os experimentos foram realizados somente para os ambientes de trabalho e academia.

Os participantes dessa fase são da empresa chamada 2DVerse, incubada na mesma

universidade, que utilizaram o sistema durante os dias de trabalho normais. O outro grupo é composto pelos mesmo indivíduos que realizaram os testes na fase 2 no contexto Academia. Os experimentos tiveram duração de 5 dias.

Durante esses experimentos, em certos momentos eram alterados os parâmetros de contexto para então gerar as *playlists*, sem avisar os participantes, verificando se havia alteração na satisfação do grupo, com as músicas recomendadas. Por exemplo, para recomendação de música no contexto Academia, são fixados valores mínimos para as métricas de *danceability* (onde 0,0 é música menos dançante e 1,0 é mais dançante) que nesse contexto deveriam ser consideradas músicas que tiverem *danceability* maiores que 0,6, e com alto valor para *energy*, dessa forma recomendando músicas mais rápidas e com alta intensidade. Entretanto, durante a semana esse valores eram alterados para valores menores para verificar se a satisfação também mudava.

Conforme podemos verificar na Figura 43, foram realizados cinco experimentos. No primeiro dia foram fixados os valores de *danceability* e *energy* em 0,5, no segundo dia, esses valores foram colocados com valor alto, em seguida no terceiro e quarto dia esses valores foram fixados em 0,3 e no último dia esses valores voltaram para valores alto. Quando os parâmetros foram alterados para considerar músicas com níveis mais baixos de *danceability* e *energy*, a satisfação diminuiu.

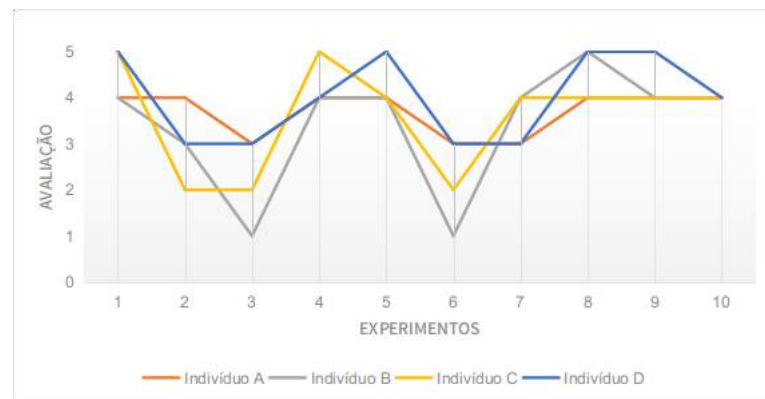


**Figura 43:** Nível de satisfação das recomendações realizadas no contexto Academia

Pode-se observar na Figura 44, no contexto Trabalho foram realizadas duas recomendações diárias totalizando dez experimentos. As recomendações são geradas com valores mais amenos para *energy*, *danceability* e *popularity*. Nos testes os valores de *energy* e *danceability* foram aumentados e verificou-se que o nível de satisfação diminuiu e os participantes não consideraram as recomendações condizentes com o ambiente.

A terceira etapa dos experimentos contou com a participação de oito indivíduos do sexo





**Figura 44:** Nível de satisfação das recomendações realizadas no contexto Trabalho

masculino. Durante as experiências, os participantes e o experimentador compartilharam uma sala de chat de texto usando o aplicativo Whatsapp . Este canal de comunicação foi concebido principalmente para o experimentador responder possíveis dúvidas e também manter contato entre os participantes durante os experimentos.

## 5 CONSIDERAÇÕES FINAIS E TRABALHOS FUTUROS

Recomendação para grupos é ainda pouco explorado, porém, como verificado nesse trabalho, muito promissora. Nesse trabalho foi possível observar as dificuldades envolvidas na recomendação para grupo, uma vez que a recomendação deve satisfazer o maior número de indivíduos de um grupo e atender esse requisito envolve um número muito alto de informações implícitas ao contexto do indivíduo.

O desenvolvimento de serviço Web para recomendação de música para ambientes compartilhados torna-se mais prático e eficiente, uma vez que não há necessidade do indivíduo selecionar gêneros ou procurar por títulos, pois o recomendador levará em consideração o gosto musical de todo o grupo, não somente de um indivíduo. Para tanto, nesta dissertação utilizamos estratégia de agregação de preferência individual criando um pseudo-usuário com as características agregadas através de modelagem de grafo, que se mostrou promissora, podendo ser utilizada para recomendar outros tipos de itens.

Durante os experimentos, a utilização da recomendação como o contexto atribuindo valores mínimos por exemplo *danceability* e *energy* para *playlist* filtrar as música recomendada para festa, mostrando uma melhora na satisfação e no quesito de canções adequadas ao ambiente.

Para trabalhos futuros a criação de experimentos computacionais para avaliação do método de recomendação se faz necessário uma vez que, nos experimentos realizados, um limitante significativo é a generalização de nossos resultados, sendo diretamente relacionada com as características da nossa amostra, já que todos os participantes se conheciam, e grande parte eram do sexo masculino.

Outro ponto a ser explorado é a utilização de dados implícitos do contexto, como local, horário e clima. E além disso, a sugestão de música por um indivíduo que pode se considerada adequada através de votos.

Finalmente, com o desenvolvimento deste trabalho, espera-se contribuir com pesquisas na área de recomendação de música para grupo. Este poderá ser utilizado em trabalhos futuros,

para investigar outros métodos de recomendação e criar mecanismos de *feedback* adaptativos.

## REFERÊNCIAS

- ANGLES, R.; GUTIERREZ, C. Survey of graph database models. **ACM Computing Surveys (CSUR)**, ACM, v. 40, n. 1, p. 1, 2008.
- BALABANOVIĆ, M.; SHOHAM, Y. Fab: content-based, collaborative recommendation. **Communications of the ACM**, ACM, v. 40, n. 3, p. 66–72, 1997.
- BIRD, C. et al. The promises and perils of mining git. In: IEEE. **Mining Software Repositories, 2009. MSR'09. 6th IEEE International Working Conference on**. Washington, DC, USA: IEEE Computer Society, 2009. p. 1–10.
- BORATTO, L.; CARTA, S. State-of-the-art in group recommendation and new approaches for automatic identification of groups. In: **Information retrieval and mining in distributed environments**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2010. p. 1–20.
- CAMPOS, L. M. de et al. Managing uncertainty in group recommending processes. **User Modeling and User-Adapted Interaction**, Springer, v. 19, n. 3, p. 207–242, 2009.
- CANO MARKUS KOPPENBERGER, N. W. P. Content-based music audio recommendation. In: **ACM Multimedia**. Singapore: ACM, 2005. p. 211–212. ISBN 1-59593-044-2.
- CAROLIS, B. D.; FERILLI, S.; ORIO, N. Recommending music to groups in fitness classes. Athens, Greece, p. 1759 – 1765, 2014.
- CARVALHO, L. **Sistema de Recomendação para Grupos**. maio 2012. Disponível em: <<http://goo.gl/hrZEKL>>. Acesso em: 15 de dezembro de 2015.
- CARVALHO, L.; MACEDO, H. Introdução aos sistemas de recomendação para grupos. **Revista de Informática Teórica e Aplicada**, v. 21, n. 1, p. 77–109, 2014.
- CARVALHO, L. A. M. C. **Abordagens de Teoria dos Jogos para modelagem de Sistemas de Recomendação para grupos**. Ciência da Computação, 2013. Disponível em: <<http://bdt.d.ufs.br/handle/tede/595>>.
- CI, T. T. **Travis CI**. maio 2012. Disponível em: <<https://docs.travis-ci.com/>>. Acesso em: 10 de março de 2016.
- CUNNINGHAM, S. J. et al. Social music in cars. In: THE INTERNATIONAL SOCIETY OF MUSIC INFORMATION RETRIEVAL CONFERENCE (ISMIR). **15th International Society for Music Information Retrieval Conference**. Taipei, Taiwan, 2014. p. 457–462.
- FIELDING, R. T.; TAYLOR, R. N. Principled design of the modern web architecture. **ACM Transactions on Internet Technology (TOIT)**, ACM, v. 2, n. 2, p. 115–150, 2002.
- FOWLER, M.; FOEMMEL, M. Continuous integration. **Thought-Works**) <http://www.thoughtworks.com/Continuous Integration.pdf>, p. 122, 2006.

GOLDBERG DAVID NICHOLS, B. M. O. D. T. D. Using collaborative filtering to weave an information tapestry. **Communications of the ACM**, ACM, v. 35, n. 12, p. 61–70, 1992.

HAN, J. et al. Survey on nosql database. In: IEEE. **Pervasive computing and applications (ICPCA), 2011 6th international conference on**. Port Elizabeth, South Africa, 2011. p. 363–366.

HARRIS, J. K. **An introduction to exponential random graph modeling**. Washington, DC, USA: Sage Publications, 2013.

HU, Y. A model-based music recommendation system for individual users and implicit user groups. University of Miami, p. 83 – 93, 2014.

KNIBERG, K.; SKARIN, M. **Kanban e Scrum obtendo o melhor de ambos**. InfoQ, 2009. Disponível em: <<https://www.infoq.com/br/minibooks/kanban-scrum-minibook>>. Acesso em: 06 de janeiro de 2016.

LAMERE, P. **Music APIs**. oct 2013. Disponível em: <<http://musicmachinery.com/music-apis/>>. Acesso em: 17 de setembro de 2015.

LOGAN, B. Music recommendation from song sets. In: **The International Society of Music Information Retrieval Conference (ISMIR)**. Barcelona, Spain: ISMIR, 2004. p. 1–7.

MCCARTHY, J. F.; ANAGNOST, T. D. Musicfx: an arbiter of group preferences for computer supported collaborative workouts. In: **Proceedings of the 1998 ACM conference on Computer supported cooperative work**. New York, NY, USA: ACM, 1998. p. 363–372. ISBN 1-58113-009-0.

MCFFEE, B.; BARRINGTON, L.; LANCKRIET, G. R. Learning similarity from collaborative filters. In: **The International Society of Music Information Retrieval Conference (ISMIR)**. San Diego, California, EUA: ISMIR, 2010. p. 345–350.

MESO, P.; JAIN, R. Agile software development: adaptive systems principles and best practices. **Information Systems Management**, Taylor & Francis, v. 23, n. 3, p. 19–30, 2006.

MIRANDA, N.; GONÇALVES, T. Sistemas de recomendação para grupos. *JIUE'2015 – Jornadas de Informática da Universidade de Évora*, n. 498, p. 153 – 165, 2015. Disponível em: <<http://hdl.handle.net/10174/17475>>.

NEST, T. E. **Echo Nest API Overview**. Mar 2016. Disponível em: <<http://developer.echonest.com/docs/v4/>>. Acesso em: 1 de janeiro de 2016.

O'CONNOR, M. et al. Polylens: a recommender system for groups of users. In: **SPRINGER. Proceedings of the Seventh Conference on European Conference on Computer Supported Cooperative Work**. Norwell, MA, USA: ECSCW, 2001. p. 199–218.

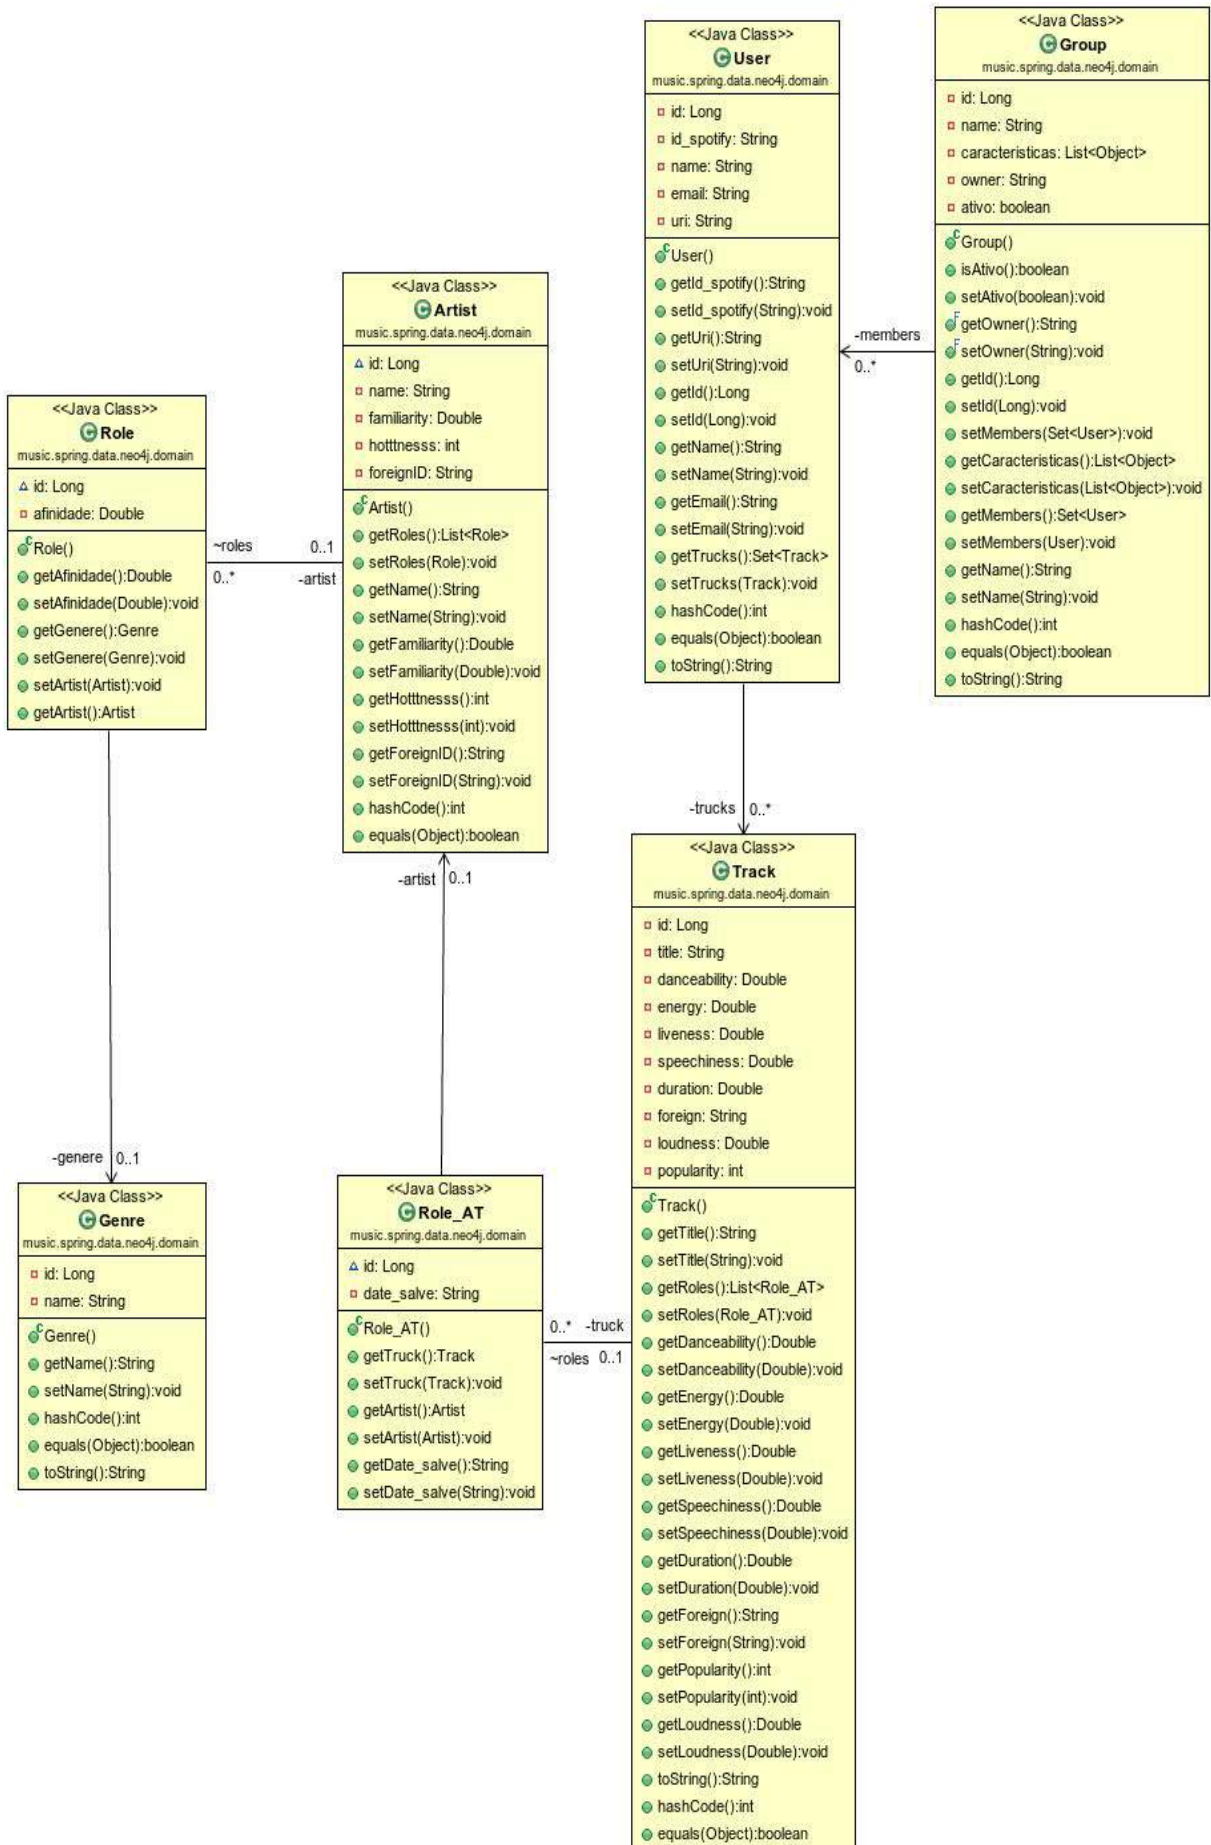
PICHL, M.; ZANGERLE, E.; SPECHT, G. Combining spotify and twitter data for generating a recent and public dataset for music recommendation. In: **Proceedings of the 26th GI-Workshop Grundlagen von Datenbanken**. Bozen-Bolzano, Italy: GI-Workshop. p. 35–40.

RESNICK, P.; VARIAN, H. R. Recommender systems. **Communications of the ACM**, ACM, New York, NY, USA, v. 40, n. 3, p. 56–58, mar 1997. ISSN 0001-0782. Disponível em: <<http://doi.acm.org/10.1145/245108.245121>>.

- ROBINSON, I.; WEBBER, J.; EIFREM, E. **Graph Databases: New Opportunities for Connected Data**. USA: "O'Reilly Media, Inc.", 2015.
- SCHNEEMAN, N. M. R. **Heroku: Up and Running - Effortless Application Deployment and Scaling**. USA: O'Reilly Media, Inc., 2013.
- SOLAZZI, C. M. **Incorporating a personalized wireframe image in a computer software application**. Washington, DC, USA: Google Patents, nov 2004. US Patent 6,816,159.
- SONG, Y.; DIXON, S.; PEARCE, M. A survey of music recommendation systems and future perspectives. In: **9th International Symposium on Computer Music Modeling and Retrieval**. London, England: ISMIR, 2012. p. 395–410.
- SOUZA, R. G. D. d. **Sistemas de Recomendação**. mai 2014. Disponível em: <<https://goo.gl/s62P9P>>. Acesso em: 21 de setembro de 2015.
- SPOTIFY, T. T. **15 for '15!** jan 2015. Disponível em: <<https://news.spotify.com/us/2015/01/12/15-million-subscribers/>>. Acesso em: 17 de setembro de 2015.
- SPOTIFY, T. T. **Get Audio Features for a Track**. Abr 2016. Disponível em: <<https://developer.spotify.com/web-api/get-audio-features>>. Acesso em: 29 de abril de 2016.
- SU HSIN-HO YEH, P. S. Y. V. S. T. J.-H. Music recommendation using content and context information mining. **Intelligent Systems, IEEE**, IEEE, v. 25, n. 1, p. 16–26, 2010.
- TILKOV, S. **Uma rápida Introdução ao REST**. out 2008. Disponível em: <<http://www.infoq.com/br/articles/rest-introduction>>. Acesso em: 17 de setembro de 2015.
- VASILOUDIS, T. **Extending recommendation algorithms by modeling user context**. 2014.
- VIEIRA, F.; ANDRADE, N. **Evaluating Conflict Management Mechanisms for Online Social Jukeboxes**. Málaga, Spain: ISMIR 2015, 2015. 190–196 p.
- WANG, J.; VRIES, A. P. D.; REINDERS, M. J. Unifying user-based and item-based collaborative filtering approaches by similarity fusion. In: ACM. **Proceedings of the 29th annual international ACM SIGIR conference on Research and development in information retrieval**. [S.l.], 2006. p. 501–508.
- YAMASHITA, J. S. **Visualização de tags para explicar e filtrar recomendações de músicas**. Tese (Doutorado) — Universidade de São Paulo, 2013.
- YOSHII, K. et al. An efficient hybrid music recommender system using an incrementally trainable probabilistic generative model. **Audio, Speech, and Language Processing, IEEE Transactions on**, IEEE, v. 16, n. 2, p. 435–447, 2008.

## APÊNDICE A - DIAGRAMA DE CLASSE DO NEO4J

\Diagrama de Classe do Neo4j





## **APÊNDICE B – DIAGRAMA DE CLASSE DOS SERVIÇOS**

\Diagrama de classe dos Serviços

