



**EDUARDO LÚCIO LASMAR JÚNIOR**

**QUALIDADE DE EXPERIÊNCIA EM SERVIÇOS DE  
MOBILIDADE COMPARTILHADA:  
PROPOSTA DE UM SISTEMA DE RECOMENDAÇÃO PARA  
USUÁRIOS**

**LAVRAS – MG**

**2018**

**EDUARDO LÚCIO LASMAR JÚNIOR**

**QUALIDADE DE EXPERIÊNCIA EM SERVIÇOS DE MOBILIDADE**

**COMPARTILHADA:**

**PROPOSTA DE UM SISTEMA DE RECOMENDAÇÃO PARA USUÁRIOS**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia de Sistemas e Automação, para a obtenção do título de Mestre.

Prof. DSc. Demóstenes Zegarra Rodriguez

Orientador

Profa. DSc. Renata Rosa Lopes

Coorientadora

**LAVRAS – MG**

**2018**

Ficha catalográfica elaborada pelo Sistema de Geração de Ficha Catalográfica da Biblioteca  
Universitária da UFLA, com dados informados pelo(a) próprio(a) autor(a).

Lasmar Júnior, Eduardo Lúcio.

Qualidade de experiência em serviços de mobilidade  
compartilhada: Proposta de um sistema de recomendação para  
usuários / Eduardo Lúcio Lasmar Júnior. - 2018.

77 p.

Orientador(a): Demóstenes Zegarra Rodriguez.

Coorientador(a): Renata Rosa Lopes.

Dissertação (mestrado acadêmico) - Universidade Federal de  
Lavras, 2018.

Bibliografia.

1. Novos modelos de mobilidade. 2. Qualidade de experiência.  
3. Sistemas de recomendação. I. Rodriguez, Demóstenes Zegarra.  
II. Lopes, Renata Rosa. III. Título.

**EDUARDO LÚCIO LASMAR JÚNIOR**

**QUALIDADE DE EXPERIÊNCIA EM SERVIÇOS DE MOBILIDADE  
COMPARTILHADA:  
PROPOSTA DE UM SISTEMA DE RECOMENDAÇÃO PARA USUÁRIOS**

**QUALITY OF EXPERIENCE IN SHARED MOBILITY SERVICES:  
AN USER RECOMMENDATION SYSTEM PROPOSAL**

Dissertação apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Engenharia de Sistemas e Automação, área de concentração em Engenharia de Sistemas e Automação, para a obtenção do título de Mestre.

APROVADA em 24 de agosto de 2018.

Dr. Danilo Alves Lima UFLA  
DSc. Demóstenes Zegarra Rodríguez UFLA  
DSc. Dárlinton Barbosa Figueira Cardoso UFSJ

Prof. DSc.. Demóstenes Zegarra Rodríguez  
Orientador

Profa. Dsc. Renata Rosa Lopes  
Coorientadora

**LAVRAS – MG  
2018**

## **AGRADECIMENTOS**

Agradeço a Deus, por possibilitar as oportunidades de cada dia e pelos desafios superados.

Agradeço aos meus pais por todo o apoio prestado, por representarem os valores essenciais de uma vida íntegra e pelo amor incondicional. As minhas irmãs pelos momentos de compreensão, carinho e ajuda nesta caminhada.

Agradeço ao meu orientador, Demóstenes, por apoiar minhas ideias e aspirações, por estar sempre disponível me auxiliando. Também agradeço minha coorientadora, Renata, por estar sempre presente em todos os momentos, me apoiando nas pesquisas.

Meu agradecimento ao Programa de Pós Graduação em Engenharia de Sistemas e Automação (PPGESISA), aos professores e funcionários. Meu agradecimento também aos professores de outros departamentos, DAE e DCC, pelas disciplinas e atividades desenvolvidas.

Agradeço aos professores LMT, principalmente aos professores, Arthur, Danilo e Sérgio, por me acolherem antes mesmo do curso, pela atenção e disponibilidade. Meu agradecimento se estende aos membros do laboratório, principalmente ao grupo do DAE, Thais, Rodrigo, Bruna e Fabio, pelos momentos divididos, trabalhos realizados e muito aprendizado.

Aos colegas do PPGESISA por dividirem momentos de aprendizado e me auxiliar nesta caminhada.

Agradeço à Fernanda, secretária do PPGESISA, pela atenção e disponibilidade nos diversos momentos em que foi solicitada.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

*A vida são as incessantes oportunidades que surgem pela frente, jamais os insucessos que  
ocorreram no passado.*

*(Joanna de Ângelis)*

## RESUMO

Nos últimos anos, novos modelos de mobilidade urbana têm ganhado popularidade por suas vantagens e custos menores para os usuários. Um dos novos modelos de serviço que tem se destacado é o *Ridesharing*, que possibilita viagens compartilhadas, podendo reduzir a quantidade de veículos nas ruas e contribuir para a mobilidade urbana. Além disso, a evolução e disseminação dos *smartphones* permitiu o surgimento de diversos aplicativos (APP), desenvolvendo soluções inovadoras para a mobilidade, além de contribuir para o rápido crescimento do número de usuários. Considerando ainda que, os sistemas de qualidade estão presentes na indústria automotiva há décadas, garantindo a satisfação dos clientes com seus produtos; a percepção da qualidade em serviços de mobilidade pelo usuário se torna um fator-chave nas soluções de transporte. Desta forma, a Qualidade da Experiência (QoE) pode ser um novo parâmetro de avaliação tangível para os novos modelos de transporte compartilhado. Com base neste cenário, o presente trabalho propõe a utilização dos conceitos de QoE para os serviços de *Ridesharing*. Um modelo de recomendação para serviços de mobilidade compartilhada é proposto, considerando as informações de perfis, extraídas de sites de rede social, e preferências dos usuários. O principal objetivo do modelo de recomendação proposto é melhorar a QoE do usuário. Para isso, são aplicados teste subjetivos, criando uma base de dados capaz de fornecer condições para elaborar modelos de classificação com aplicação de algoritmos de aprendizado de máquina. Os resultados destes algoritmos de aprendizado de máquina constituem o modelo de recomendação, este por sua vez, poderá identificar usuários com preferências similares, por meio de uma função de similaridade, possibilitando, assim, o compartilhamento de viagens entre usuários com características e preferências similares. Resultados experimentais constataam que o algoritmo *Random Forest* obteve o melhor desempenho, atingindo *F-Measure* de 0,92. Por fim, os resultados certificam que 94,2% dos respondentes concordam com os resultados da recomendação do modelo.

**Palavras-chave:** Novos modelos de transporte. Qualidade de Experiência. QoE. Mobilidade compartilhada. Sistemas de recomendação. Aprendizado de máquina.

## ABSTRACT

In recent years, new models of urban transport system gained popularity for their advantages and lower costs for users. One of the new service models that has been highlighted is the Ridesharing service, which allows shared travel and can reduce the number of vehicles in the streets and contributes for urban mobility. The evolution and dissemination of smartphones allowed the emergence of several applications (APP), developing innovative solutions for mobility, and contributing to the rapid growth of the number of users. Quality systems have been present in the automotive industry for decades, ensuring customers' satisfaction with their products. The user's quality perception in mobility services, has become a key factor in transport solutions. In this way, the Quality of Experience (QoE) can be a new tangible evaluation parameter for the new models of sharing transport. Based on this scenario, the present work proposes to use the QoE concept in Ridesharing services. A recommendation model for shared mobility services is proposed, considering the profile information, extracted from the social network sites, and user preferences. The main objective of the proposed recommendation model is to improve the user's QoE. For this, subjective tests are conducted, creating a database capable of providing the conditions for elaborating the classification model with application of machine learning algorithms. The results of these algorithms compose the recommendation model, this in turn can identify users with similar preferences through a similarity function, thus users with similar preferences and characteristic share a ride. An experimental results showed that Random Forest algorithm achieved the best performance, reaching the F-Measure of 0,92. In addition, the results showed that 94.2% of participants agree with the recommendation model results.

**Keywords:** New models of transport. Quality of experience. QoE. Shared mobility. Machine Learning. Recommendation system.

## LISTA DE FIGURAS

Figura 2.1 – Screenshot da simulação de um percurso no aplicativo da Car2Go . . . . .	20
Figura 2.2 – Relatório de citações de QoE (2009 - 2018) . . . . .	26
Figura 2.3 – Taxonomia dos fatores que impactam na QoE . . . . .	29
Figura 2.4 – Taxonomia dos Sistemas de Recomendação . . . . .	34
Figura 2.5 – Sistema de recomendação de <i>Ridesharing</i> Uber . . . . .	37
Figura 3.1 – Fluxograma da metodologia utilizada para determinar o modelo proposto. .	39
Figura 4.1 – Representação dos dados organizados. . . . .	45
Figura 4.2 – Interface WEKA. . . . .	47
Figura 4.3 – Tela inicial do RsRS sistema de recomendação. . . . .	48
Figura 5.1 – Intervalo entre gerações. . . . .	51
Figura 5.2 – Resultados do questionário - parte Q1. . . . .	52
Figura 5.3 – Resultados do questionário - parte Q2. . . . .	53
Figura 5.4 – Comportamento das gerações na mobilidade compartilhada. . . . .	54
Figura 5.5 – Resultados do questionário - parte Q3. . . . .	54
Figura 5.6 – Desempenho dos algoritmos para questão gênero - Correct Class. . . . .	56
Figura 5.7 – Resultados agrupados em planilhas. . . . .	57
Figura 5.8 – Representação da árvore de decisão do item "Time de futebol diferente". . .	58
Figura 5.9 – Mensagem de recomendação contendo os resultados do algoritmo de classificação da função similaridade. . . . .	62

## LISTA DE TABELAS

Tabela 4.1 – Algoritmo de determinação da função similaridade. . . . .	50
Tabela 5.1 – Média dos resultados. . . . .	57
Tabela 5.2 – Distribuição dos atributos. . . . .	60

## LISTA DE QUADROS

Quadro 2.1 – Escala de Classificação MOS de 5 pontuações. . . . .	28
---	----

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b>	<b>11</b>
1.1	Contexto e motivação	11
1.2	Objetivos	13
1.2.1	Objetivos específicos	14
1.3	Justificativas	14
1.3.1	Produção científica	16
1.4	Organização do trabalho	16
<b>2</b>	<b>REFERENCIAL TEÓRICO</b>	<b>18</b>
2.1	Novos modelos de transporte de passageiros	18
2.1.1	Mobilidade compartilhada	19
2.1.1.1	Carpooling	19
2.1.1.2	Carsharing	19
2.1.1.3	Ridesharing	21
2.1.1.4	Ridehailing	21
2.1.1.5	Companhias de Rede de Transportes	22
2.2	Qualidade na indústria automobilística	23
2.3	Qualidade de experiência	25
2.3.1	Pontuação média de opinião	27
2.3.2	Fatores que influenciam na Qualidade de Experiência	28
2.4	Algoritmos de inteligência artificial	29
2.4.1	Redes neurais	31
2.4.2	Árvore de decisão	31
2.4.3	Máquina de Vetor de Suporte	32
2.4.4	Random forest	32
2.5	Redes sociais	32
2.6	Sistemas de recomendação	33
2.7	Trabalhos relacionados	35
<b>3</b>	<b>MODELO DE RECOMENDAÇÃO PROPOSTO</b>	<b>38</b>
3.1	Principais componentes e fluxograma do modelo de recomendação	38
3.1.1	Modelo de classificação por AM	38
3.1.2	Sistema de recomendação proposto	38

<b>4</b>	<b>METODOLOGIA PROPOSTA</b>	<b>41</b>
<b>4.1</b>	<b>Testes subjetivos via questionário</b>	<b>41</b>
<b>4.1.1</b>	<b>Definição do questionário</b>	<b>42</b>
<b>4.1.1.1</b>	<b>Parâmetros propostos para a classificação de preferências</b>	<b>44</b>
<b>4.1.2</b>	<b>Critérios para definição da base de dados</b>	<b>44</b>
<b>4.2</b>	<b>Tratamento dos dados utilizando algoritmos de aprendizado de máquina</b>	<b>45</b>
<b>4.2.1</b>	<b>Ferramenta WEKA</b>	<b>46</b>
<b>4.3</b>	<b>Implementação do sistema de recomendação</b>	<b>46</b>
<b>4.3.1</b>	<b>Módulo para extração de dados de redes sociais</b>	<b>47</b>
<b>4.3.2</b>	<b>Módulo de interface com usuário</b>	<b>49</b>
<b>4.3.3</b>	<b>Algoritmos selecionados</b>	<b>49</b>
<b>4.3.4</b>	<b>Função de similaridade</b>	<b>49</b>
<b>4.4</b>	<b>Métricas para avaliação de desempenho</b>	<b>50</b>
<b>5</b>	<b>RESULTADOS E DISCUSSÕES</b>	<b>51</b>
<b>5.1</b>	<b>Análise dos testes subjetivos</b>	<b>51</b>
<b>5.2</b>	<b>Determinação de um modelo de classificação</b>	<b>55</b>
<b>5.3</b>	<b>Avaliação do desempenho do modelo de recomendação proposto</b>	<b>61</b>
<b>6</b>	<b>CONCLUSÃO</b>	<b>63</b>
	<b>REFERÊNCIAS</b>	<b>65</b>
	<b>APENDICE A – Questionário Aplicado</b>	<b>71</b>

## 1 INTRODUÇÃO

O presente trabalho aborda a temática dos novos modelos de mobilidade, com foco na mobilidade compartilhada, aspectos relacionados a qualidade, Qualidade de Experiência (QoE) e sistemas inteligentes de recomendação. Este capítulo introdutório é composto pela contextualização e motivação do estudo, bem como os objetivos e as justificativas de pesquisa. Por fim, aborda-se a estrutura da dissertação.

### 1.1 Contexto e motivação

A mobilidade urbana está passando por grandes alterações atualmente, especialmente considerando o uso de serviços de transporte privado por meio de aplicativos de *Smartphones*, conhecidos como APPs, tem permitido inovações disruptivas na mobilidade os serviços de compartilhamento de viagens disseminados por APPs, como Uber, Lyft ou Cabify, permitem o arranjo on-line e em tempo real de rotas compartilhadas com diferentes usuários.

Existe uma distinção entre o transporte público e o transporte privado. Os sistemas de transportes como o metrô, ônibus e táxis são considerados transportes públicos. Os serviços realizados por motoristas parceiros dos APPs se enquadram no conceito de “transporte individual privado de passageiros” segundo a Lei Federal nº 12.567/2012 (BRASIL, 2012). Ao abordar este tema com foco nos modelos de transporte privado, compreende-se que novas formas de mobilidade estão emergindo por meio de inovações tecnológicas e maior capacidade das redes de comunicação, disponíveis tanto para o motorista quanto para o passageiro (LENZ; FRAEDRICH, 2016).

Essas possibilidades estimularam mudanças nas soluções tradicionais de transporte, criando gradualmente um mercado de transporte compartilhado (ENOCH, 2015). O modelo *Ridesharing* possibilita aos usuários o compartilhamento de corridas com outros usuários desconhecidos, desde que possuam trajetórias similares (COHEN; KIETZMANN, 2014), tendo como exemplo as categorias Uberpool e Lyft Line.

Os novos modelos de mobilidade possuem números interessantes, como em 2015, que mais de 80 mil veículos trabalharam no modelo de *Carsharing* (sistema de alugueis de veículos por minutos ou horas gerenciados normalmente por aplicativos), atendendo a quase seis milhões de usuários (BERT et al., 2016). Além disso, a mobilidade compartilhada é considerada uma das soluções para o transporte urbano e redução das emissões de CO<sub>2</sub> até 2050 (FULTON; MASON; MEROUX, 2017).

Nesse cenário, as estratégias adotadas pelos fabricantes de veículos estão sendo alteradas, em que o padrão de veículo como posse está sendo repensado para serviços de mobilidade. Por exemplo da Daimler com o Car2Go e a General Motors com o Maven, ambos serviços de *Carsharing*, isto evidencia a inovação dos modelos de negócios de companhias tradicionais, dando atenção maior a mobilidade (JÚNIOR et al., 2018).

Uma das grandes conquistas do setor automotivo é a qualidade dos produtos, adquirida principalmente com o conceito de veículo global que teve sua disseminação no início da década de 1990, sendo a padronização dos produtos um desafio para as montadoras (GROUP, 2010). Tais padrões internacionais para o desenvolvimento do processo de fabricação, deram origem a regras de qualidade específicas para o setor automotivo, como a norma ISO TS 16949 (ISO, 2015).

O conceito de qualidade está fortemente presente na indústria automotiva há algumas décadas e é um fator chave no desempenho de seus produtos (RAO et al., 1997). Entretanto, a mudança de produto para serviço dos novos modelos de mobilidade necessita de atenção à satisfação do usuário na prestação do serviço (LENZ; FRAEDRICH, 2016; ENOCH, 2015), e aplicação de sistemas de qualidade diferentes aos utilizados pelo setor atualmente nos produtos.

A Qualidade da Experiência (QoE) é um conceito multidimensional baseado nas percepções do usuário. Representa as respostas emocionais, comportamentais e cognitivas que podem ser avaliadas por métodos subjetivos ou objetivos (FOTROUSI; FRICKER; FIEDLER, 2017). Os usuários escolhem um serviço ou produto com base em características pessoais, como preferências e experiências anteriores (PIRES, 2002). Assim, nas avaliações subjetivas, as características pessoais de cada avaliador precisam ser consideradas.

Diante das inevitáveis mudanças que ocorrem na mobilidade urbana, e considerando a importância do aspecto da qualidade no setor automotivo, os novos modelos de mobilidade compartilhada podem demandar sistemas capazes de aprimorar a qualidade dos serviços, podendo a QoE ser um destes sistemas.

Um número escasso de pesquisas trata da aplicação do conceito de QoE no serviço de transporte urbano. No serviço de compartilhamento de viagens ou rotas, há poucos estudos (VIEIRA et al., 2012; DAI et al., 2016), também em Bijor et al. (2017) é introduzido um Sistema de Recomendação (SR), em que a mensagem de recomendação é enviada para usuários que estão na mesma rota de uma viagem e pertencem à mesma Rede Social possibilitando o compartilhamento de corridas.

Outros estudos, (ZHANG et al., 2013; ZHANG et al., 2014), apresentam diferentes SR que lidam com serviços de táxi, com o objetivo de agrupar usuários considerando o custo e a redução de rotas. Algumas dessas soluções usam algoritmos de aprendizado de máquina diferentes, como Random Forest, Máquina de Vetor de Suporte (SVM) e Rede Neural Artificial (RNA). Esses algoritmos são amplamente utilizados em SR para classificação, regressão e outras tarefas (ZHANG; MIN, 2016).

Neste contexto, a principal contribuição deste trabalho é utilizar a QoE na mobilidade compartilhada, especificamente em modelos *Ridesharing*, introduzindo um novo SR que considera as características do perfil do usuário, como idade, gênero, grau de educação e estado civil, além de algumas preferências relacionadas ao compartilhamento de corridas e/ou viagens.

O objetivo é demonstrar que as informações do usuário são relevantes para melhorar a QoE do usuário. Para isso, são realizados testes subjetivos para estudar as preferências dos respondentes, que já utilizaram os serviços por APP, considerando informações demográficas, e alguns temas relevantes no contexto social, como política, religião, esportes, entre outros. Desta forma, um banco de dados foi criado usando os resultados dos questionários e posteriormente, algoritmos de aprendizado de máquina aplicaram as informações deste banco, determinando um modelo de recomendação de usuário para o compartilhamento de corridas.

Além disso, uma interface Web é utilizada para os usuários responderem a algumas perguntas sobre suas preferências, com base nos temas propostos, e extrair informações do seu perfil das redes sociais. Uma vez definida a classificação do perfil do usuário, o sistema cria uma lista de possíveis passageiros para compartilhar a viagem. Então, o modelo de recomendação usa uma função de similaridade para determinar a classificação de usuários com os perfis mais semelhantes. Esta informação é enviada para um provedor de serviços, no intuito de selecionar os usuários. Assim, o modelo permite agrupar passageiros com perfis semelhantes, evitando o compartilhamento de usuários, com preferências opostas.

Resultados experimentais demonstraram que algoritmos de aprendizado de máquina têm alta precisão na tarefa de classificação de perfis, alcançando um valor médio de *F-measure* de 0,92. Além disso, 49 de um total de 52 avaliados ficaram satisfeitos com a lista de classificação.

## 1.2 Objetivos

Esta pesquisa tem como objetivo geral aplicar os conceitos da Qualidade de Experiência no serviço de mobilidade compartilhada por aplicativos de *Smartphone*, identificando as carac-

terísticas e preferências pessoais que possam influenciar a experiência dos usuários durante o compartilhamento de corridas e/ou viagens.

Para isso, propõe-se também um sistema de recomendação que utiliza informações de usuários extraídas das redes sociais, as quais são analisadas com algoritmos de aprendizado de máquina, com a finalidade de agrupar usuários com características afins. Espera-se que o modelo de recomendação seja capaz de aprimorar a QoE dos usuários em serviços de mobilidade compartilhada.

### 1.2.1 Objetivos específicos

Como objetivos específicos têm-se:

1. Realizar testes subjetivos, por meio de questionários, para identificar as influências dos principais parâmetros que determinam a QoE dos usuários no compartilhamento de mobilidade;
2. Propor um sistema de classificação dos usuários, utilizando aprendizado de máquina, a partir dos resultados dos testes subjetivos;
3. Desenvolver e validar um modelo de recomendação para a mobilidade compartilhada, capaz de ranquear os possíveis passageiros.

### 1.3 Justificativas

A mobilidade urbana atual é responsável por grandes transformações no cotidiano das pessoas, principalmente em grandes centros. As novas formas de mobilidade possibilitam experiências inovadoras em serviços para deslocamento, sendo que, as recentes empresas de transporte privado, por meio de plataformas de aplicativos de *smartphones*, como Uber e Cabify, focam nestes serviços, essas empresas são caracterizadas por possuírem um relacionamento direto com seus clientes e motoristas, situação em que os clientes pagam somente pelas distâncias percorridas.

Neste contexto de serviços via APPs, compreende-se que novas formas de mobilidade serão os principais responsáveis por esta inovação. Enoch (2015) aponta que as transformações ocorridas nos modos de transportes convencionais são estimuladas pelos avanços tecnológicos e fatores de demanda, criando gradativamente um mercado de transporte compartilhado, também ressalta que os meios de transporte como ônibus irá perder espaço para os veículos que oferecem

corridas compartilhadas. Adicionalmente, McKerracher et al. (2016) avalia que a chegada dos veículos autônomos irá impulsionar os modelos transporte compartilhado.

O acesso a estes serviços já acontece por meio de APPs de *smartphone*, conhecidos com *Ridesharing*, tais fatos mostram que existe um grande potencial de migração dos transportes coletivos para este modelo. Outro ponto é o impacto que estes novos serviços causam no mercado, em 2017, mais de US\$ 28 bilhões foram investidos em startups de mobilidade<sup>1</sup>.

A Uber, umas das principais empresas de *Ridesharing*, afirma já ter atingido 10 bilhões de viagens em todo o mundo em 10 de Junho de 2018, sendo que mais da metade foram realizadas em 13 meses<sup>2</sup>, além de possuir mais de 75 milhões de clientes em 65 países, abrangendo mais de 600 cidades<sup>3</sup>. Os valores conquistados pela empresa demonstram a rápida ascensão destes serviços, entretanto, existem insatisfações de muitos dos usuários.

De acordo com o site ReclameAqui<sup>4</sup> (serviço gratuito para consumidores postarem reclamações sobre serviços, produtos, atendimentos e vendas no Brasil, possibilitando também a respostas das empresas mencionadas), as reclamações sobre a Uber têm crescido constantemente. Em 2016, primeiro ano da empresa no site, foram quase 30 mil, em 2017 mais de 53 mil reclamações, totalizando mais de 108 mil reclamações até Julho de 2018. Diante da quantidade de reclamações, a empresa ocupa o 7º lugar no ranking das empresas mais reclamadas.

Outro indicador de insatisfação dos usuários é o *site* ConsumerAffairs.com<sup>5</sup>, empresa com sede nos EUA, organização sem fins lucrativos que fornece notícias e avaliações dos consumidores deste país, Os usuários avaliaram a Uber em 1,5 estrelas, de um total de 5, de acordo com mais de 900 avaliações. As empresas também podem participar respondendo os usuários.

Diante dos números que demonstram a insatisfação dos usuários, os serviços prestados por APP de *Ridesharing* podem ser prejudicados pela falta de qualidade. Com base nisto, o esforço para aprimorar a QoE do usuário em tais serviços é válido e de grande importância.

<sup>1</sup> <https://www.bloomberg.com/news/articles/2018-02-02/there-s-never-been-more-money-pouring-into-mobility-startups>

<sup>2</sup> <https://www.uber.com/pt-BR/newsroom/uber-ultrapassa-10-bilhoes-de-viagens-no-mundo/>

<sup>3</sup> <https://www.uber.com/pt-BR/newsroom/fatos-e-dados-sobre-uber/>

<sup>4</sup> <<https://www.reclameaqui.com.br/ranking/>> acessado em: 20/07/2018

<sup>5</sup> <<https://www.consumeraffairs.com/travel/uber.html>> acessado em: 20/07/2018

### 1.3.1 Produção científica

Reforçando as justificativas, os trabalhos desenvolvidos durante a dissertação possibilitaram publicações tanto em *Journal* quanto em eventos científicos, as produções científicas são listadas à seguir:

- Artigo completo publicado em Periódico:

LASMAR JUNIOR, E. L.; GANDIA, R. M.; SUGANO, J. Y.; SOUZA, T. A.; RODRIGUEZ, D. Z. New Business Model and the Sharing Economy: Impacts and Challenges for the Traditional Automotive Industry. **International Journal of Automotive Technology and Management**, 2018.

- Trabalhos completos publicados em anais de congresso:

LASMAR JUNIOR, E. L.; ROSA R. L.; RODRIGUEZ, D. Z. A Recommendation System for Shared-Use Mobility Service. In: **International Conference on Software, Telecommunications and Computer Networks**, 2018, Split-Supetar. Softcom, 2018.

LASMAR JUNIOR, E. L.; GANDIA, R. M.; SOUZA, T. A.; CAVAZZA, B. H.; ANTONIALI, F.; ROSA, R. L.; RODRIGUEZ, D. Z. Shared-used Mobility: global generations and service perception. In: **26th International Colloquium of Gerpisa**, São Paulo, 2018.

LASMAR JUNIOR, E. L.; GANDIA, R. M.; SOUZA, T. A.; SUGANO, J. Y.; RODRIGUEZ, D. Z. Novos modelos de negócios e a economia compartilhada: impactos e desafios para indústria tradicional de automóveis. In: **XX SemeAd - Seminários em Administração**, 2017, São Paulo. XX SemeAd, 2017.

### 1.4 Organização do trabalho

Esta dissertação é composta por este capítulo introdutório e por outros 6 capítulos, sendo eles:

Capítulo 2: O Referencial teórico trata dos novos modelos de mobilidade, a QoE, também aborda a qualidade na indústria automotiva, algoritmos de aprendizado de máquina, redes sociais, os sistemas de recomendação e; por fim, trabalhos relacionados.

Capítulo 3: Sistema de recomendação proposto descreve resumidamente o modelo que foi utilizado neste trabalho.

Capítulo 4: Metodologia proposta está dividida nos testes subjetivos aplicados via questionário, seguido da seção que aborda o tratamento de dados utilizando algoritmos de aprendizado de máquina, também descreve a implementação do sistema de recomendação e, por fim, as métricas para avaliação de desempenho dos algoritmos.

Capítulo 5: Resultados e discussões descrito em três seções, com a análise dos testes subjetivos, determinação de um modelo de classificação e avaliação do desempenho do modelo proposto.

Capítulo 6: A Conclusão, descrevendo as contribuições e trabalhos futuros.

## 2 REFERENCIAL TEÓRICO

Neste capítulo são abordados os principais tópicos do trabalho, de importância para o desenvolvimento e entendimento desta dissertação, assim como, os trabalhos correlatos de acordo com a literatura existente. Os assuntos aqui tratados são: sistemas de transporte com foco na mobilidade compartilhada, qualidade no setor automotivo, Qualidade de Experiência, sistemas de recomendação, redes sociais e trabalhos relacionados.

### 2.1 Novos modelos de transporte de passageiros

A inovação nos modelos de transporte de passageiros pode ocorrer de diferentes causas, um exemplo é a crise do petróleo da década de 70 nos Estados Unidos, fator motivador para o surgimento de transportes compartilhados (FURUHATA et al., 2013). Entretanto, os novos modelos de mobilidade recentes proporcionaram inovações disruptivas.

A evolução da tecnologia permitiu a proliferação de *smartphones*, possibilitando o acesso em tempo real a mapas digitais, internet, plataformas de e-commerce, comunicação, pagamentos e acesso a informação como nunca antes (RIFKIN, 2014). Tais tecnologias alinhadas à mudança nos padrões de consumo, abrem espaço para a chamada economia compartilhada, com foco na criação de serviços mais acessíveis e redução de desperdícios, otimização do uso produtos por meio de plataformas digitais (BOTSMAN; ROGERS, 2011; RIFKIN, 2014).

Inseridas neste contexto, algumas empresas prestam serviços de compartilhamento de carona, *Carpooling* e *Carsharing* (compartilhamento de carros), podendo o motorista ser remunerado ou não. O objetivo desses modelos é promover o compartilhamento, facilitar o deslocamento de usuários e reduzir custos de viagens (COHEN; KIETZMANN, 2014; SHAHEEN et al., 2015).

O processo de solicitação de um serviço de transporte individual é por meio de APP de *smartphone* ou computador, sendo esse prestado por carros particulares, táxis ou outros veículos. Esse serviço é conhecido como *Ridesharing* ou *e-hailing* (HINO et al., 2015; RAYLE et al., 2014; COHEN; KIETZMANN, 2014).

A literatura descreve diferentes definições para esses serviços. Na revisão realizada neste estudo, dentro do intervalo de 2002 a 2017, não se identificou definições claras para as denominações: *Ridesharing*, *e-hailing*, *Ridehailing*, *Ridesourcing*, *Carpooling*, *on-demand rides*, *Real-time ridesharing*, entre outros.

Apesar de que ainda não exista um consenso nas definições das denominações descritas, faz-se necessário esclarecer os conceitos relacionados aos modelos compartilhados. Nas seguintes subseções são descritos os novos modelos de mobilidade com foco no compartilhamento.

### **2.1.1 Mobilidade compartilhada**

O uso compartilhado de meios de transporte, principalmente carros e bicicletas, tem ganhado destaque. A mobilidade compartilhada pode ser estabelecida por práticas comerciais que permitem o acesso a bens ou serviços, sem que exista a necessidade de obtenção do produto (BOTSMAN; ROGERS, 2011; ZHEN, 2015).

De acordo com (RAYLE et al., 2014), a mobilidade compartilhada é o uso compartilhado de veículos ou bicicletas possibilitando aos usuários um acesso de acordo com a necessidade sem arcar com os custos de propriedade. A mobilidade compartilhada inclui o compartilhamento de veículos (*Carsharing*), caronas solidárias (*Carpooling*), compartilhamento de corridas e viagens (*Ridesharing* e *Ridehailing*) e compartilhamento de bicicletas (*Bikesharing*) (SHAHEEN et al., 2015).

A seguir são descritos os principais modelos de mobilidade compartilhada.

#### **2.1.1.1 Carpooling**

O *Carpooling* consiste no compartilhamento de viagens de carros particulares pelos *car-poolers*, para que mais de uma pessoa viaje em um veículo, possibilitando reduzir os custos em combustível, estacionamentos e manutenção. Esse modelo propõe uma forma mais ecológica e sustentável de viajar do que o uso comum de carros particulares, ele significa menos congestionamentos nas vias, estradas e menos poluição de ar (MALLUS et al., 2017).

De acordo com Greenblatt e Shaheen (2015), o *Carpooling* ocorre quando duas ou mais pessoas possuem o mesmo destino e compartilham um veículo, sem remuneração ou transação financeira entre os passageiros e motorista.

São exemplos de aplicativos de *Carpooling*: Waze Carpool, BlaBlaCar e ToGO Carpool.

#### **2.1.1.2 Carsharing**

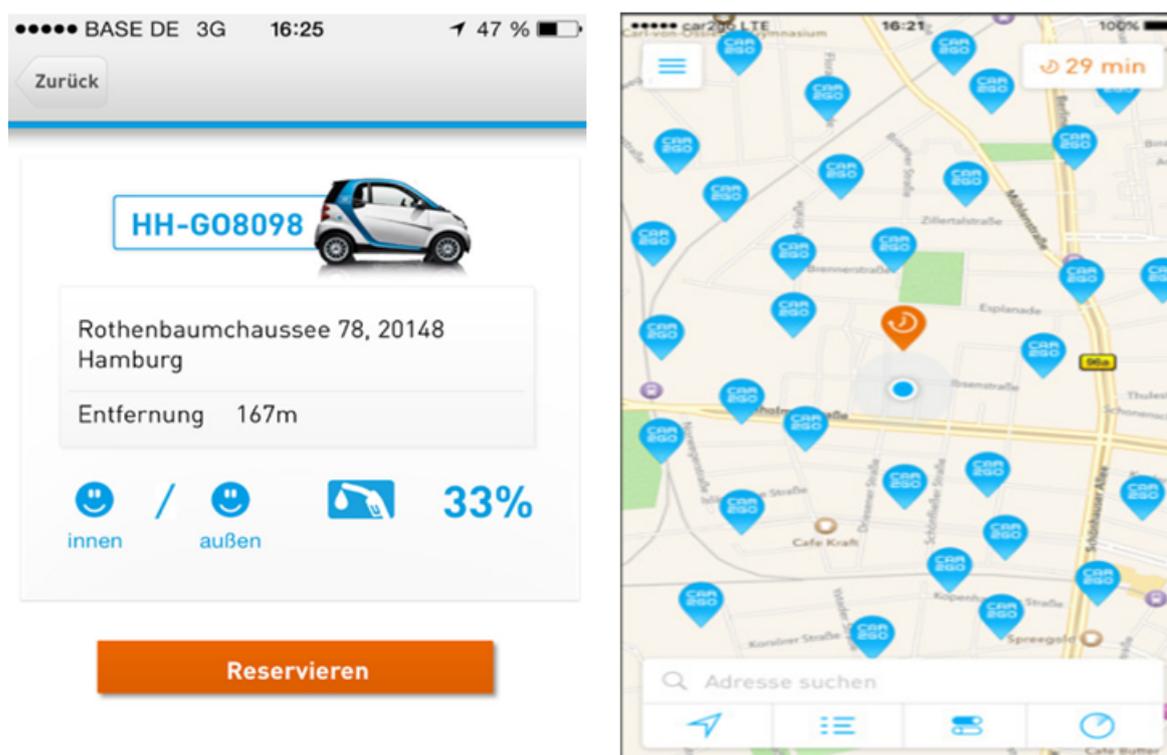
O compartilhamento de veículos (*Carsharing*) é um serviço que fornece aos seus usuários uma frota de carros em diversos pontos de uma cidade, os usuários podem reservar o veículo

por *smartphone* ou Internet e o acesso pode ser por meio de cartão eletrônico ou, atualmente, pelo próprio *smartphone* (CLEWLOW; MISHRA; CENTER, 2017).

A transação financeira normalmente é realizada ao final do uso ou no final do mês. Em seu início o modelo possuía as vantagens estratégicas de estarem em locais acessíveis na região urbana e os usuários podiam utilizar os veículos em frações pequenas de tempo (MILLARD-BALL, 2005).

Atualmente, os números de locais disponíveis aumentaram significativamente, em comparação com a introdução do serviço. Na Figura 2.1 é visível o grande número de pontos disponíveis (ícones azuis), na cidade de Hamburgo na Alemanha, possibilitando o acesso ao serviço de uma empresa de *Carsharing*, a Car2Go, que pertence ao grupo Daimler AG.

Figura 2.1 – Screenshot da simulação de um percurso no aplicativo da Car2Go



Fonte: CAR2GO (2017)

Apesar de ser similar ao aluguel de carros, este modelo se diferencia por oferecer o serviço por minutos ou horas, diferente dos alugueis diários. Também, o *Carsharing* possibilita reservas sem burocracias, e um proprietário pode compartilhar seu veículo por meio de aplicativos.

Os exemplos de aplicativos de *Carsharing* são diversos, e um fator que o diferencia dos demais modelos é o fato de existirem APPs de *startups*, como a ZipCar, Free2Move, ZazCar,

que possibilitam usuário compartilharem seus veículos particulares, como também, os aplicativos das montadoras automotivas, ao exemplo do Maven (General Motors), ReachNow (BMW) e o Car2Go (Daimler).

### 2.1.1.3 Ridesharing

O termo *Ridesharing* é utilizado normalmente para os serviços em tempo real ofertados por meio de APPs, que facilitem o encontro entre pessoas em busca de um transporte compartilhado (POSEN, 2015). De acordo com Furuhata et al. (2013), *RideSharing* refere-se a um modelo de transporte em que o usuário, normalmente proprietário do veículo e condutor, compartilha seu carro para uma viagem ou corrida com outras pessoas que possuam trajetos e horários semelhantes, com o intuito de dividir os custos.

O *Ridesharing* é um sistema que pode combinar a flexibilidade e a rapidez de veículos particulares com o custo fixo de manutenção reduzido, aos custos de conveniência, trazendo vantagens tanto para o condutor, tanto para passageiros, além de contribuir com a redução de trânsito e, conseqüentemente, tempos de viagens (CHAN; SHAHEEN, 2012). Essa definição se aproxima muito das atividades da Uber, Lyft, Cabify e outras, empresas que auto denominam-se companhias de *Ridesharing*, além de algumas fontes da mídia.

Entretanto, a definição de Cohen e Kietzmann (2014), descreve *Ridesharing* como o compartilhamento do veículo envolvendo o agrupamento de viajantes em um automóvel particular, afim de reduzir os custos e congestionamento, com origens e/ou destinos semelhantes. As novas categorias como o UberPool e Lyft Line são entendidas por essas definições.

Diante disto, este trabalho entende o modelo *Ridesharing* podendo ser viagens compartilhadas entre um ou mais usuários com destinos semelhantes, sendo este o foco da aplicação do modelo de recomendação proposto.

### 2.1.1.4 Ridehailing

O termo *Ridehailing* pode ser encontrado para definições iguais à do *Ridesharing* em algumas literaturas e até órgãos governamentais relacionados a transporte, por conta disto, o termo é abordado no trabalho. *Ridehailing* também é utilizado para o compartilhamento de corridas entre usuário, similar ao *Ridesharing*. O termo foi argumentado por profissionais da área sobre o condutor e passageiros não possuírem os mesmos destinos, e sim, os motoristas

forneciam serviços análogos a táxis (CLEWLOW; MISHRA; CENTER, 2017; VINE; POLAK, 2015).

Em 2013, uma decisão da Comissão de Utilidades Públicas da Califórnia definiu oficialmente esses serviços como companhias de redes de transporte (TNCs, do inglês – *Transportation Network Companies*), embora ainda sejam frequentemente chamadas coloquialmente de *Ridesharing*, mais recentemente, *Ridehailing services* “serviços de carona” (CLEWLOW; MISHRA; CENTER, 2017).

### 2.1.1.5 Companhias de Rede de Transportes

As Companhias de Rede de Transporte (do inglês, *Transportation Network Companies* (TNC), possuem como principal função oferecer serviços de mobilidade utilizando tecnologias digitais, principalmente por meio do aplicativos para *smartphone*, nas quais se conectam os passageiros aos motoristas, estes que utilizam seus veículos pessoais para oferecer corridas. Estes serviços também são conhecidos como *Ridesharing* ou *Ridehailing* (KOFFMAN, 2016).

De acordo com as leis do Texas (*House Bill [HB] 1733, 84th Regular Session, codified as new Chapter 1954, Insurance Code*<sup>1</sup>), as TNC é uma corporação, parceria, empresa pessoal, ou outra entidade que opera no Estado do Texas, EUA, utilizando uma rede digital para conectar um motorista de companhia de redes de transportes os viajante para uma corrida pré-estabelecida.

Em outros estados, a definição normalmente inclui o uso de uma plataforma digital e software de aplicativo, geralmente acessado por *smartphone*, para estabelecer uma viagem. Assim, um motorista utilizando um veículo pessoal pode fornecer o serviço de transporte (KOFFMAN, 2016).

As TNC fornecem serviço de transporte baseado em aplicativo, como Uber e Cabify. Em 2014, o estado de Colorado nos EUA estabeleceu a primeira legislação afim de regulamentar e autorizar as operações de TNC. Atualmente, 33 estados americanos possuem algum tipo de legislação para as TNC.

No Brasil, a regulamentação de transporte público é de responsabilidade de cada município, porém, os veículos que utilizam os APPs de serviços de transportes são classificados como privado. A chegada do serviço fornecido pela empresa Uber provocou diversos conflitos com taxistas, nas principais capitais do país.

<sup>1</sup> [http://www.naic.org/documents/committees\\_c\\_sharing\\_econ\\_wg\\_related\\_tx\\_hb1733.pdf](http://www.naic.org/documents/committees_c_sharing_econ_wg_related_tx_hb1733.pdf)

Em Março de 2018, foi sancionado o projeto que regulamenta o transporte privado de passageiros por aplicativo, definindo algumas regras e cobranças de tributos, porém cabe aos municípios fiscalizar e regulamentar os serviços<sup>2</sup>.

## 2.2 Qualidade na indústria automobilística

O termo qualidade faz parte do setor automobilístico há muito tempo, principalmente após os conceitos de produção em larga escala nas das linhas de montagem, no início da década de 1930. Os elevados níveis de globalização dos produtos e as altas exigências de montadoras para com seus fornecedores originaram normas de qualidade específicas para o setor. Para Juran (2003), o termo qualidade está relacionado à realização de alguma atividade que tenha sido feita de tal forma que repeti-la ou refazê-la em um curto espaço de tempo, não seja necessário.

São grandes os desafios para se projetar, fabricar e garantir o funcionamento de um veículo. De acordo com Goldratt e Fox (1992) a qualidade baseada em manufatura tem como objetivo atender as conformidades às especificações, aos requisitos, não havendo nenhum defeito, ou seja, a busca pelo zero defeito.

A Organização Internacional de Normalização (ISO - do inglês *International Organization for Standardization*), define a qualidade como a "totalidade de características de uma entidade que lhe confere a capacidade de satisfazer as necessidades explícitas e implícitas"(ISO, 2005).

A ISO foi responsável pela primeira norma internacional sobre sistemas de gestão da qualidade, ISO 9000, criada em 1987, tinha como objetivo oferecer um sistema de garantia da qualidade a nível mundial, unificando as normas existentes em diversos países (ISO, 2005).

Entretanto, a aplicação da norma ISO série 9000 era insuficiente na concepção do veículo global (desenvolvimento do produto realizado normalmente na unidade matriz e manufaturado em diversas partes do mundo). Ela não garantia a qualidade necessária, por ser uma norma genérica, não tratava as exigências do setor, como processos de aprovação de peça de produção (PPAP), controle estatístico do processo (CEP), entre outros. Isto fez com que as principais fabricantes desenvolvessem suas próprias normas de qualidade para fornecedores de componentes e fábricas terceirizadas (MISZTAL, 2015).

<sup>2</sup> <https://g1.globo.com/politica/noticia/temer-sanciona-regulamentacao-de-aplicativos-de-transporte-privado-de-passageiros-como-uber-e-cabify.ghtml>

Desta forma, os projetos globais deram origem a normas de garantia da qualidade específicas do setor automotivo (HARO, 2001):

- (a) QS-9000 - originada no final da década de 80 pelas montadoras de automóveis americanas, Chrysler, Ford e General Motors;
- (b) VDA 6 - norma alemã originada na década de 90, termo VDA tem como significado Associação de Fabricantes para a Indústria Automobilística da Alemanha (do alemão, *Verband der Automobilindustri e. V*), sendo representada pela maioria das empresas deste país, entre elas a Audi, BMW, Opel, TRW, Mahle, Daimler e Volkswagen;
- (c) AVSQ - também originada na década de 90, a AVSQ do italiano *ANFIA Valutazione Sistemi Qualita*, que significa Avaliação de Sistema da Qualidade da ANFIA (*Associazione Nazionale Fra Industrie Automobilistiche*). Participaram desta norma a Fiat Auto, Pirelli, Magneti Marelli, Valeo e Gilardini;
- (d) EAQF - esta norma francesa teve origem na década de 90, elabora pelas montadoras Renault e Peugeot. A sigla EAQF, do francês, *Evaluation Apitude Qualité Fournisseur* (Avaliação da Atitude da Qualidade do Fornecedor).

Como resultado de tantas normas que regem o setor automotivo, o órgão internacional de padronização da ISO desenvolveu no final da década de 90, um novo conjunto de normas para atender as necessidades e os requisitos padrão dos fornecedores da indústria automotiva. A especificação técnica ISO / TS 16949 tinha como objetivo o desenvolvimento de um sistema de gestão da qualidade que proporcione melhoria contínua, com ênfase especial na prevenção de erros e na redução de variações, otimizando a cadeia de suprimentos (MISZTAL, 2015).

O conceito de qualidade descrito nesta subseção considera o veículo como produto, uma propriedade do cliente por tempo determinado. Este trabalho discute a qualidade voltada ao serviço de mobilidade. De acordo com (JÚNIOR et al., 2018) diversos grupos automotivos, como BMW e Daimler, estão modificando seus modelos de negócios, que até então tinham como foco o produto, para modelos com foco no serviço de mobilidade, alterando assim, a forma de relacionamento com o cliente e mantendo a marca consolidada. Diante disto, o conceito qualidade destes novos serviços, ainda é um desafio para os atuais grupos automotivos e novos entrantes.

### 2.3 Qualidade de experiência

A experiência de um cliente com qualquer tipo de serviço pode ser mensurada por seu grau de satisfação ou insatisfação. A Qualidade de Experiência (QoE, do inglês *Quality of Experience*) se concentra na experiência de serviço, principalmente nas áreas de telecomunicações, aplicações multimídias e provedores de serviços web, expressando a satisfação objetiva e subjetivamente do usuário (MÖLLER; RAAKE, 2014). Como definido em Caruana (2002), a QoE pode ser entendida como o resultado da comparação feitas por clientes entre a percepção de como um serviço foi realizado e suas expectativas.

O termo QoE se originou para completar as questões não abordadas pelas avaliações de Qualidade de Serviço (do inglês, *Quality of Service - QoS*), que avaliam os atributos técnicos de desempenho de rede, não revelando a qualidade do serviço conforme as percepções dos usuários finais e desconsiderando a sensibilidade humana (PIAMRAT et al., 2008).

Para (LAGHARI et al., 2012), a QoE pode ser utilizada para auxiliar nos parâmetros da QoS, considerando abstrato o conceito de QoE, com base na análise de utilização de dados do usuário.

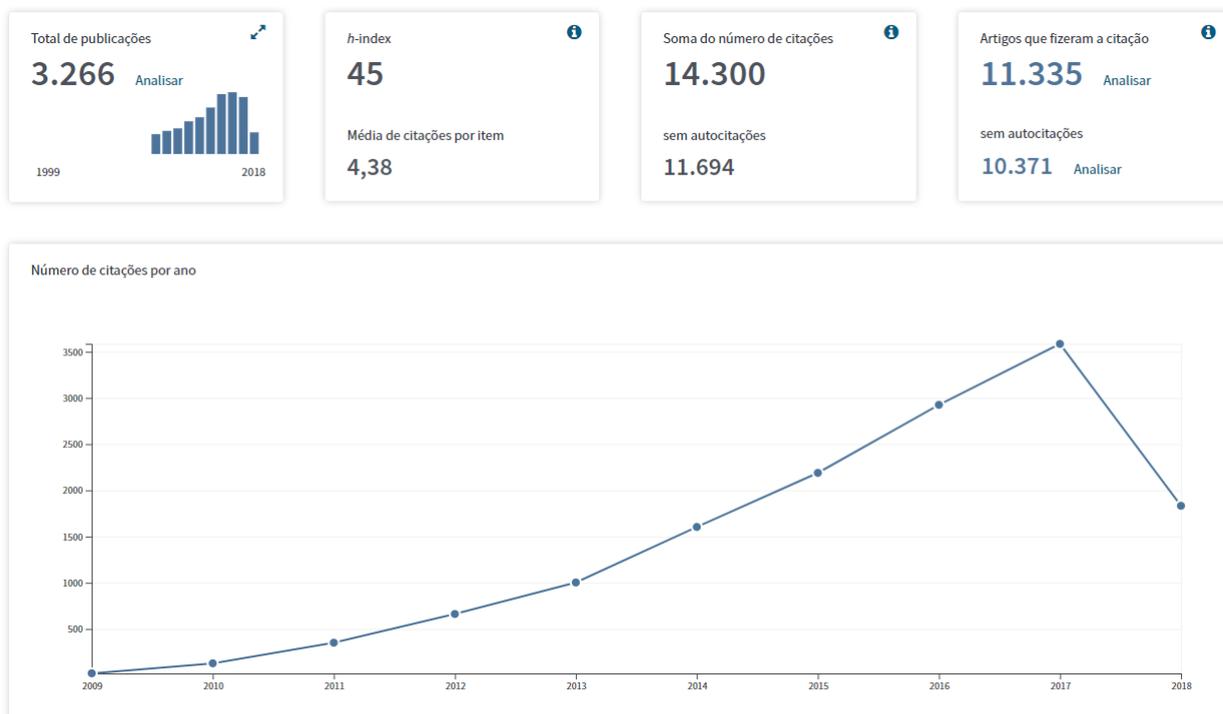
De acordo com Vieira et al. (2012), a QoE geralmente é confundida com QoS, pois os dois possuem relação por conta da percepção e a satisfação dos usuários terem origem em diversos aspectos diferentes, podendo um ser influenciado pelo desempenho do outro, ou seja, a QoS afeta a QoE, mas não é determinante.

Outro conceito relacionado a QoE é a Experiência do Usuário (UX, do inglês *User Experience*), definida pela (ISO9241-210, 2010) como "as percepções e respostas de uma pessoa que resultam do uso ou antecipação do uso de um produto, sistema ou serviço".

Um dos fatores que motivou o uso da QoE neste trabalho foi sua relevância acadêmica, justificando isto, um relatório gerado pelo *Web of Science* demonstra a importância do assunto, pesquisados os termos "Quality of Experience" e "QoE" restritos ao título, ligados pelo operador OR, considerando o intervalo de 10 anos (2009 até julho de 2018) e sem refinar nenhuma categoria, foram encontrados 3266 trabalhos, contra menos de 3000 da pesquisa de UX.

A Figura 2.2 foi extraída do site em questão, o gráfico refere-se à soma do número de citações por ano, totalizando 14300, sendo possível notar um crescimento exponencial das citações, ressaltam. Na parte da superior da figura tem-se: o número de publicações nos anos selecionados, o índice h, a soma já mencionada no gráfico e, por fim, os 11335 artigos que fizeram a citação. Todas essas informações demonstram a relevância do tema.

Figura 2.2 – Relatório de citações de QoE (2009 - 2018)



Fonte: Adaptado de Web of Science

A proposta de utilizar os conceitos da QoE no transporte compartilhado por aplicativo ainda é muito escassa, justifica-se isto nos trabalhos relacionados na Seção 2.7. Diante disto, faz-se necessário abordar outras definições relacionadas a proposta do trabalho.

A QoE é uma avaliação da satisfação, percepção do usuário, sobre o conteúdo exibido em algum dispositivo. Muitos fatores afetam a QoE dos aplicativos móveis, entre eles: a transmissão de dados (RODRÍGUEZ et al., 2016), o consumo de bateria (ICKIN; WAC; FIEDLER, 2013), o desempenho, e as características da Interface do Usuário (IU). As características de IU indicam como ele interage com os recursos de um APP e o tempo de resposta dos aplicativos está fortemente relacionado com o desempenho, ou seja, a impressão do resultado geral da qualidade dos serviços é uma ferramenta de feedback importante, possibilitando identificar a qualidade percebida pelo cliente (ZEPERNICK; ENGELKE, 2011; ICKIN et al., 2012).

Na definição Wu et al. (2009) QoE é de um construto multidimensional de percepções e comportamentos do usuário, que representa respostas emocionais, cognitivas e comportamentais, tanto objetivas e subjetivas ao usar um determinado sistema.

A QoE determina em sua análise final a satisfação de um usuário quando qualquer serviço, aplicativo ou produto possui interação. Esta possui um tempo de vida, inspirando mudanças e aperfeiçoamento da usabilidade (VIEIRA et al., 2012).

A abordagem de (SOUZA et al., 2017), possui uma forte relação com o que se propõe neste trabalho. Segundo os autores a provisão de serviços origina uma relação entre usuário e a infraestrutura provedora do serviço. O usuário tem a expectativa de que esta relação seja transparente, de modo que alguns esforços podem ser tomados com a QoE, sendo eles os perfis de serviços e/ou habilitadores de contexto.

Os perfis de serviços têm como conceito uma definição customizada de serviço, possibilitando uma melhor experiência do usuário de acordo com seus valores pré definidos. Selecionados os perfis, os serviços devem ser providos de acordo com as definições para tal perfil (ABRAMOWICZ et al., 2006).

Os habilitadores de contexto, por sua vez, propõem uma solução para sistemas em tempo real, obtendo automaticamente informações do usuário, para então decidir a melhor maneira de prestação de serviço que se encaixe nas necessidades do usuário (RICHTER; BOHM, 2006)

Desta forma, neste trabalho onde se propõe avaliar a qualidade dos serviços de mobilidade compartilhada entre usuários, a QoE é entendida como um conjunto de fatores que envolvam os perfis de serviço dos usuários provendo os habilitadores de contexto para a avaliação da qualidade de um serviço em mobilidade compartilhada por aplicativo. Para mensurar a satisfação do usuário utiliza-se a escala MOS, descrita na próxima subseção.

### **2.3.1 Pontuação média de opinião**

A Pontuação Média de Opinião (MOS, do inglês *Mean Opinion Score*) é uma medida subjetiva que pode refletir a qualidade percebida pelo usuário, podendo expressar a QoE. MOS é uma métrica, amplamente utilizada, para testes objetivos da modelagem da qualidade, por meio de uma pontuação numérica objetiva (1 a 5) que infere a experiência subjetiva do usuário (XU et al., 2011). O MOS utiliza a recomendação ITU-T P.800 (2008) por meio de uma escala de avaliação subjetiva de cinco valores possíveis, segundo Quadro 2.1.

De acordo com Costa (2015), existem duas formas de quantificar a qualidade percebida pelo usuário. A forma direta utiliza questionários de acordo com as especificações da ITU-T P.800. Os usuários atribuem valores de satisfação de acordo com a qualidade percebida, esta forma é um método subjetivo para avaliar a qualidade e resulta em uma pontuação definida pelo usuário. Neste sentido, essa abordagem possui como prerrogativa a aplicação de questionários a população acarretando em grande complexidade e/ou em grandes períodos de avaliação. A

Quadro 2.1 – Escala de Classificação MOS de 5 pontuações.

MOS	PERCEPÇÃO
5	Excelente
4	Boa
3	Razoável
2	Pobre
1	Ruim

Fonte: ITU-T P.800 (2008)

outra forma é indireta, chamada de avaliação objetiva que faz uso de algoritmos para estimar um índice MOS (COSTA, 2015).

### 2.3.2 Fatores que influenciam na Qualidade de Experiência

Diferentes fatores influenciam a Qualidade de Experiência, segundo (REITER et al., 2014). Determinados fatores que influenciam podem ser descritos de certa forma pelos usuários, por conta dos impactos da maneira que se utiliza algum serviço, baseado nas experiências de usuários, os autores agruparam em três categorias tais fatores, sendo eles: fatores humanos, fatores do sistema e fatores do contexto.

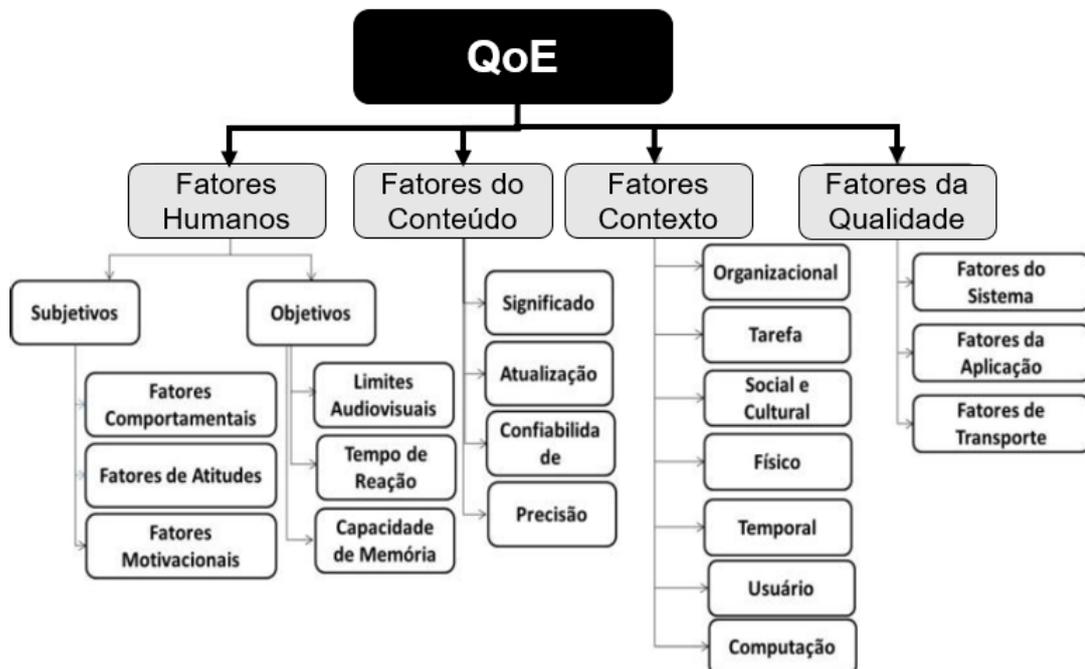
Silva (2014) propõe um modelo com abordagem interdisciplinar frente a outros modelos multidimensionais de fatores que impactam na QoE. Os fatores que influenciam na QoE, segundo a autora, são os fatores humanos, de conteúdo, de contexto e fatores de qualidade. A taxonomia das dimensões que impactam na QoE são apresentados na Figura 2.3, sendo a definição de cada um dos fatores descritas a seguir:

- (a) Fatores Humanos: Podem ser subjetivos e mensurados por meio de aplicação de modelos psicológicos para compreender as intenções e comportamentos humanos (atitudes pessoais, sociais, controle comportamental percebido). Também podem ser objetivos, abordados por meio da ciência da cognição, modelos mentais e os designers de interface, todos são usados para entender o desempenho da tarefa humana;
- (b) Fatores Conteúdo: (Sintático e Semântico) Mídia do Conhecimento preocupa-se tanto com a comunicação técnica quanto com a linguagem das palavras. A semiótica ajuda compreender o significado e valorização que o receptor atribui a

mensagem de acordo com a semântica. A Engenharia do conhecimento é usada para desambiguar termos;

- (c) Fatores Contexto: Social e Cultural (sociologia e psicologia), tarefa, organizacional (gestão do conhecimento);
- (d) Fatores Qualidade: Sistema (Engenharia de software), Redes e Aplicações (Sistemas Multimídias).

Figura 2.3 – Taxonomia dos fatores que impactam na QoE



Fonte: Adaptado de Silva (2014)

Neste trabalho pretende-se utilizar a QoE em uma abordagem dos fatores humanos que impactam o serviço de mobilidade compartilhada.

## 2.4 Algoritmos de inteligência artificial

A inteligência artificial (IA) é o nome utilizado em uma área específica da ciência da computação. Elas são técnicas que permitem ao computador aprimorar seu desempenho em determinadas tarefas, por meio da elaboração e aperfeiçoamento de algoritmos, de maneira independente ou assistida por seres humanos (LANGLEY, 1996).

Os algoritmos de aprendizado de máquina, pertencentes a IA, são utilizados como ferramenta auxiliar para atender aos objetivos propostos. Desta maneira, são apresentados os conceitos gerais dos algoritmos utilizados, elucidando o leitor sobre o tema e sua relevância para o

trabalho. A aplicação desta ferramenta é feita por um *software* (WEKA), com os algoritmos já definidos previamente.

Segundo Russell e Norvig (2016), diversas áreas se empenham nos estudos de algum aspecto da IA sendo objeto de apreciação de matemáticos, economistas, neurocientistas, psicólogos, filósofos, além dos cientistas da computação e outros. A IA é um campo de pesquisa recente em comparação com outras ciências, tendo como característica a interdisciplinaridade.

As aplicações para IA são diversas, podendo destacar os sistemas de recomendação, reconhecimento de padrões, previsão de séries temporais, mecanismos de busca, modelagens, e outras tarefas onde a delimitação e programação de algoritmos com base em regras são complexas para a natureza do problema.

Existem vários subcampos da IA, onde o aprendizado de máquina pode ser considerado um deles, essa técnica utiliza normalmente métodos como a regressão linear e modelos em árvores, assim como, métodos mais sofisticados como a Máquina de Vetor de Suporte (SVM), Redes Neurais Artificiais (RNA) e Árvores de Decisão. A comparação entre esses modelos pode ser utilizada para se obter melhores previsões (FRANKLIN, 2005).

Os algoritmos de aprendizado de máquina possuem algumas características e são classificados de acordo com o tipo de variável de saída, podendo ser de regressão, para prever variáveis de saída com valores contínuos, ou podem ser de classificação, para prever o grau de aproximação à uma ou várias classes (MOHRI; ROSTAMIZADEH; TALWALKAR, 2012). Quanto ao aprendizado podem ser classificados de duas formas:

- (a) Supervisionado: Utilizado para o treinamento um conjunto de observações classificadas, podendo ser eventos com rotulações e/ou resultados conhecidos. Neste aprendizado o objetivo é que o algoritmo atribua corretamente os rótulos a novas observações (MOHRI; ROSTAMIZADEH; TALWALKAR, 2012);
- (b) Não supervisionado: Utilizado para conjuntos não classificados de observação, o objetivo é que o sistema descubra grupos de indivíduos similares por técnicas de *Clustering* (agrupamento) (BISHOP, 2016).

A aplicação de IA neste trabalho é feita com base em um sistema de recomendação, sendo o aprendizado do tipo supervisionado. Nas subseções que seguem são descritos os algoritmos utilizados para este fim.

### 2.4.1 Redes neurais

As Redes Neurais Artificiais (RNA) tiveram origem na tentativa de representar e modelar o sistema nervoso humano, usando computadores e modelagens matemáticas e tem sido utilizada de forma extensiva desde então, proporcionando uma boa alternativa à IA. O seu uso crescente se dá pela utilização de uma arquitetura com alto paralelismo, possibilitando um melhor desempenho quando comparado aos modelos convencionais (BISHOP; BISHOP, 1995).

As propriedades principais de uma RNA são em razão da capacidade de aprendizado por meio de exemplos, generalizando a informação aprendida, realizando interpolação baseado no fornecimento de padrões e selecionando propriedades específicas em suas amostras (ABER; AMANI-GHADIM; MIRZAJANI, 2009a) (ABER; AMANI-GHADIM; MIRZAJANI, 2009b). Segundo Bishop e Bishop (1995), a generalização ocorre por meio do aprendizado dos conjuntos de entrada reduzido e retornando saídas coerentes para dados desconhecidos.

As RNAs possuem diversas arquiteturas, uma que se destaca é a Rede Neural Artificial de Múltiplas Camadas (MLP, do inglês *Multilayer Perceptron*) que é uma RNA formada por neurônios com várias camadas, a saída de cada neurônio de uma camada precedente é entrada para todos os neurônios da camada seguinte. Sua arquitetura é determinada pela sua topologia da rede e pela função de ativação de cada nodo, sendo formada basicamente por três camadas, a de entrada, a intermediária e camada de saída, além do número de neurônios que forma cada camada (BISHOP; BISHOP, 1995).

### 2.4.2 Árvore de decisão

A árvore de decisão é um algoritmo de IA que utiliza uma estratégia de dividir para conquistar, seu princípio é agrupar instâncias de forma recursiva, minimizando a variabilidade das classes. Para isso, utiliza-se uma estrutura onde cada nó interno é um atributo da entrada (amostra), as folhas são valores do atributo-classe, cada ramo liga um nó filho a um nó pai e é rotulado com um valor do atributo contido no nó pai (TAN et al., 2006).

Baseado no conceito de folhas, cada nó interno corresponde a uma decisão de classificação. A árvore não é capaz de realizar regressão desempenhando somente o papel de classificador, podendo atender a necessidade de classificação de tópicos (BHARGAVA et al., 2013).

### 2.4.3 Máquina de Vetor de Suporte

A Máquina de Vetor de Suporte (SVM, do inglês, *Support Vector Machine*) utiliza métodos discriminatórios que aprendem limites entre as classes, realizando uma classificação binária com base na separação de hiperplanos. Seu mecanismo de classificação consiste na separação ótima de dados, independentemente da dimensionalidade. Já seu separador é escolhido de forma a maximizar as distâncias desses hiperplanos e os vetores de formação mais próximos, os quais são chamados de vetores de suporte (ALGHOWINEM et al., 2016).

A vantagem desta técnica em relação a outras é que as funções do modelo de probabilidade não precisam ser conhecidas anteriormente (SAKR; ELHAJJ; HUIJER, 2010). Esta vantagem é importante para fins de generalização, pois, em situações práticas, podem não haver informações suficientes sobre as funções e distribuições entre as entradas e saídas.

### 2.4.4 Random forest

Como definido por Breiman (2001), as árvores de decisão são treinadas com os mesmos parâmetros do algoritmo *Random Forest*, porém, utilizam diferentes conjuntos de treinamento. Os conjuntos são gerados a partir dos conjuntos de treinamento original utilizando procedimento de inicialização, onde, para cada conjunto de treinamento, são selecionados aleatoriamente o mesmo número de vetores como no conjunto original, selecionados com a substituição. Os vetores podem ser utilizados mais de uma vez além de outros estarem ausentes, de tal forma que, nem todas as variáveis são utilizadas, mas um subconjunto aleatório destas (BREIMAN, 2001).

Outra abordagem envolvendo o desenvolvimento de múltiplas árvores com amostras aleatórias de subespaços, utilizados como recursos de entrada, combinando com as saídas resultantes, este método possibilita uma generalização superior para pequenas amostras de treinamento, entretanto, são computacionalmente intensivos (HAM et al., 2005).

## 2.5 Redes sociais

As redes sociais são espaços criados com o objetivo de efetuar o compartilhamento da informação por meio da troca de experiências, além de contribuir para a construção do conhecimento, criando bases e gerando informações relevantes, podendo essas ações trazer mudanças no contexto em que as pessoas estão inseridas (TOMAÉL; ALCARÁ; CHIARA, 2005). Na

definição de Boyd (2007), os sites de redes sociais são utilizadas por seus usuários como um espaço social capaz de construir, de forma simbólica, novos cotidianos por meio de ações que geram novos significados, ou até mesmo, novos personagens.

As plataformas, como o Facebook, Twitter e Instagram, possibilitam aos seus autores conversão e interação uns com os outros, por meio de curtidas, comentários, postagens e compartilhamentos de diversos tipos de conteúdo (RECUERO, 2014).

O Facebook é a principal rede social atualmente, possuindo o maior número de usuários ativos no mundo. A rede social já ultrapassa os 2 bilhões de usuários. As quantidades de dados gerados por esses usuários podem ser utilizadas de diversas maneiras.

O uso de dados de usuários das redes sociais é assunto recorrente. De acordo com (FRANCO, 2018), os dados dos usuários podem ser utilizados para definir o comportamento deles, como exemplo, melhorando o sistema de anúncios em suas plataformas.

Neste trabalho, optou-se por utilizar a rede social Facebook por ela possibilitar o acesso aos dados de cadastro dos usuários, a plataforma da rede social disponibiliza um desenvolvedor de aplicativos (Facebook for developers<sup>3</sup>), que possibilita a extração de dados como: idade, gênero, relacionamento e grau de instrução, desde que o usuário concorde com os termos ao acessar o aplicativo.

## 2.6 Sistemas de recomendação

Sistemas de Recomendação (SR) são capazes de processar grande quantidade de dados, possibilitando a recomendação de algo ou alguém com perfil semelhante a um usuário do SR. Os SRs permitem que as empresas gerem sistemas de sugestão personalizados de produtos ou serviços aos seus clientes, tornando-se parte integrante de alguns sites de comércio eletrônico, como Amazon.com e de serviços de TV por Internet como Netflix (BURKE, 2002).

A aplicação de SR contribui para o aumento da satisfação e fidelidade dos usuários, graças a melhor compreensão de seus perfis, oferecendo a eles produtos e serviços relevantes. O sistema tornou-se atualmente uma solução importante em empresas que possuem um extenso leque de produtos e serviços, possibilitando reduzir os esforços de busca por usuários (RICCI; ROKACH; SHAPIRA, 2011).

Existem diversos exemplos de SR, entre eles estão a recomendação de filmes aos usuários, utilizando como base as avaliações de filmes já assistidos, a recomendação de artigos de

---

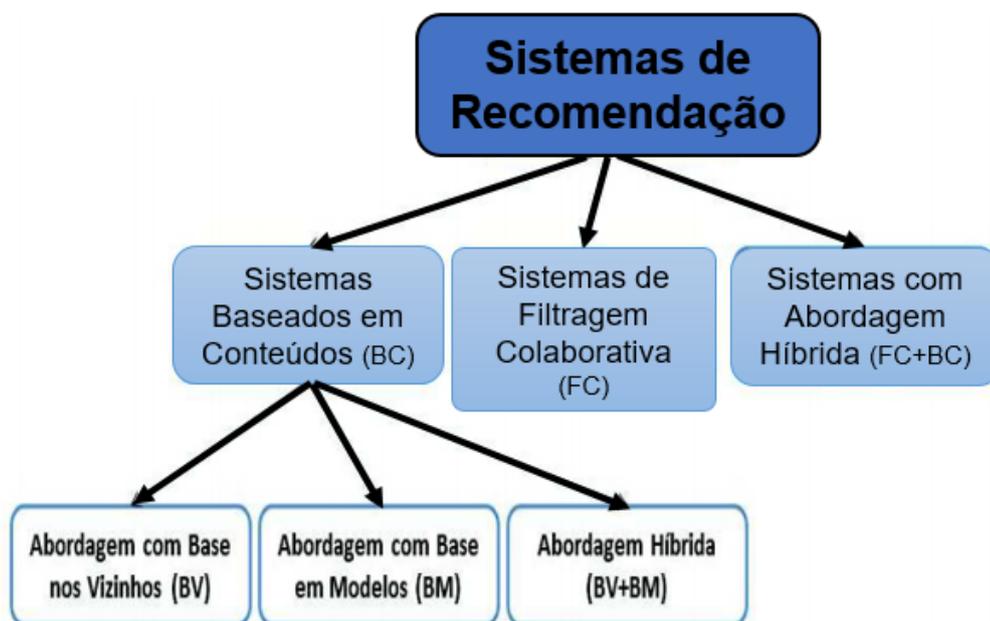
<sup>3</sup> <https://developers.facebook.com/>

notícias digitais, com base no histórico de leitura, em ambientes de comércio e lojas on-line a recomendação de produtos à clientes baseadas nas buscas e compras passadas e recomendação e sugestão de amigos e comunidades em redes sociais, baseando-se em redes de amigos.

O objetivo dos SR é proporcionar serviços personalizados por meio do desenvolvimento de sistemas capazes de reduzirem a sobrecarga de informações e recuperar serviços e conhecimentos de grande quantidade de dados. As recomendações são originadas por meio da análise dos comportamentos de grupos de usuários e do usuário, o qual receberá a recomendação, possibilitando prever as preferências e interesses de um usuário (LU et al., 2015).

Em geral, independente do objetivo e do tipo de informação a ser recomendada, vislumbra-se hoje três abordagens distintas da forma como se define o interesse do usuário e como se calcula a similaridade entre os itens, elas são: Filtragem baseada em Conteúdo, Filtragem Colaborativa e Filtragem Híbrida (ADOMAVICIUS; TUZHILIN, 2005). A Figura 2.4, demonstra a taxonomia dos principais sistemas de recomendação existentes.

Figura 2.4 – Taxonomia dos Sistemas de Recomendação



Fonte: Adaptado de Adomavicius e Tuzhilin (2005)

- (a) **Sistemas de Recomendação Baseados em Conteúdo (BC):** Tem como objetivo gerar automaticamente as descrições dos itens e compará-los com a descrição de cada item informado e com a descrição do usuário, verifica-se se o item é relevante para o usuário ou não. O BC aplica técnicas de indexação de frequência de termos, índices de busca booleana e sistemas de filtragem probabilística.

- (b) Sistemas de Recomendação de Filtragem Colaborativa (FC): A filtragem colaborativa complementa a filtragem baseada em conteúdo, esse modelo procura prever a pontuação de um item para um usuário em particular, baseando em suas atividades com gostos semelhantes ao usuário alvo, sendo este previamente pontuado.
- (c) Abordagens Híbridas (BC+FC): A filtragem híbrida tem como estratégia combinar os benefícios das duas técnicas de filtragens anteriores, a determinação do usuário alvo é definida a partir da semelhança existente entre os perfis de usuários. Após determinar os usuários semelhantes o próximo passo é recomendar novos itens utilizando as técnicas convencionais.

## 2.7 Trabalhos relacionados

Vieira et al. (2012) trata a QoE em aplicativos móveis para o planejamento de rotas, emissão de bilhetes e validação móvel no transporte público, o trabalho é baseado na definição de que as emoções são fundamentais para a experiência humana e que influenciam a tomada racional de decisão. Os autores apresentam uma nova solução para identificar e compreender os padrões de satisfação dos usuários do transporte público, propondo um protótipo de aplicativo para *smartphone* baseado na pesquisa multidisciplinar vastamente conduzida, fazendo uso das informações sensoriais coletadas por meio de sensores inerciais dos *smartphones* dos usuários (acelerômetro, microfone, temperatura, GPS e outros).

O trabalho possibilitou o desenvolvimento de um protótipo permitindo a coleta de dados pelos sensores no transporte público. Com isto, os autores apresentam uma solução para melhorar a QoE de forma autônoma e menos discreta com o potencial de criar serviços centrados no usuário (VIEIRA et al., 2012). No entanto, esse trabalho abordou a QoE no transporte público e com abordagens de conforto térmico e acústico.

Em (DAI et al., 2016), o aprimoramento da QoE do usuário foi proposto por meio de um mecanismo de controle de cruzamentos, imaginado um cenário futuro com veículos autônomos e uma infraestrutura conectada. O trabalho resulta em um algoritmo com modelo de simulação capaz de melhorar o tempo de viagem e também a segurança dos usuários. O termo QoE é aplicado, porém, trata de aspectos voltados ao tempo de viagem, diferente dos fatores subjetivos abordados nesta dissertação.

Em Mallus et al. (2017), a QoE é aplicada por meio dos resultados fornecidos por usuários, da implementação de ensaios extensivos do serviço de *Carpooling* em tempo real. Os autores implementam um sistema de emulação para gerar um número crescente de usuário da plataforma CLACSSON, para isso é feita uma variação da população da cidade de Cagliari, na Itália. Um novo serviço é proposto para ajudar os usuários a encontrarem companheiros de viagem de forma semiautomática, atingindo resultados capazes de gerar informações importantes para aprimorar a experiência com o CLACSOON.

O ComeWithMe é apresentado por Lira et al. (2015), um método de *Carpooling* orientado pelas atividades diárias dos usuários, que consideram dados de viagens e comportamentos, além dos dados de destino final ou trajeto dos usuários. O processo possui como entrada os dados das rotinas de viagens, pontos de interesses, conjunto de intervalos e requisição de viagens, também possui um algoritmo que utiliza essas informações para processar possíveis caronas para as requisições, potencializando o número de possíveis viagens.

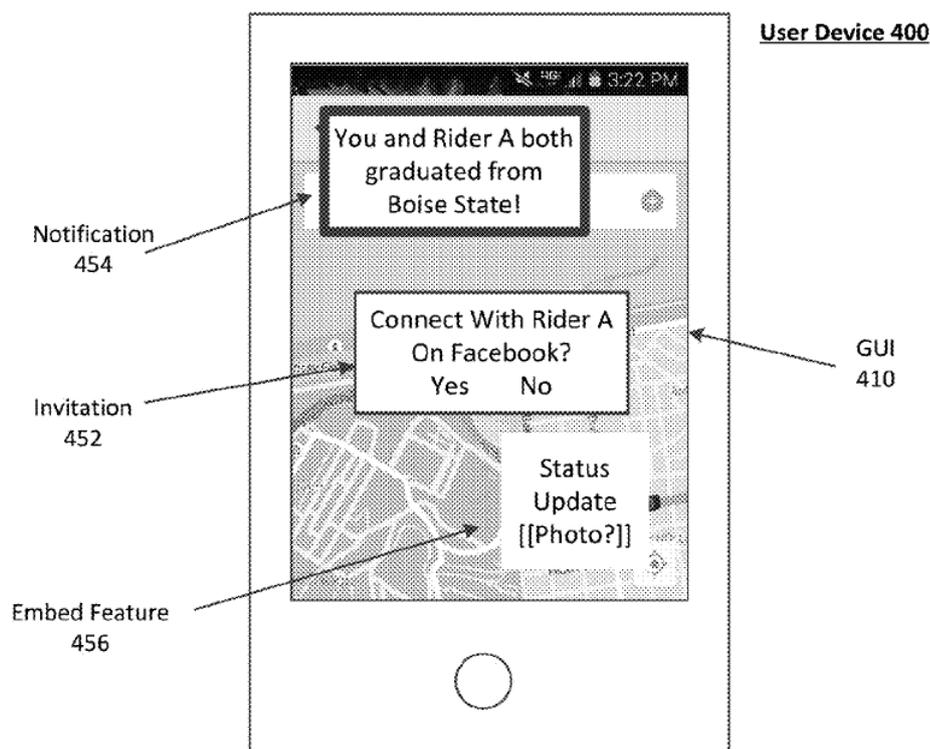
O volume de trabalhos que abordam o uso de QoE em aplicativos móveis voltados para a mobilidade são reduzidos, entretanto, a abordagem em outros tipos de APPs são bem extensas. Um dos estudos que possui relação com este trabalho é o de Dong et al. (2014), pioneiro ao abordar os problemas de QoE em redes sociais em aplicativos móveis, por meio de uma investigação abrangente sobre avanços em redes sócias moveis, resultando em uma proposta de um modelo para o aprimoramento da QoE.

Recentemente, uma patente de projeto intitulada “*Social media integration for transport arrangement service*” abordou um tema relacionado a este trabalho, o sistema pode acessar os dados das redes sociais para o usuário solicitante e outros passageiros, quando os dados acessados indicarem um vínculo comum entre usuários ele pode gerar e transmitir uma notificação ao solicitante, indicando uma ligação em comum (BIJOR et al., 2017). O sistema possui uma interface para conectar, por meio de uma rede, os provedores de mídias sociais e organiza o transporte entre os usuários do sistema, podem ser utilizadas diversas redes sociais ou *network services*, nos quais são mencionados, Facebook, Myspace, Whatsapp, LinkedIn, Gaming Network, plataformas de encontros, e redes online em geral (fóruns, hobby, entre outros) (BIJOR et al., 2017).

A Figura 2.5 demonstra um exemplo do sistema. Ao cruzar as informações de usuários que solicitaram uma corrida com trajetos similares, é exibida uma notificação mostrando alguma particularidade comum entre eles, no caso os passageiros que se graduaram na mesma

universidade. Em seguida o sistema gera um convite e também exibe as características do convidado (status, foto ou até o link da rede social) e, posteriormente, o compartilhamento pode então ser autorizado.

Figura 2.5 – Sistema de recomendação de *Ridesharing* Uber



Fonte: Bijor, Rahul et al. (2016)

Dentre os trabalhos mencionados, o de Bijour, Rahul et al. (2016) é o que possui mais características em comum com os objetivos propostos neste trabalho. Os autores da patente não propõem o sistema com objetivo de avaliar a QoE, entretanto, a abordagem de compartilhamento de corridas e/ou viagens se assemelha por utilizarem as redes sociais como fonte de dados para aprimorar a experiência dos usuários. O seu foco principal é encontrar relação entre os usuários, diferente do proposto nesta dissertação, que tem como objetivo evitar o compartilhamento entre usuários com características comportamentais totalmente opostas.

### 3 MODELO DE RECOMENDAÇÃO PROPOSTO

Neste capítulo é descrito o fluxograma do modelo de recomendação, também denominado aqui de modelos RsRS (*Ridesharing Recommendation System*), por meio de uma visão macro das etapas para definição do modelo proposto.

#### 3.1 Principais componentes e fluxograma do modelo de recomendação

O fluxograma de ações realizadas para determinar o modelo de recomendação é ilustrado na Figura 3.1. Basicamente ele possui duas etapas, sendo a definição do modelo de classificação e o sistema de recomendação proposto.

##### 3.1.1 Modelo de classificação por AM

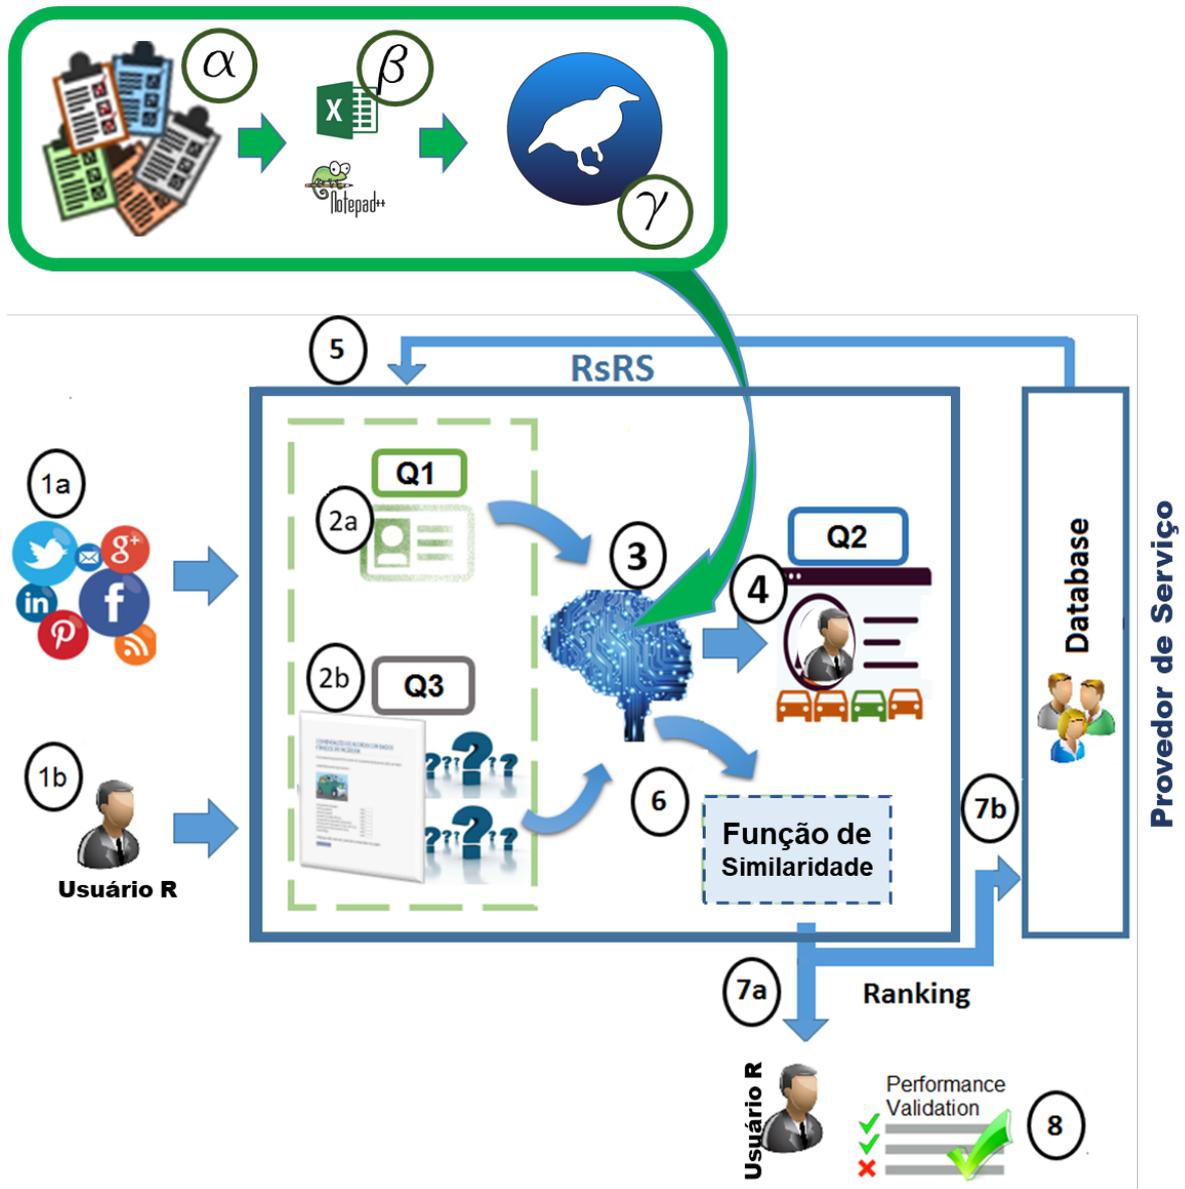
A primeira parte do fluxograma é composta pelo modelo de classificação que utiliza Aprendizado de Máquina (AM), ela contempla toda a parte superior da Figura 3.1 com contornos verdes e com letras gregas. Ela representa a fase de obtenção da base de dados e definição dos algoritmos de AM, o item  $\alpha$  trata dos testes subjetivos aplicados via questionário, dividido em três categorias (Q1, Q2 e Q3), detalhadas na Seção 4.1.

Posteriormente, o item  $\beta$ , descreve o pré processamento dos dados obtidos, inicialmente tratados em Excel e depois passados para o formato .ARFF, possibilitando a aplicação dos algoritmos. A terceira etapa ( $\gamma$ ), aborda o tratamento de dados utilizando algoritmos de AM, mais especificamente os de aprendizado de máquina, por meio do software WEKA, descrito na subseção 4.2.1. Após diversos algoritmos testados o que alcançou melhor resultado foi selecionado, e então aplicado como "cérebro"(item 3,) da etapa seguinte do modelo RsRS.

##### 3.1.2 Sistema de recomendação proposto

A segunda parte, contornos em azul, inicia com o item 1a, obtendo de forma prévia as informações demográficas de perfis dos usuários de redes sociais que utilizaram o modelo. Elas são extraídas após o usuário logar pela primeira vez no aplicativo desenvolvido para este trabalho, por meio do Facebook Developments (detalhado na Subseção 4.3). O aplicativo pode ser acessado via Web pelos usuários, neste caso ilustrado pelo Usuário R (1b), onde é disponibilizado algumas questões chave para serem respondidas.

Figura 3.1 – Fluxograma da metodologia utilizada para determinar o modelo proposto.



Fonte: Do próprio trabalho

As informações básicas do perfil do usuário, conforme as questões Q1 do questionário, são salvas no servidor (2a). As questões relacionadas a Q3 (questionário), são informadas pelo Usuário R e também salvas no servidor (2b). O modelo de classificação definido na primeira parte (3) processa as informações salvas e determina o perfil de compartilhamento de viagens do Usuário R (4).

Em seguida, as informações de possíveis passageiros, com rotas similares, são enviadas ao provedor de serviços RsRS (5). Importante ressaltar, o modelo descrito seleciona até quatro usuários por viagem, o Usuário R corresponde ao primeiro passageiro do veículo, sendo então, o perfil dele que irá determinar a função de similaridade (6). Basicamente, isto é feito por

meio de um ranking definido por um algoritmo de similaridade, que recebe as informações dos usuários já classificados, seleciona os passageiros em potencial, descrita na subsecção 4.3.4.

Por fim, o modelo RsRS considera o envio da classificação recomendada para o primeiro passageiro - Usuário R (7a) e/ou para o provedor de serviços (7b).

Para validar o desempenho do modelo RsRS proposto, diferentes voluntários participaram de testes subjetivos adicionais, para validar a precisão e a utilidade da lista de classificados (8). Esses voluntários simulam uma lista de passageiros que utilizariam a mobilidade compartilhada.

O capítulo que segue detalha a metodologia utilizada, descrevendo os testes subjetivos via questionário, em seguida o tratamento de dados utilizando algoritmos de aprendizado de máquina, a implementação do sistema de recomendação e, por fim, detalhes das métricas utilizadas para a avaliação de desempenho dos algoritmos de aprendizado de máquina.

## 4 METODOLOGIA PROPOSTA

Neste capítulo é apresentada a metodologia utilizada para o desenvolvimento desta dissertação, resultando em um modelo de recomendação que possa aprimorar a qualidade de experiência dos usuários da mobilidade compartilhada.

Inicialmente, a pesquisa foi desenvolvida mediante a utilização de acervo teórico, possibilitando o desenvolvimento do Referencial teórico, bem como, a verificação de trabalhos relacionados. Foram utilizadas as bases da *Web of Science*, *Google Acadêmico* e *IEEE Xplore*.

Na sequência, são apresentadas as seções descrevendo os testes subjetivos via questionário. Em seguida, o tratamento de dados utilizando algoritmos de aprendizado de máquina, seguido pela seção implementação do sistema de recomendação e, por fim, métricas para avaliação de desempenho.

### 4.1 Testes subjetivos via questionário

Características pessoais podem influenciar na qualidade de experiência dos usuários, conforme descrito na Seção 2.3, com o objetivo de elaborar uma base de dados com as características e também aspectos pessoais de usuários de transporte privado por aplicativo, um questionário foi elaborado. Segundo Parasuraman, Grewal e Krishnan (2006), um questionário é composto por um conjunto de perguntas, elaborado para gerar os dados necessários para se alcançar os objetivos do projeto.

A elaboração de um questionário exige cuidados, de acordo com Chagas (2000), no processo de pesquisa, pois, podem ocorrer erros na escolha e no tamanho da amostra, dados mal elaborados, com questões tendenciosas ou dúbias e escalas de medição mal dimensionadas. Durante a elaboração é importante avaliar as diferenças nas características do que está sendo medido, mas também diferenças em variáveis, tais como grau de formação, personalidade, preferências, entre outras, as quais podem prejudicar os resultados de um questionário ou as avaliações de um observador.

Os passos para elaboração de um questionário devem estabelecer uma ligação entre o problema e os objetos da pesquisa. Desta forma, durante a elaboração do questionário atentou-se aos pontos mencionados, considerando o retorno de informações de pessoas que conheçam o serviço de transporte privado compartilhado, ou não, por aplicativo.

Nas subseções que seguem são tratadas as definições do questionário, sua aplicação e os critérios para definição da base de dados.

#### 4.1.1 Definição do questionário

O questionário foi estruturado basicamente em 3 partes, denominadas aqui de Q1, Q2 e Q3. No Apêndice A está disponível o questionário completo aplicado aos respondentes.

Na primeira parte do questionário (Q1) são solicitadas as informações pessoais dos respondentes, sendo elas: faixa etária separada em 4 faixas, além da idade exata, o gênero, o tipo de relacionamento e o grau de instrução.

A segunda parte (Q2), aborda os parâmetros dos respondentes com base em tópicos e temas da atualidade. Estes foram definidos por duas linhas, a primeira baseou-se em matérias de jornais que tratam o modelo de compartilhamento de corridas por aplicativos de transporte. Já a segunda parte leva em conta os principais assuntos tratados nas redes sociais. Esses parâmetros são detalhados na Subseção 4.1.1.1.

Antecedendo as questões desta parte, uma descrição foi feita sobre modelos de mobilidade compartilhada em aplicativos por transporte, com o intuito de elucidar o respondente, além de atender as orientações descritas na Seção 4.1. As respostas foram avaliadas de 1 a 5, sendo 1 - muito baixa aceitabilidade em compartilhar uma corrida e/ou viagem, e para 5 - muito alta aceitabilidade em compartilhar uma corrida e/ou viagem. Este critério de avaliação foi adaptado da escala MOS, descrito na Subseção 2.3.1.

As questões abordadas em Q2 foram:

1. Eu compartilharia uma corrida/viagem com uma pessoa desconhecida;
2. Eu compartilharia uma corrida/viagem com um casal desconhecido;
3. Eu compartilharia uma corrida/viagem com pessoas de gênero oposto ao meu;
4. Eu compartilharia uma corrida/viagem com pessoas opostas à minha opinião política;
5. Eu compartilharia uma corrida/viagem com pessoas solteiras;
6. Eu compartilharia uma corrida/viagem com pessoas com hobby diferente do meu;
7. Eu compartilharia uma corrida/viagem com pessoas com algum tipo união estável;
8. Eu compartilharia uma corrida/viagem com pessoas que falassem sobre futebol;
9. Eu compartilharia uma corrida/viagem com pessoas que torcem para times rivais ao meu (Ex. Palmeiras x Corinthians, Atlético x Cruzeiro);

10. Eu compartilharia uma corrida/viagem com pessoas de opinião religiosa diferente da minha;
11. Eu compartilharia uma corrida/viagem com pessoas que transportassem animais (cachorro ou gato);
12. Ao compartilhar uma corrida/viagem eu desejo não dialogar com outras pessoas;
13. Ao compartilhar uma corrida/viagem, em caso de eu escolher não dialogar com outras pessoas, desejo que elas saibam disso previamente de alguma forma.

Antecedendo ao texto, uma questão avalia se os participantes já utilizaram alguma vez aplicativos de transporte privado.

Por fim, a parte Q3 trata do nível de importância dos principais tópicos tratados nas questões de Q2, questionando qual a relevância e importância das mesmas, estas questões tem por objetivo prover uma base de dados complementar para os algoritmos de classificação. As questões abordadas nesta parte foram:

1. Qual a relevância da sua opção política?
2. Qual a relevância da sua opção religiosa?
3. Qual a relevância da sua orientação sexual em um convívio social?
4. Qual a relevância da sua opção por esporte?
5. Qual a importância da sua opção de hobby?
6. Qual a importância que animais possuem para você?
7. Qual a importância em se socializar com novas pessoas?
8. Qual a importância de socializar com pessoas com quem você possa se envolver?

De maneira semelhante em Q2, as respostas de Q3 avaliavam de 1 a 5, baseado no contexto solicitado, podendo 1 ser muito pouco, baixa relação e baixa importância e 5 para extremamente, alta relação e alta importância.

#### 4.1.1.1 Parâmetros propostos para a classificação de preferências

Os parâmetros propostos para classificar as preferências foram definidos inicialmente pelos dados demográficos dos usuários. Em seguida, os temas considerados relevantes durante o compartilhamento foram definidos por duas linhas. A primeira baseou-se em reportagens que abordavam o modelo de compartilhamento *Ridesharing* (Uberpool) e suas consequências, já a segunda, considerou os *trending topics*<sup>1</sup> do Twitter

O lançamento da modalidade Uberpool fez com que alguns meios de comunicação avaliassem o serviço, descrevendo as experiências de usuários. SOPRANA (2016) menciona as experiências tanto positivas quanto negativas durante o compartilhamento entre manifestantes políticos, casais gays e de pessoas que abordaram assuntos sobre hobby. A comparação do modelo de transporte com a rede social Tinder foi mencionada por SCIORTINO (2015), tratando a possibilidade de os usuários conseguirem encontros amorosos durante um compartilhamento de corrida.

As redes sociais possibilitam a discussão de qualquer assunto, os acontecimentos de grande repercussão geram inúmeros comentários, de diversos usuários e em poucos minutos. O Twitter por meio do seu *trending topics* elenca os principais assuntos discutidos no momento e no dia, constantemente assuntos relacionados a política, esporte e religião são destaques. Com base nesses temas tratados nas duas linhas, destacou-se os tópicos que abordavam a política, religião, relacionamentos, gênero, hobby, comunicação, vida social, esporte e animais, sendo esses utilizados como parâmetros para a classificação de preferências.

#### 4.1.2 Critérios para definição da base de dados

Os questionários foram aplicados em um ambiente controlado na Universidade de São Paulo (USP), possibilitando todos os voluntários responderem os questionários de maneira manuscrita e sem interrupções.

Os parâmetros abordados nos questionários podem diferenciar de acordo com a região que os voluntários habitam. Desta forma, restringiu-se somente a população do grande centro de São Paulo, sendo esta, a cidade com o maior número de corridas de Uber mundialmente <sup>2</sup>.

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

<sup>2</sup> <<https://veja.abril.com.br/economia/sao-paulo-e-a-cidade-com-o-maior-numero-de-viagens-na-uber/>> Acessado em: 14/08/2017

A quantidade de amostras foi definida pela estabilidade da mediada nos resultados, considerando que todas as possíveis respostas de cada uma das perguntas dos questionários estivessem balanceadas, ou seja com um número similar de respostas. Desta forma o número de participantes nos testes subjetivos foi sendo incrementado, em grupos, resultando em 296 respondentes, onde se estabeleceu a condição de estabilidade.

## 4.2 Tratamento dos dados utilizando algoritmos de aprendizado de máquina

Após o questionário aplicado, os resultados foram organizados em planilhas por meio do Excel para o tratamento iniciais dos dados, posteriormente os dados foram transferidos para o formato .ARFF com o uso do NOTEPAD++ (item  $\beta$  da Fig. 3.1). Em seguida, a técnica de aprendizado de máquina é realizada. A análise foi executada em um computador com CPU de 2,5 GHz e 6,00 GB de RAM.

Figura 4.1 – Representação dos dados organizados.

```

1 @relation mobility
2
3 @attribute age_range {1,2,3,4}
4 @attribute age numeric
5 @attribute gender {M,F}
6 @attribute relation {casado,solteiro,divorciado,relacionamentoserio,viuvo}
7 @attribute escolarity {ensinofundam,ensinomedio,tecnico,superior,mestrado,doutorado}
8 @attribute oneone {1,2,3,4,5}
9 @attribute onetwo {1,2,3,4,5}
10 @attribute onethree {1,2,3,4,5}
11 @attribute onefour {1,2,3,4,5}
12 @attribute twoone {1,2,3,4,5}
13 @attribute twotwo {1,2,3,4,5}
14 @attribute twothree {1,2,3,4,5}
15 @attribute twofour {1,2,3,4,5}
16 @attribute sharingothergender {1,2,3,4,5}
17
18 @data
19
20 3,33,F,casado,mestrado,sim,4,5,1,1,5,5,2,4,2,2,5,5,5,3,4,2,3,3,2,1,1
21 3,34,F,casado,mestrado,sim,4,5,1,1,5,5,2,4,2,2,5,5,5,3,4,2,3,3,2,1,1
22 3,38,F,solteiro,mestrado,sim,2,4,2,4,2,4,2,5,5,4,2,5,3,1,4,1,4,4,4,4,4
23 3,36,F,solteiro,mestrado,sim,2,4,2,4,2,4,2,5,5,4,2,5,3,1,4,1,4,4,4,4,4
24 3,31,F,casado,tecnico,nao,3,4,2,1,4,5,1,5,1,3,3,4,3,5,3,1,2,3,3,1,1
25 3,33,F,casado,tecnico,nao,3,4,2,1,4,5,1,5,1,3,3,4,3,5,3,1,2,3,3,1,1
26 3,33,F,casado,tecnico,nao,5,5,5,1,4,5,1,5,2,3,5,4,1,4,3,1,2,3,2,1,1
27 3,37,F,casado,superior,sim,5,5,1,1,4,5,1,5,2,3,5,4,4,3,3,1,2,3,2,1,1
28 3,34,F,casado,superior,sim,5,5,1,1,4,5,4,1,1,3,5,4,3,4,3,4,2,3,2,1,1
29 3,39,F,casado,superior,sim,5,5,2,3,4,5,4,1,1,3,4,5,2,4,3,4,2,3,2,1,2
30 3,36,F,casado,superior,sim,5,5,2,3,4,5,4,1,1,3,4,5,2,4,3,4,2,3,2,1,2
31 3,36,F,solteiro,superior,sim,2,4,1,5,2,3,5,1,1,4,2,5,4,4,3,5,4,4,4,3,5
32 3,30,F,solteiro,superior,sim,3,4,2,5,1,4,5,1,1,5,3,5,3,4,3,4,5,4,3,4,5
33 3,34,F,solteiro,superior,sim,2,3,5,5,4,2,3,2,1,5,2,5,2,4,4,3,3,4,4,5,5
34 3,40,F,separado,tecnico,nao,3,4,5,3,4,2,3,2,2,5,3,5,1,3,4,3,3,5,3,3,3
35 3,41,F,separado,superior,sim,3,4,5,5,2,3,3,2,5,5,3,5,2,2,4,3,4,5,3,4,4
36 3,45,F,divorciado,mestrado,sim,3,4,2,5,2,4,2,5,5,5,3,5,3,1,4,1,4,5,3,4,4
37 3,42,F,solteiro,doutorado,sim,2,3,5,3,2,4,2,5,5,4,1,5,1,1,4,2,4,4,4,3,3
38 3,43,F,casado,doutorado,sim,5,5,5,1,4,5,2,5,5,4,5,5,2,1,4,1,2,4,2,1,1
39 3,40,F,casado,doutorado,sim,5,5,5,1,4,5,2,5,5,3,5,5,2,1,4,1,2,3,2,1,1
40 3,41,F,casado,doutorado,sim,5,5,5,1,4,5,2,5,5,3,5,5,2,1,4,1,2,3,2,1,1

```

Fonte: Do próprio trabalho

A Figura 4.1 mostra os dados oriundos dos questionários, organizados para o *software* WEKA. As informações referentes à parte Q1 estão entre as linhas 3 e 7, já as linhas 8 a 15 apresentam os dados de Q3, por fim a linha 16 trata a questão a ser classificado pelo algoritmo, neste caso, a questão "Compartilhar com gêneros diferentes", referente ao item de Q2 a ser classificado. A partir da linha 20, são disponibilizados o conjunto de dados originados das respostas dos questionários.

Os testes iniciais foram realizados com diversos algoritmos de aprendizado de máquina, todos eles por meio do *software* WEKA, descrito na Subseção 4.2.1. Foram utilizados os seguintes algoritmos: Naive Bayes, Algoritmo IBK, Redes Neurais, SVM, Random Forest e Árvore de Decisão (J48), além do Zero R. O algoritmo J48 é uma recodificação do algoritmo C4.5 escrito originalmente na linguagem C, para a linguagem JAVA que é utilizada pelo WEKA (BHARGAVA et al., 2013).

As configurações dos algoritmos de aprendizado de máquina foram mantidas, sendo testadas as disposições originais. Os algoritmos que apresentaram melhores resultados foram mantidos, podendo ser alterado algumas configurações para otimizar os resultados.

#### 4.2.1 Ferramenta WEKA

O *software* utilizado na primeira parte da Figura 3.1 ( $\gamma$ ), foi o WEKA (*Waikato Environment for Knowledge Analysis*), é uma ferramenta muito utilizada para aprendizado de máquina desenvolvido pela Universidade de Waikato, na Nova Zelândia.

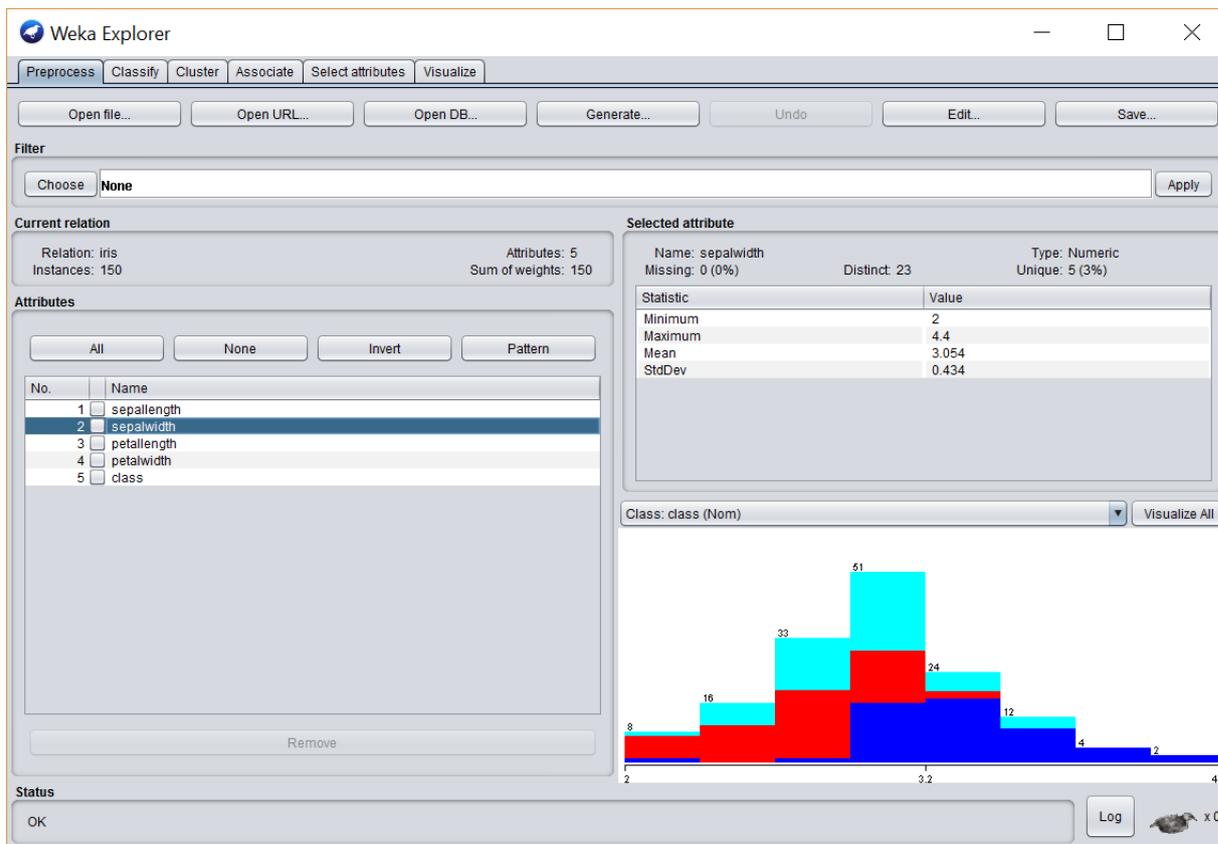
Escrito em Java, o WEKA contém um conjunto de algoritmos para análise de dados, mineração de dados e aprendizado de máquina, além de possuir boa interface gráfica que facilita sua funcionalidade (SINGHAL; JENA, 2013). O *software* é *open source* e está disponível gratuitamente. A Figura 4.2, ilustra sua interface do WEKA. A aplicação dos algoritmos selecionados é realizada por meio da aba "*Classify*", onde também são apresentados os resultados.

#### 4.3 Implementação do sistema de recomendação

As redes sociais disponibilizam informações básicas dos perfis de usuários, segundo o item (1a) do fluxograma da metodologia. Essas podem ser extraídas por meio de uma aplicação baseada em uma ferramenta disponível pela própria rede social, no caso o *Facebook for Development*<sup>3</sup>. Após o desenvolvimento da aplicação, o usuário teve acesso pelo endereço

<sup>3</sup> <https://developers.facebook.com/docs/apps>

Figura 4.2 – Interface WEKA.



Fonte: WEKA (2018)

eletrônico (<http://143.107.111.41/opinion/facebook/rs/>), e realiza o *login* por meio da sua conta do Facebook, disponibilizando seus dados.

Com relação ao desenvolvimento do site eletrônico, foi utilizado a *HyperText Markup Language* (HTML), o CSS (*Cascading Style Sheets*) e o PHP (*Hypertext Preprocessor Language*). Neste estudo, extraiu-se as informações do perfil básico do usuário, como idade, sexo, nível educacional e estado civil. Além disso, uma conexão segura com um servidor da Web está disponível para os usuários (1b). Os usuários podem acessar o aplicativo da web e responder a perguntas referentes a parte Q3 do questionário, descritas na Subseção 4.3.2. Esta etapa do trabalho foi realizada em parceria com um aluno de graduação em Ciências da Computação, da UFLA, em seu projeto de iniciação científica.

#### 4.3.1 Módulo para extração de dados de redes sociais

A extração de dados dos usuários das redes sociais (item 1a da Fig. 3.1) foi realizada por meio da página da WEB descritas na Seção 4.3.

A Figura 4.3, demonstra a *interface* da página, nela contém as questões da parte Q3 do questionário, já as questões da parte Q1 não são solicitadas, pois são extraídas automaticamente após o usuário realizar o login.

Figura 4.3 – Tela inicial do RsRS sistema de recomendação.



**RSRS: RIDESHARING  
RECOMMENDATION SYSTEM**

RECOMMENDATIONS ACCORDING TO DATA  
EXTRACTED FROM FACEBOOK



Select a score 1, 3 or 5 according to the relevance that each item below represents to you:

① Choose an option according with the importance level of the following issues to you (1 = not very important - 5 = very important)

What's the relevance of your political option?	1
What's the relevance of your religion option?	1
What's the relevance of your sexual orientation in a social environment?	1
What's the relevance of your favorite sport option? (Favorite soccer team, basketball, athlete, etc.)	1
What's the relevance of your hobby option? ▶ details	1
What's the importance of pets to you? (cats and dogs)	1
What's the importance of socializing with new people?	1
What's the importance of socializing with people whom you could get to know better?	1

Login to know with who you would likely share a carpool service

[Login with Facebook](#)

[Read privacy statement.](#)

Fonte: Do próprio autor

O usuário pode optar por não responder as questões e realizar o login no site. Por meio desta operação, ele estará permitindo que o aplicativo extraia suas informações de perfil, como: data de nascimento, sexo, estado civil e escolaridade.

### 4.3.2 Módulo de interface com usuário

O módulo de interface com o usuário é ilustrado na Figura 4.3. As questões solicitadas são referentes à parte Q3 do questionário, as quais são descritas na Subseção 4.1.1. No fluxograma do modelo de recomendação proposto (Figura 3.1), ilustra esta parte no item 2b.

Após respondida as questões e realizado o login, o sistema de recomendação terá as entradas necessárias, itens Q1 e Q2, para aplicar no algoritmo de classificação selecionada (item 3 da Fig. 3.1). A metodologia para escolha deste algoritmo é descrita na subseção a seguir.

### 4.3.3 Algoritmos selecionados

O algoritmo de aprendizado de máquina utilizado no modelo, item (3), classificou o Usuário R de acordo com os aspectos tratados na parte Q2 do questionário (item 4 Fig. 3.1).

Os testes e seleção deste algoritmo foram feitos de acordo a Seção 4.2, o algoritmo que apresentou melhor resultado, de acordo com as médias das métricas para avaliação de desempenho (vide Subseção 4.4), foi implementado no modelo RsRS (item 5) desenvolvido em HTML (subseção 4.3). Diante disto, foram definidos os critérios para selecionar os outros usuários que irão compartilhar a corrida com o Usuário R, ressaltando que, qualquer usuário que utilize o modelo já terá sido classificado previamente pelo sistema de recomendação.

Por fim, outro algoritmo com uma função de similaridade, Subseção 4.3.4, irá selecionar os passageiros em potencial para a corrida.

### 4.3.4 Função de similaridade

O sistema de classificação baseado no aprendizado de máquina permitiu que o modelo de recomendação proposto definisse o perfil do usuário para o serviço de compartilhamento de viagens. Uma vez definido o perfil, o modelo RsRS recebe do prestador de serviços as informações referentes aos passageiros em potencial que estão solicitando o serviço com uma rota semelhante.

O perfil desses usuários é extraído da rede social e as informações são analisadas pelo mesmo algoritmo de aprendizado de máquina. Em seguida, é utilizada uma função de similaridade que gera uma classificação dos passageiros com os perfis mais semelhantes relacionados ao usuário que já está no carro. Dessa maneira, o modelo RsRS envia essa classificação para o provedor de serviços de compartilhamento de viagens para selecionar um ou mais passageiros.

A Tabela 4.1 apresenta o algoritmo da função de similaridade implementada no RsRS e mostra quais são os parâmetros, e os passos seguidos para determinar o ranking.

Tabela 4.1 – Algoritmo de determinação da função similaridade.

Linha	Statement
1	n <= número de potenciais passageiros fornecido pelo provedor de serviço
2	j <= índice para representar cada passageiro em potencial
3	m <= índice que representa a questão abordada em Q2
4	CPi <= preferência do atual passageiro a respeito de i
5	FPI <= preferência do futuro passageiro a respeito de i
6	Sj <= pontuação de similaridade para passageiros em potencial j
7	Svector <= vetor para armazenar Sj
8	for j = 0 to n - 1
9	{ Sj = abs( $\sum_{i=0}^m (CPi - FPI)$ )
10	Svector[j] = Sj
11	j = j + 1 }
12	Ranking = menor (S <sub>0</sub> , S <sub>2</sub> , ...S <sub>n-1</sub> )
13	// Ranking para envio so provedor de serviço

Fonte: Do próprio trabalho

#### 4.4 Métricas para avaliação de desempenho

Os resultados foram analisados com base nos valores do percentual de acerto que o algoritmo obteve, denominado *Corret Class*, além de *F-Mensure* e *Kappa Weight*. O *F-Mensure* é usado para medir o desempenho, onde seu cálculo é a medida harmônica entre os valores de Precisão (*Precision* - valor de predição positiva) e Cobertura (*Recall* - calculada pelo número total de casos aplicáveis), sendo seu valor obtido pelo produto da Precisão e Cobertura, multiplicado por dois, e dividido pela soma dos mesmos. Quanto mais próximo de 1,0 melhor o resultado.

O *Kappa Weight* é similar ao usual *Kappa Cohen*, este leva em consideração a análise da precisão da matriz de confusão por meio da contagem das classificações erradas, porém, ela não leva em consideração as "distâncias" do erro de classificação. O *Kappa Weight* atribui pesos aos valores classificados de forma errada na matriz de confusão, sendo assim, seu uso na tomada de decisão entrega valores mais confiáveis (BEN-DAVID, 2008), ou seja, para classificações erradas, quanto mais distante do valor correto, menor é o valor do *Kapaa Weight*.

## 5 RESULTADOS E DISCUSSÕES

A presente capítulo apresenta os resultados obtidos neste trabalho e discussões, com base na metodologia descrita, e por meios das seções: análise dos testes subjetivos, determinação de um modelo de classificação e avaliação do desempenho do modelo proposto.

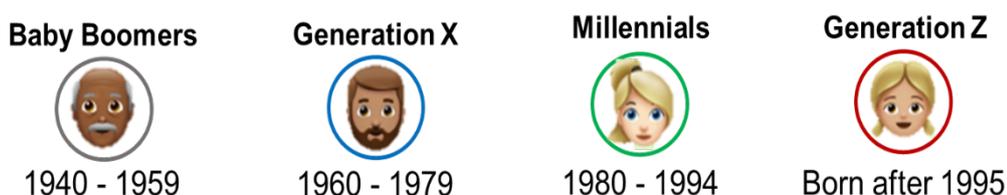
### 5.1 Análise dos testes subjetivos

A aplicação dos questionários proporcionou um conjunto de informações valiosas para o trabalho. Ao todo foram 296 participantes com idades entre 16 a 71 anos, todos residentes na região metropolitana de São Paulo.

Os resultados obtidos das aplicações dos questionários proporcionaram, não somente, a construção da base de dados para execução da metodologia proposta nesta dissertação, mas também, expandir as discussões abordando às gerações globais relacionando suas preferências com os novos modelos de mobilidade compartilhada. Estes resultados foram descritos em (LASMAR JR et al., 2018).

Os resultados demográficos dos respondentes, parte Q1 do questionário, são apresentadas conforme Lasmar Jr et al. (2018), os participantes foram divididos em gerações, descritos na Figura 5.1.

Figura 5.1 – Intervalo entre gerações.

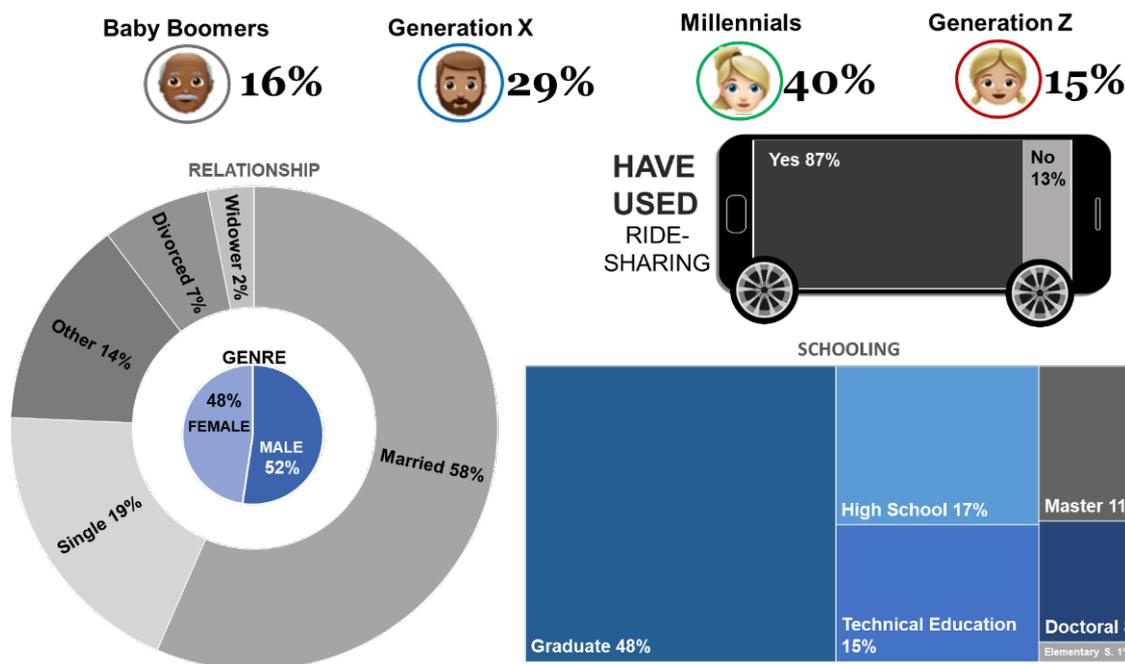


Fonte: Lasmar et. al (2018)

Os Baby Boomers representaram 16% dos respondentes, total de 47 participantes, a Geração X totalizaram 86 respondentes, com 29%, o maior percentual de participantes foram os Millennials 40%, com 119 respondentes e a Geração Z teve a participação de 44 pessoas, representando 15%, por ser a geração mais nova estes contaram apenas com uma faixa de 6 anos, de 16 a 22.

A Figura 5.2 apresenta os resultados demográficos, com relação ao gênero, se declararam homens 52% e 48% mulheres, ainda abordado na parte Q1, o tipo de relacionamento resultou em: Solteiros 19% (*Single*), casados 58% (*Married*), divorciados 7% (*Divorced*), viúvos

Figura 5.2 – Resultados do questionário - parte Q1.



Fonte: Lasmar et al. (2018)

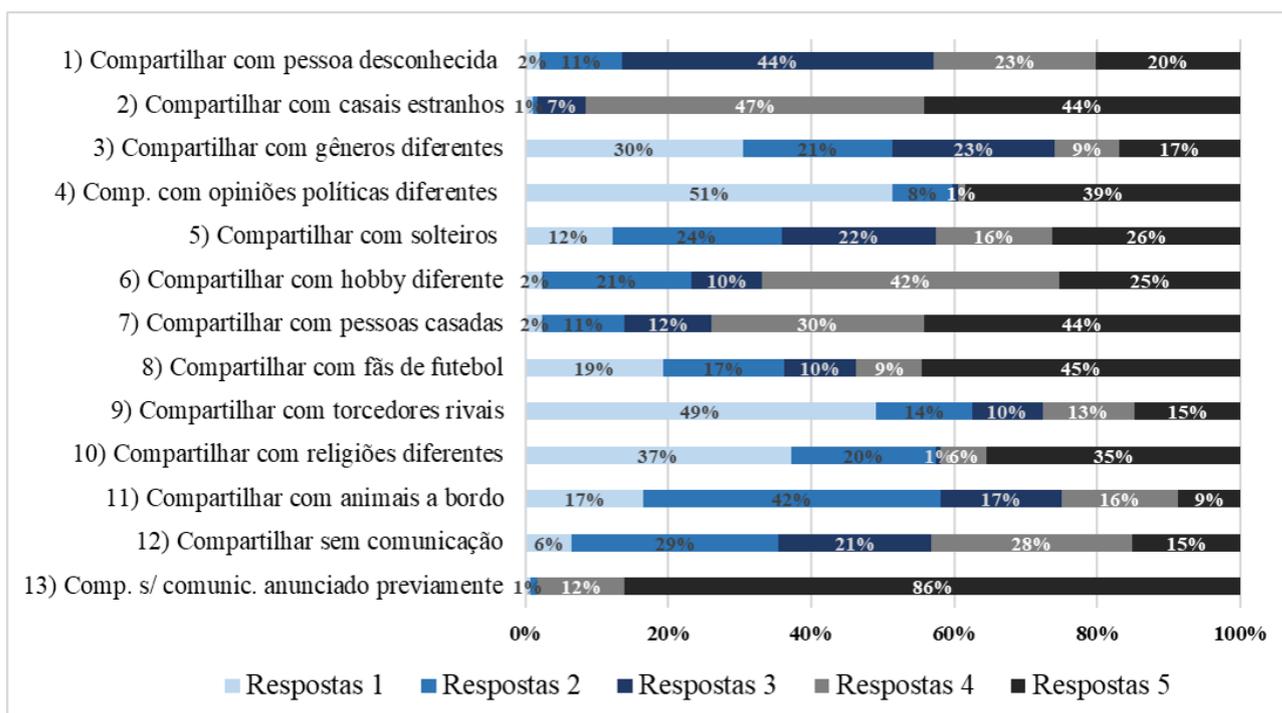
2% (*Widower*) e outro tipo de relacionamento 14% (*Other*). Com relação ao nível de escolaridade, o maior índice foram os 48% de respondentes graduados (*Graduate*), nível médio 17% (*High School*), participantes com nível técnico representaram 15% (*Technical Education*), mes-trando 11% (*Master*), doutorandos 8% (*Doctoral*) e ensino médio com apenas 1% (*Elementary School*), dos respondentes.

O percentual dos respondentes que manifestaram ter utilizado algum APP de *Ridesha-ring*, também é descrito na Figura 5.2, 87% responderam que sim, enquanto apenas 13% ainda não utilizaram em nenhum momento este tipo de transporte.

Os resultados apresentados na segunda parte do questionário estão expressos na Fi-gura 5.3, os dados são organizados de acordo com o percentual das respostas para cada uma das 13 questões abordadas da parte Q2.

Como exemplo, o item 3 relacionado a gênero, no questionário tinha a seguinte pergunta: "Eu compartilharia corrida/viagem com pessoas do gênero oposto ao meu?". Nesta questão, 30% dos respondentes optaram por 1 (muito baixa), ou seja, o compartilhamento de corrida ou viagem com pessoas de gênero oposto tinha muito pouca aceitabilidade, 21% responderam 2 (pouco), 21% foram indiferentes (resposta 3), a resposta 4 tiveram apenas 9% e 17% optaram pela resposta 5, muito alta aceitabilidade em compartilhar uma corrida.

Figura 5.3 – Resultados do questionário - parte Q2.



Fonte: Do próprio trabalho

As análises destes resultados proporcionaram, inicialmente, atender ao objetivo deste trabalho, conforme a descrita na metodologia na seção 4.1.1, estas divisões foram mantidas para definição do modelo proposto.

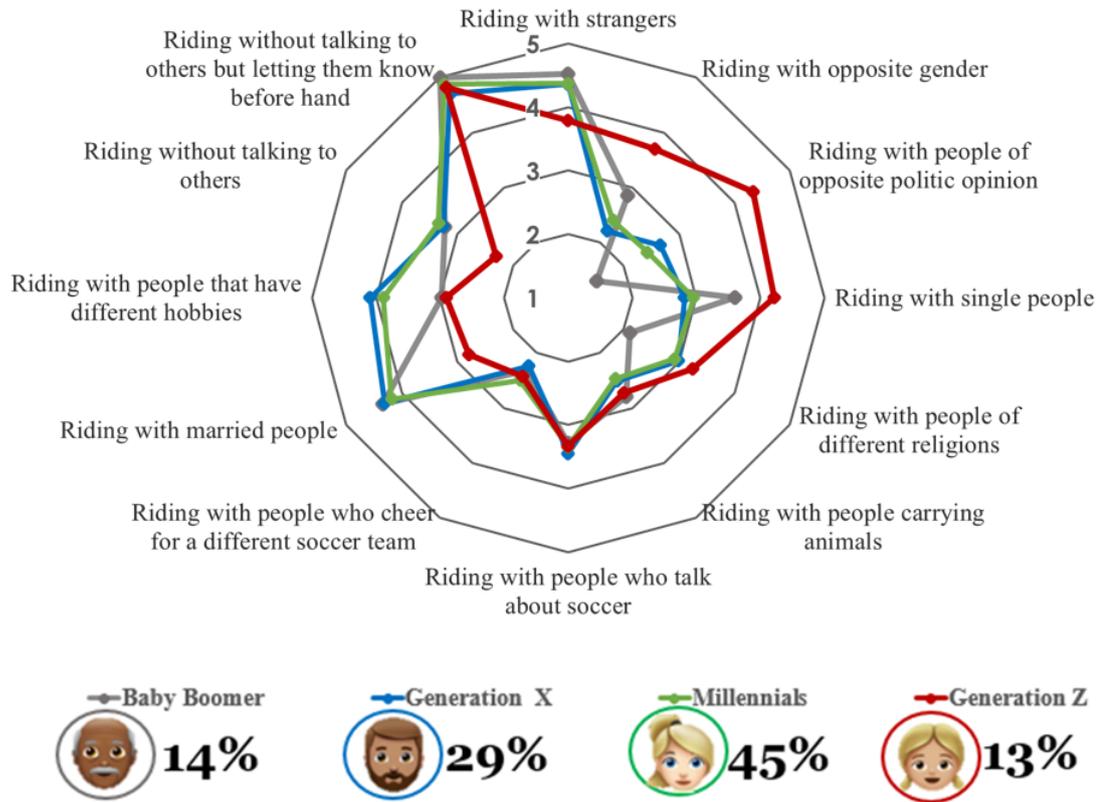
Porém, a análise com base nas gerações globais possibilitou outras contribuições. A Geração Z, por exemplo, apresenta maior aceitabilidade em aspectos como gênero, política e religião, além de ser mais amigável ao compartilhar com usuários solteiros, diferente das outras gerações.

A Figura 5.4 apresenta os comportamentos para os aspectos abordados na parte Q2. As divisões das gerações apresentam percentuais diferentes da Figura 5.2, pois não foram considerados os 13% dos respondentes que manifestaram não terem utilizado o modelo de transporte *Ridesharing* por APP. Também foi eliminada a questão relacionada ao compartilhamento de pessoas desconhecidas, por não contribuir com a proposta do trabalho em questão.

Por fim, os resultados da terceira parte do questionário (Q3), demonstrados a distribuição das respostas quanto a relevância e importância dos tópicos abordados, a apresentação é de forma similar aos resultados de Q2.

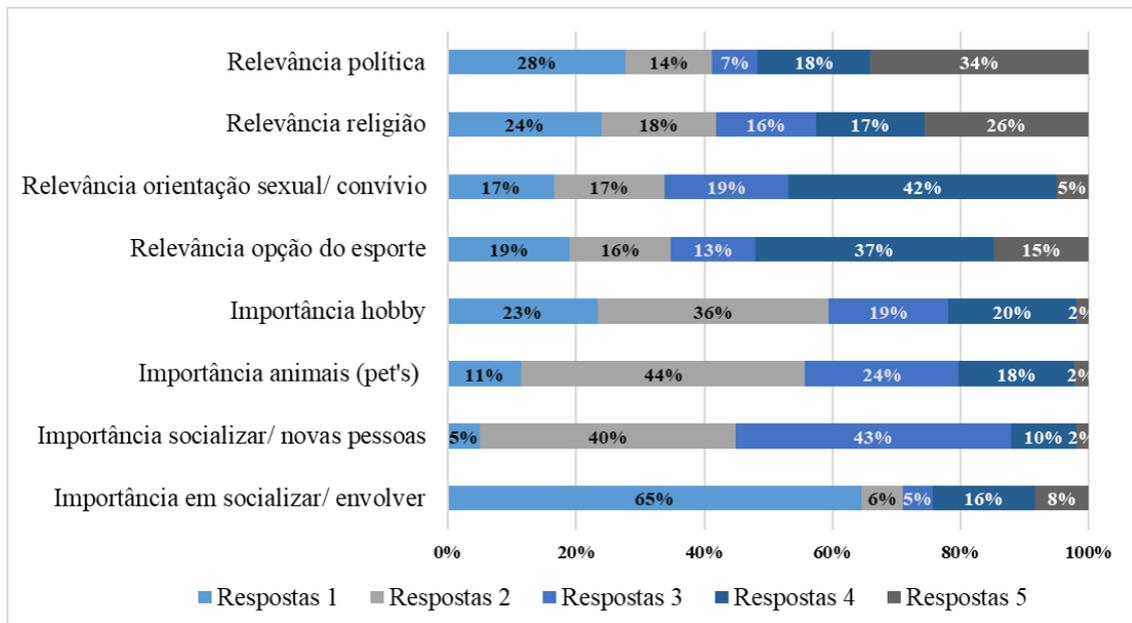
Os assuntos relacionados a política, religião, gênero e esportes apresentam uma distribuição mais equilibrada, considerando o agrupamento de "irrelevante" (respostas 1 + 2), e

Figura 5.4 – Comportamento das gerações na mobilidade compartilhada.



Fonte: Lasmar et al. (2018)

Figura 5.5 – Resultados do questionário - parte Q3.



Fonte: Do próprio trabalho

"relevante"(respostas 4 + 5), nenhum deles obtiveram mais de 52% das respostas. Ao contrário de casos extremos como os 65% apresentados na última questão de Q3.

## 5.2 Determinação de um modelo de classificação

Os resultados dos testes subjetivos proporcionaram uma base de dados possibilitando determinar um modelo capaz de classificar os usuários conforme as características abordadas.

Com os dados organizados na estrutura descrita na Seção 4.2, foi possível aplicar os algoritmos de classificação disponíveis no WEKA. Foram utilizados o conjunto de dados dos 258 respondentes, ressaltando que os 38 respondentes não considerados são referentes aos 13% dos que declararam não utilizar o sistema de transporte por aplicativo.

Os testes iniciais foram realizados com *Cross Validation* configurados em 10 *Folds*, o primeiro algoritmo utilizado foi o Zero R (zero regras), ele prediz a classe majoritária dos dados treinados, sua aplicação possibilita ter como referência um valor mínimo de percentual de acerto. Em seguida, foram aplicados os seguintes algoritmos em suas configurações originais: Naive Bayes, Algoritmo IBK, Redes Neurais, SVM, Árvore de Decisão (J48) e Random Forest.

As métricas utilizadas para análise dos resultados, descritas na Seção 4.4, foram os valores do percentual de acerto, denominado *Correct Class*, *F-Measure* e *Kappa Weight*. O *F-Measure* quanto mais próximo de 1,0 melhor o resultado, métrica também aplicada ao *Kappa Weight*.

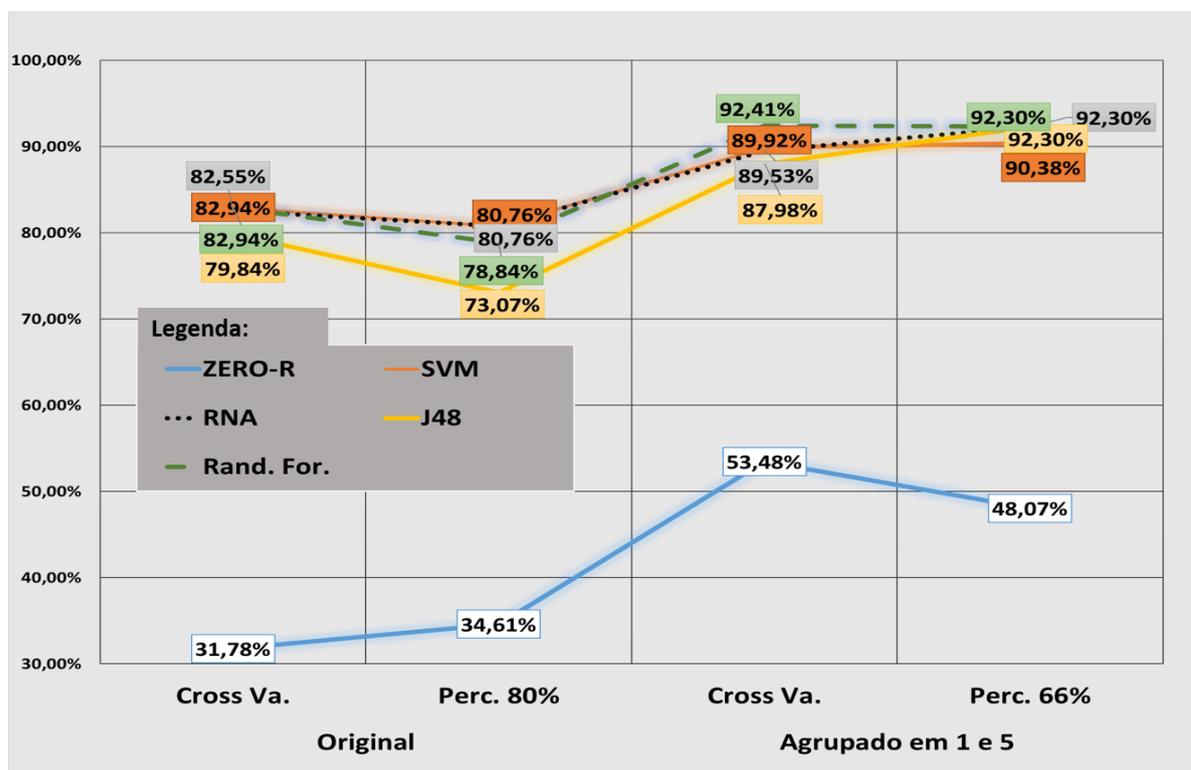
Dentre os algoritmos testados, os que obtiveram melhores resultados foram as Redes Neurais, SVM, Árvore de Decisão (J48) e Random Forest, sendo então, aplicados nas 13 questões de Q2, além de ser utilizado a opção de teste "*Percentage Split*", configurado em 80%, basicamente treina o algoritmo com 80% da amostra e testa com o restante.

A Figura 5.6 apresenta os resultados obtidos para classificação do item relacionado ao gênero (questão 3 de Q2), os dados são apresentados utilizando os valores de *Correct Class* para os algoritmos Zero R, SVM, Redes Neurais (RNA), Árvore de Decisão (J48) e Random Forest, tanto nas opções de *Cross Validation* (Cross Va.) e *Percentage Split* (Perc. 80%). Os dados também são apresentados com a estrutura original e agrupados em 1 e 5.

Os valores da estrutura original correspondem os dados sem alteração, apresentados na Figura 4.1. Após a primeira análise de resultados outra estrutura foi desenvolvida, a estrutura agrupada, que corresponde a redução de opções da quantidade de classificadores, passando de cinco para três. As respostas com valor igual a 2 foram agrupadas em 1, e o mesmo foi feito com respostas de valor 4 para 5. Desta forma, observa-se um melhor desempenho nos resultados dos algoritmos agrupados em 1 e 5.

Durante os testes com o algoritmo de Redes Neurais, diferentes topologias de rede foram testadas, e os melhores resultados foram obtidos considerando 500 épocas de treinamento, uma taxa de aprendizado de 0,3, um momento de 0,2 e uma camada oculta. Outras configurações de algoritmos são mantidas na topologia padrão.

Figura 5.6 – Desempenho dos algoritmos para questão gênero - Correct Class.



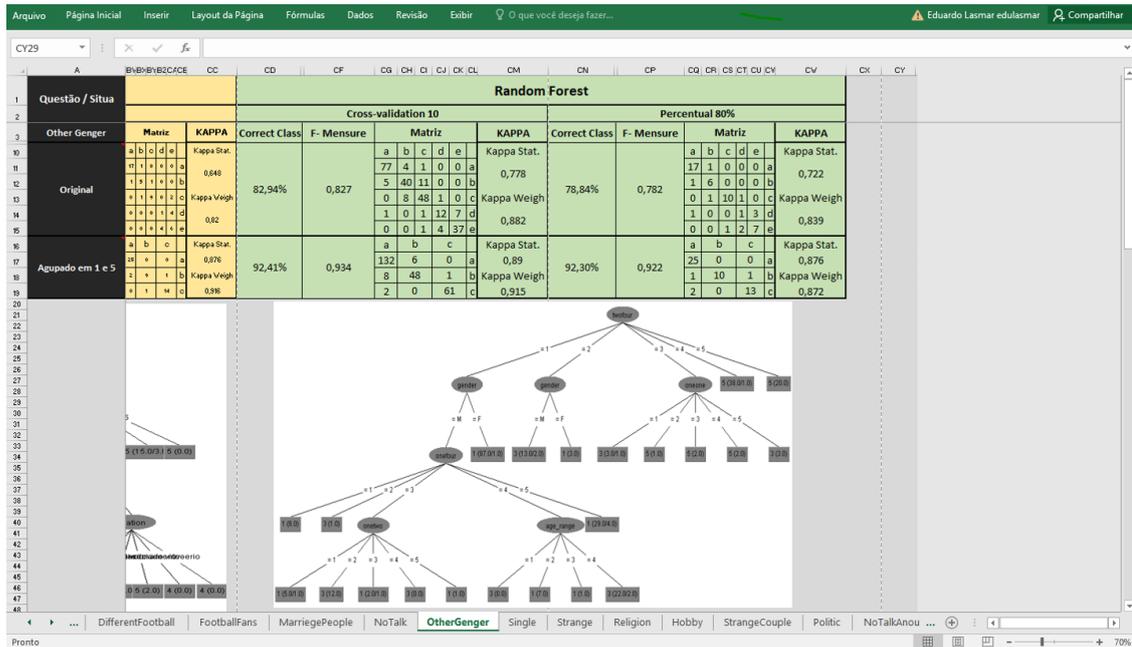
Fonte: Do próprio trabalho

A escolha do algoritmo para definir o melhor resultado foi realizada após análise de cada uma das 13 questões de Q2 propostos no questionário. Dessa forma, os resultados de todos os itens de Q2 foram organizados em uma planilha.

A Figura 5.7 apresenta uma parte da planilha referente ao algoritmo Random Forest aplicado a questão gênero. Além dos valores de *Correct Class*, é possível visualizar valores de *F-Measure*, a Matriz de Confusão, os valores de *Kappa* e a lógica utilizada para definição (árvore de decisão na parte branca). A ilustração tem por objetivo apresentar de forma resumida parte dos resultados obtidos.

A média dos resultados de *Correct Class*, *F-Measure* e *Kappa Weight* foram calculadas, tanto as estruturas original e agrupado em 1 e 5, descritas na Tabela 5.1. O algoritmo que apresentou melhor resultado foi o Random Forest na estrutura agrupado em 1 e 5, com resul-

Figura 5.7 – Resultados agrupados em planilhas.



Fonte: Do próprio trabalho

tados de 92,94% de *Correct Class*, valor de *Kappa Weight* de 0,877 e *F-Mensuare* de 0,928. Diante destes resultados ele foi selecionado para se aplicar ao modelo de classificação.

Tabela 5.1 – Média dos resultados.

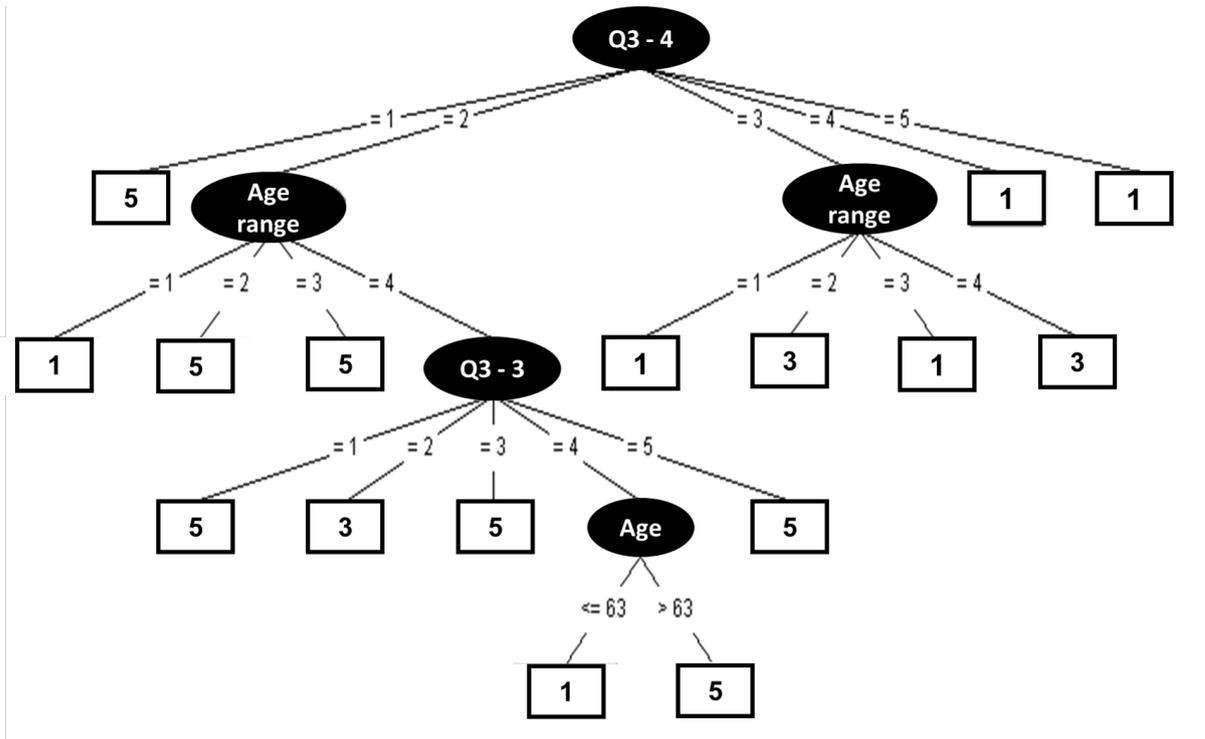
Algoritmo	Correct Class	F-Meansure	Kappa Weight	Estrutura
SVM	82,29%	0,820	0,794	Original
	92,20%	0,911	0,842	Agrupado
RNA	83,12%	0,829	0,800	Original
	90,99%	0,909	0,835	Agrupado
Árvore de Decisão (J48)	84,14%	0,829	0,787	Original
	91,80%	0,915	0,867	Agrupado
Random Forest	83,54%	0,829	0,802	Original
	92,94%	0,928	0,877	Agrupado

Fonte: Do próprio trabalho

Para exemplificar uma das lógicas do resultado, a Figura 5.8 demonstra a lógica de um dos itens classificados, no caso a questão 9 de Q2, compartilhar uma corrida com pessoas que torcem para times opostos.

A árvore de decisão utiliza ambos os dados de entrada Q1 e Q3, representados pelas elipses escuras, ou seja, os atributos, podem ser classificadas em 1, 3 e 5, que por sua vez estão representados pelos quadrados de fundo branco e correspondem as saídas. Os valores que

Figura 5.8 – Representação da árvore de decisão do item "Time de futebol diferente".



Fonte: Do próprio trabalho

estão nas linhas de ligação entre a elipse e o quadrado correspondem as respostas possíveis ou agrupamentos (ao exemplo AGE que utiliza  $\leq 63$  e  $> 63$ ).

A lógica resultante desta classificação utiliza a quarta questão de Q3 (Qual a relevância do esporte?), na elipse superior (Q3-4), para respostas de valor que correspondem a =1 é classificado como 5, quadrado branco e corresponde a muito alta aceitabilidade de compartilhar uma corrida, já as respostas =4 e =5 são classificadas como 1 (muito baixa aceitabilidade de compartilhar uma corrida).

Para as respostas =2 e =3, é utilizado outro atributo, o *Age range*, tendo como saídas possíveis do lado direito o grupo =1 e =3 classificado como 1 e os grupos =2 e =4 classificado como 3. Já o lado esquerdo, o que diferencia é para a faixa de idade =4, que usa o atributo da questão 3 de Q3 (Qual a relevância da orientação sexual em um convívio social), ainda faz-se o uso das idades maiores e menos de 63 anos para finalizar a classificação.

Esta lógica resultou em um valor de classificação correta de 94,2%, o *F-Measure* de 0,941 e o *Kappa Weigh* de 0,901.

Para cada uma das 13 questões tratadas em Q2, resultou-se em um fluxograma de decisão lógico, como o descrito na Figura 5.8, utilizando diferentes atributos originados das questões de

Q1 e Q3. A Tabela 5.2 apresenta quais atributos cada tema de Q2 utilizou para a classificação. As questões de Q3 podem ser visualizadas no Apêndice A, ou na Subseção 4.1.1.

Tabela 5.2 – Distribuição dos atributos.

<b>Tema</b>	<b>Atributos Utilizados</b>					
<b>Solteiro</b>	Idade	Q3-4	Gênero	Q3-2	Q3-8 Estado Civil	Q3-5
<b>Gênero</b>	Idade	Q3-4	Gênero	Q3-2	Q3-1	Q3-8
<b>Sem Conversa</b>	Idade	Q3-4	Gênero			Q3-7
<b>Diferente Time Futebol</b>	Idade	Q3-4			Q3-3	
<b>Fã futebol</b>	Idade		Gênero		Q3-6	
<b>Hooby</b>	Idade			Q3-2	Q3-3	
<b>Animais</b>	Idade				Q3-6	
<b>Com Estranhos</b>	Idade					Q3-7
<b>Pessoas Casadas</b>						
<b>Religião</b>				Q3-2		
<b>Política</b>					Q3-1	
<b>Sem Conversa Anunciado</b>						Desbalanceado
<b>Casais Estranhos</b>						Desbalanceado

Fonte: Do próprio trabalho

Os temas estão dispostos de acordo com a quantidade de atributos utilizados, de maneira decrescente, sendo que o tema "Compartilhar uma corrida com pessoas solteiras", segunda coluna da Tabela 5.2, foi o que mais utilizou os atributos para classificação. O atributo idade foi o mais utilizado, já os atributos relacionados a Q3, as questões que abordam a relevância do esporte e da religião foram os mais utilizados, quatro vezes cada.

As classificações dos dois últimos temas da Tabela 5.2 ficaram desbalanceadas, ou seja, mais de 95% dos resultados das amostras agrupadas, estavam somente em uma das respostas.

Mediante ao exposto, o modelo proposto foi determinado com classificações relevantes, podendo ter resultados médios de acurácia de 93%. O módulo de interface descrito na Subseção 4.3.2, processa os dados de Q1 e Q2 obtido dos usuários e os classifica com base nos resultados dos classificadores aqui descritos. Por fim, aplica a função de similaridade que determinará quais usuários podem compartilhar uma corrida, baseado nos critérios estabelecidos.

A seção que segue descreve a avaliação do desempenho deste modelo e sua validação.

### **5.3 Avaliação do desempenho do modelo de recomendação proposto**

A validação de desempenho do modelo RsRS é realizada usando os dados do usuário extraídos da aplicação do Facebook, disponível em (<http://143.107.111.41/opinion/facebook/rs/>), e descritos na Seção 4.3.

Assim, 52 voluntários adicionais e que podem ser considerados como potenciais passageiros, foram cadastrados no sistema por meio do acesso ao link descrito via *smartphone*, sendo eles os respondentes dos testes de validação. Além disso, todos eles autorizaram a usar informações da rede social por meio do login.

A validação de desempenho do algoritmo selecionado foi testada com as respostas dos voluntários, representando aproximadamente 20% dos voluntários iniciais (256 respondentes) e que participaram da fase de treinamento. No total, 676 respostas foram avaliadas, das quais 616 respostas foram corretamente classificadas, considerando como satisfatória pelos novos respondentes, o que representa uma precisão de classificação de 91,12%.

A Figura 5.9 apresenta um exemplo do resultado do algoritmo de função de similaridade. Neste caso, a classificação de mais três perfis semelhantes é enviada para o dispositivo móvel do usuário. Cada um dos 52 voluntários avaliou este ranking de possíveis passageiros de uma corrida, e 49 deles consideraram satisfatório o resultado. Os usuários recomendados foram determinados considerando as diferentes pontuações calculados pela função de similaridade.

Figura 5.9 – Mensagem de recomendação contendo os resultados do algoritmo de classificação da função similaridade.



Fonte: Do próprio trabalho

Este resultado demonstra a utilidade e desempenho confiável do modelo RsRS proposto, principalmente do algoritmo de função de similaridade, podendo atender às definições de perfis de serviços da QoE, customizando o serviço e possibilitando uma melhor experiência do usuário de acordo com os valores pré-definidos. Assim como, os habilitadores de contexto, tratando de uma solução em tempo real para o serviço de mobilidade compartilhada.

## 6 CONCLUSÃO

Este trabalho teve por finalidade o desenvolvimento de um modelo de recomendação para aprimorar a QoE em serviços de mobilidade compartilhada.

Para tal, foi proposto a realização de testes subjetivos para identificar as influências dos principais parâmetros que determinassem a QoE no compartilhamento de mobilidade. Conforme proposto no objetivo específico 1, revelou que os usuários preferem compartilhar corridas e/ou viagens com pessoas que têm preferências semelhantes. Os testes levaram em consideração diferentes aspectos, como informações básicas do usuário (Q1) e temas sociais comumente abordados nas redes sociais (Q3). Estes aspectos podem ser considerados como parâmetros determinantes para a QoE em serviços de mobilidade compartilhada, de acordo com os perfis de serviços definidos por Abramowicz et al. (2006).

Os resultados dos questionários possibilitaram propor um sistema de classificação de usuário com uso de aprendizado de máquina, de acordo com o objetivo específico 2, os algoritmos utilizado neste trabalho demonstraram, que com os dados obtidos nos questionários, é possível obter resultados confiáveis de classificação, permitindo determinar o perfil do usuário para o serviço de compartilhamento, além de determinar quais características são mais importantes durante o compartilhamento, de acordo com o usuário. O algoritmo *Random Forest* foi o selecionado para classificação por apresentar o melhor desempenho, atingindo valores médios de *Correct Class* de 92,9%, *F-Measure* de 0,92 e *Kappa Weight* de 0,87.

A partir da definição do algoritmo, facultou-se o resultado do objetivo específico 3: o desenvolvimento e validação do modelo de recomendação com capacidade de ranquear os possíveis passageiros. O modelo de recomendação proposto alcançou o objetivo de classificar os usuários, com base nos dados obtidos das redes sociais e das questões abordadas na interface Web, entregando níveis de acerto acima de 90%. Também atingiu-se objetivamente o sequenciamento de possíveis passageiros, por meio da função de similaridade, o que possibilitou o modelo recomendar usuários para aprimorar a QoE, atendendo as definições de habilitadores de contexto de acordo com Richter e Bohm (2006). Com relação a validação, testes com voluntários atingiram índices de classificação de 91,12%.

No que tange as contribuições, pelo ponto de vista teórico, este trabalho aborda aspectos de sistemas da qualidade nos serviços de mobilidade compartilhada. Desta forma, considerando a transição da posse do veículo para um serviço, existe uma carência de trabalhos na literatura

que tratam da qualidade para os serviços de mobilidade do transporte privado, amplia-se, assim, o tema com a contribuição da QoE para estes serviços.

Constatou-se que existem diferentes opiniões quanto as características de passageiros no compartilhamento de corridas e/ou viagens, sendo que, a relação destas características está fortemente relacionada atributos pessoais e preferências, conforme mostra a Tabela 5.2. Este trabalho pode, portanto, contribuir para o aprimoramento da qualidade dos serviços de mobilidade compartilhada.

Como limitação do presente estudo, salienta-se a região onde os questionários foram aplicados, fundamental para a definição do modelo de classificação de usuário. Ambientes diferentes podem apresentar outros índices de classificação inviabilizando o modelo de recomendação, influenciando assim, na QoE. Cabe enfatizar, que o modelo proposto foi simulado, não sendo aplicados em situações reais de prestação de serviço.

Futuras pesquisas podem utilizar métodos aqui desenvolvidos bem como analisar a aplicação do modelo de recomendação em ambientes ou eventos específicos, podendo também, aplicar o modelo entre motoristas parceiros e usuários. Além disso, considerando os algoritmos utilizados, pode-se aprimorar os resultados com algoritmos mais robustos e desenvolvidos para o modelo.

## REFERÊNCIAS

- ABER, S.; AMANI-GHADIM, A.; MIRZAJANI, V. Removal of cr (vi) from polluted solutions by electrocoagulation: modeling of experimental results using artificial neural network. **Journal of hazardous materials**, Elsevier, v. 171, n. 1-3, p. 484–490, 2009.
- ABER, S.; AMANI-GHADIM, A.; MIRZAJANI, V. Removal of cr (vi) from polluted solutions by electrocoagulation: Modeling of experimental results using artificial neural network. **Journal of hazardous materials**, Elsevier, v. 171, n. 1-3, p. 484–490, 2009.
- ABRAMOWICZ, W. et al. Architecture for service profiling. In: IEEE. **Services Computing Workshops, 2006. SCW'06. IEEE**. [S.l.], 2006. p. 121–130.
- ADOMAVICIUS, G.; TUZHILIN, A. Toward the next generation of recommender systems: A survey of the state-of-the-art and possible extensions. **IEEE transactions on knowledge and data engineering**, IEEE, v. 17, n. 6, p. 734–749, 2005.
- ALGHOWINEM, S. et al. Multimodal depression detection: fusion analysis of paralinguistic, head pose and eye gaze behaviors. **IEEE Transactions on Affective Computing**, IEEE, 2016.
- BEN-DAVID, A. Comparison of classification accuracy using cohen's weighted kappa. **Expert Systems with Applications**, Elsevier, v. 34, n. 2, p. 825–832, 2008.
- BERT, J. et al. What's ahead for car sharing?: The new mobility and its impact on vehicle sales. In: **Automoted Vehicles Symposium**. [S.l.: s.n.], 2016.
- BHARGAVA, N. et al. Decision tree analysis on j48 algorithm for data mining. **Proceedings of International Journal of Advanced Research in Computer Science and Software Engineering**, v. 3, n. 6, 2013.
- BIJOR, R. et al. **Social media integration for transport arrangement service**. [S.l.]: Google Patents, 2017. US Patent App. 15/221,933.
- BISHOP, C.; BISHOP, C. M. **Neural networks for pattern recognition**. [S.l.]: Oxford university press, 1995.
- BISHOP, C. M. **PATTERN RECOGNITION AND MACHINE LEARNING**. [S.l.]: Springer-Verlag New York, 2016.
- BOTSMAN, R.; ROGERS, R. **What's mine is yours: how collaborative consumption is changing the way we live**. [S.l.]: Collins London, 2011.
- BOYD, D. Why youth (heart) social network sites: The role of networked publics in teenage social life. **MacArthur foundation series on digital learning—Youth, identity, and digital media volume**, MIT press Cambridge, MA, p. 119–142, 2007.
- BRASIL, U. **Lei nº 12.587, de 3 de janeiro de 2012, que institui as diretrizes da Política nacional de mobilidade Urbana**. [S.l.], 2012. v. 4.
- BREIMAN, L. Random forests. **Machine learning**, Springer, v. 45, n. 1, p. 5–32, 2001.
- BURKE, R. Hybrid recommender systems: Survey and experiments. **User modeling and user-adapted interaction**, Springer, v. 12, n. 4, p. 331–370, 2002.

- CARUANA, A. Service loyalty: The effects of service quality and the mediating role of customer satisfaction. **European journal of marketing**, MCB UP Ltd, v. 36, n. 7/8, p. 811–828, 2002.
- CHAGAS, A. O questionário na pesquisa científica. administração online. **São Paulo**, v. 1, n. 1, 2000.
- CHAN, N. D.; SHAHEEN, S. A. Ridesharing in north america: Past, present, and future. **Transport Reviews**, Taylor & Francis, v. 32, n. 1, p. 93–112, 2012.
- CLEWLOW, R.; MISHRA, G. S.; CENTER, P. E. E. Shared mobility: Current adoption, use, and potential impacts on travel behavior. In: **Annual Meetings of the Transportation Research Board, Washington DC**. [S.l.: s.n.], 2017.
- COHEN, B.; KIETZMANN, J. Ride on! mobility business models for the sharing economy. **Organization & Environment**, SAGE Publications Sage CA: Los Angeles, CA, v. 27, n. 3, p. 279–296, 2014.
- COSTA, F. G. I. d. **Metodologia para avaliação da qualidade de experiência-QoE-de serviços em nuvem**. Dissertação (Mestrado), 2015.
- DAI, P. et al. Quality-of-experience-oriented autonomous intersection control in vehicular networks. **IEEE Transactions on Intelligent Transportation Systems**, IEEE, v. 17, n. 7, p. 1956–1967, 2016.
- DONG, M. et al. Quality-of-experience (qoe) in emerging mobile social networks. **IEICE TRANSACTIONS on Information and Systems**, The Institute of Electronics, Information and Communication Engineers, v. 97, n. 10, p. 2606–2612, 2014.
- ENOCH, M. P. How a rapid modal convergence into a universal automated taxi service could be the future for local passenger transport. **Technology Analysis & Strategic Management**, Taylor & Francis, v. 27, n. 8, p. 910–924, 2015.
- FOTROUSI, F.; FRICKER, S. A.; FIEDLER, M. The effect of requests for user feedback on quality of experience. **Software Quality Journal**, Springer, p. 1–31, 2017.
- FRANCO, M. S. C. M. Big data e open data vs. privacidade: Constituiria a ferramenta tecnológica em uma invasão à privacidade? **Revista de Estudos Jurídicos UNESP**, v. 20, n. 32, 2018.
- FRANKLIN, J. The elements of statistical learning: data mining, inference and prediction. **The Mathematical Intelligencer**, Springer, v. 27, n. 2, p. 83–85, 2005.
- FULTON, L.; MASON, J.; MEROUX, D. **Three revolutions in urban transportation: How to achieve the full potential of vehicle electrification, automation, and shared mobility in urban transportation systems around the world by 2050**. [S.l.], 2017.
- FURUHATA, M. et al. Ridesharing: The state-of-the-art and future directions. **Transportation Research Part B: Methodological**, Elsevier, v. 57, p. 28–46, 2013.
- GOLDRATT, E. M.; FOX, R. E. A corrida pela vantagem competitiva. **São Paulo: C. Fulmann**, 1992.

- GREENBLATT, J. B.; SHAHEEN, S. Automated vehicles, on-demand mobility, and environmental impacts. **Current sustainable/renewable energy reports**, Springer, v. 2, n. 3, p. 74–81, 2015.
- GROUP, A. I. A. **History Highlights**. 2010. <https://www.aiag.org/docs/default-source/default-document-library/historyhighlights.pdf?sfvrsn=0n>. Disponível em: <<https://www.aiag.org/docs/default-source/default-document-library/historyhighlights.pdf?sfvrsn=0n>>.
- HAM, J. et al. Investigation of the random forest framework for classification of hyperspectral data. **IEEE Transactions on Geoscience and Remote Sensing**, IEEE, v. 43, n. 3, p. 492–501, 2005.
- HARO, D. G. **Sistemas da qualidade na indústria automobilística: uma proposta de auto-avaliação unificada**. Dissertação (Mestrado), 2001.
- HINO, M. C. et al. The role of information and communication technology in the transformation of consolidated business model: A study of taxi cooperatives in brazil. In: **CONF-IRM**. [S.l.: s.n.], 2015. p. 22.
- ICKIN, S.; WAC, K.; FIEDLER, M. Qoe-based energy reduction by controlling the 3g cellular data traffic on the smartphone. In: IEEE. **Energy Efficient and Green Networking (SSEEGN), 2013 22nd ITC Specialist Seminar on**. [S.l.], 2013. p. 13–18.
- ICKIN, S. et al. Factors influencing quality of experience of commonly used mobile applications. **IEEE Communications Magazine**, IEEE, v. 50, n. 4, 2012.
- ISO. **ISO 9000: Quality Management Systems–Fundamentals and Vocabulary**. [S.l.]: International Organization for Standardization Geneva, 2005.
- ISO. **ISO, International Organization for Standarization**. 2015.
- ISO9241-210. **ISO 9241-210:2010 - Human-centred design processes for interactive systems**. 2010. Disponível em: <<https://www.iso.org/standard/52075.html>>.
- JÚNIOR, E. L. L. et al. New business model and the sharing economy: Impacts and challenges for the traditional automotive industry. **Int. J. Automotive Technology and Management**, v. 18, n. 3, p. 187, 2018.
- JURAN, J. M. **Juran on leadership for quality**. [S.l.]: Simon and Schuster, 2003.
- KOFFMAN, D. Transportation network companies and paratransit: Issues and opportunities. In: **Paratransit: Shaping the Flexible Transport Future**. [S.l.]: Emerald Group Publishing Limited, 2016. p. 377–390.
- LAGHARI, A. A. et al. Qon: Quality of experience (qoe) framework for network services. In: **Proceedings of the 4th International Conference on Software Technology and Engineering (ICSTE'12)**. [S.l.: s.n.], 2012.
- LANGLEY, P. **Elements of machine learning**. [S.l.]: Morgan Kaufmann, 1996.
- LASMAR JR, E. L. et al. Shared-used mobility: global generations and service perception. In: **Gerpisa colloquium**. São Paulo: [s.n.], 2018.

- LENZ, B.; FRAEDRICH, E. New mobility concepts and autonomous driving: The potential for change. In: \_\_\_\_\_. **Autonomous Driving: Technical, Legal and Social Aspects**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2016. p. 173–191. ISBN 978-3-662-48847-8. Disponível em: <[http://dx.doi.org/10.1007/978-3-662-48847-8\\_9](http://dx.doi.org/10.1007/978-3-662-48847-8_9)>.
- LIRA, V. M. de et al. Comewithme: An activity-oriented carpooling approach. In: IEEE. **Intelligent Transportation Systems (ITSC), 2015 IEEE 18th International Conference on**. [S.l.], 2015. p. 2574–2579.
- LU, J. et al. Recommender system application developments: a survey. **Decision Support Systems**, Elsevier, v. 74, p. 12–32, 2015.
- MALLUS, M. et al. A persuasive real-time carpooling service in a smart city: A case-study to measure the advantages in urban area. In: IEEE. **Innovations in Clouds, Internet and Networks (ICIN), 2017 20th Conference on**. [S.l.], 2017. p. 300–307.
- MCKERRACHER et al. An integrated perspective on the future of mobility. **New York, NY: McKinsey & Company, Inc. and Bloomberg New Energy Finance. Online at [www.bbhub.io/bnef/sites/4/2016/10/BNEF\\_McKinsey\\_The-Futureof-Mobility\\_11-10-16.pdf](http://www.bbhub.io/bnef/sites/4/2016/10/BNEF_McKinsey_The-Futureof-Mobility_11-10-16.pdf)**, 2016.
- MILLARD-BALL, A. **Car-Sharing: Where and how it succeeds**. [S.l.]: Transportation Research Board, 2005. v. 108.
- MISZTAL, A. Technical determinants of success the quality management systems implementation in automotive industry. **Int. Sch. Sci. Res. Innov**, v. 9, n. 8, p. 1928–1933, 2015.
- MOHRI, M.; ROSTAMIZADEH, A.; TALWALKAR, A. **Foundations of machine learning**. [S.l.]: MIT press, 2012.
- MÖLLER, S.; RAAKE, A. **Quality of experience: advanced concepts, applications and methods**. [S.l.]: Springer, 2014.
- PARASURAMAN, A.; GREWAL, D.; KRISHNAN, R. **Marketing research**. [S.l.]: Cengage Learning, 2006.
- PIAMRAT, K. et al. Qoe-based network selection for multimedia users in ieee 802.11 wireless networks. In: IEEE. **2008 33rd IEEE Conference on Local Computer Networks (LCN)**. [S.l.], 2008. p. 388–394.
- PIRES, V. C. Factors that influence information source choice by new car buyers. **Annals of Balas - Annual Conference 2002**, 2002.
- POSEN, H. A. Ridesharing in the sharing economy: Should regulators impose uber regulations on uber. **Iowa L. Rev.**, HeinOnline, v. 101, p. 405, 2015.
- RAO, A. et al. Total quality management—a cross functional perspective. **Journal of the Operational Research Society**, Taylor & Francis, v. 48, n. 5, p. 544–545, 1997.
- RAYLE, L. et al. App-based, on-demand ride services: Comparing taxi and ridesourcing trips and user characteristics in san francisco university of california transportation center (uctc). **University of California, Berkeley, United States Rogers, B.(2015) The social costs of Uber. James E. Beasley School of Law, Temple University, Philadelphia, United States**, 2014.

RECUERO, R. Curtir, compartilhar, comentar: trabalho de face, conversação e redes sociais no facebook. **Verso e Reverso**, v. 28, n. 68, p. 117–127, 2014.

REITER, U. et al. Factors influencing quality of experience. In: \_\_\_\_\_. **Quality of Experience: Advanced Concepts, Applications and Methods**. Cham: Springer International Publishing, 2014. p. 55–72. ISBN 978-3-319-02681-7. Disponível em: <[http://dx.doi.org/10.1007/978-3-319-02681-7\\_4](http://dx.doi.org/10.1007/978-3-319-02681-7_4)>.

RICCI, F.; ROKACH, L.; SHAPIRA, B. **Introduction to recommender systems handbook**. [S.l.]: Springer, 2011.

RICHTER, S.; BOHM, A. A location and privacy service enabler for context-aware and location-based services in ngn. In: IEEE. **Telecommunications Network Strategy and Planning Symposium, 2006. NETWORKS 2006. 12th International**. [S.l.], 2006. p. 1–5.

RIFKIN, J. **The zero marginal cost society: The internet of things, the collaborative commons, and the eclipse of capitalism**. [S.l.]: St. Martin's Press, 2014.

RODRÍGUEZ, D. Z. et al. Video quality metric for streaming service using dash standard. **IEEE Transactions on Broadcasting**, IEEE, v. 62, n. 3, p. 628–639, 2016.

RUSSELL, S. J.; NORVIG, P. **Artificial intelligence: a modern approach**. [S.l.]: Malaysia; Pearson Education Limited,, 2016.

SAKR, G. E.; ELHAJJ, I. H.; HUIJER, H. A.-S. Support vector machines to define and detect agitation transition. **IEEE transactions on affective computing**, IEEE, v. 1, n. 2, p. 98–108, 2010.

SCIORTINO, K. **Breathless: Is Uberpool the New Tinder?** 2015. Disponível em: <<https://www.vogue.com/article/breathless-karley-sciortino-uberpool>>.

SHAHEEN, S. et al. Shared mobility: A sustainability & technologies workshop: definitions, industry developments, and early understanding. In: **Automated Vehicles Symposium**. [S.l.: s.n.], 2015.

SILVA, M. P. da. Qualidade de experiência: Uma abordagem interdisciplinar. **Revista de Exatas e TECNológicas**, v. 5, n. 1, p. 17–26, 2014.

SINGHAL, S.; JENA, M. A study on weka tool for data preprocessing, classification and clustering. **International Journal of Innovative technology and exploring engineering (IJITEE)**, v. 2, n. 6, p. 250–253, 2013.

SOPRANA, P. **UberPool: namoro ou amizade?** 2016. Disponível em: <<https://epoca.globo.com/vida/experiencias-digitais/noticia/2016/05/uber-pool-e-interacao-no-banco-detras.html>>.

SOUZA, R. H. d. et al. **Mapeamento de qualidade de experiência (QOE) através de qualidade de serviço (QOS) focado em bases de dados distribuídas**. Tese de mestrado, 2017.

TAN, P.-N. et al. **Introduction to data mining**. [S.l.]: Pearson Education India, 2006.

TOMAÉL, M. I.; ALCARÁ, A. R.; CHIARA, I. G. D. Das redes sociais à inovação. **Ciência da informação, Brasília**, SciELO Brasil, v. 34, n. 2, p. 93–104, 2005.

- VIEIRA, J. et al. Investigating mobile quality of experience in public transport. In: ACM. **Proceedings of the 14th international conference on Human-computer interaction with mobile devices and services companion**. [S.l.], 2012. p. 29–34.
- VINE, S. L.; POLAK, J. Introduction to special issue: new directions in shared-mobility research. **Transportation**, Springer, v. 42, n. 3, p. 407–411, 2015.
- WU, W. et al. Quality of experience in distributed interactive multimedia environments: toward a theoretical framework. In: ACM. **Proceedings of the 17th ACM international conference on Multimedia**. [S.l.], 2009. p. 481–490.
- XU, J. et al. On the properties of mean opinion scores for quality of experience management. In: **2011 IEEE International Symposium on Multimedia**. [S.l.: s.n.], 2011. p. 500–505.
- ZEPERNICK, H.-J.; ENGELKE, U. Quality of experience of multimedia services: past, present, and future. In: **Adjunct Proceedings of the 9th European Interactive TV Conference (EuroITV 2011)**. [S.l.: s.n.], 2011. p. 115–119.
- ZHANG, D. et al. Callcab: A unified recommendation system for carpooling and regular taxicab services. In: **BigData Conference**. [S.l.]: IEEE, 2013. p. 439–447.
- ZHANG, D. et al. A carpooling recommendation system for taxicab services. **IEEE Transactions on Emerging Topics in Computing**, IEEE, v. 2, n. 3, p. 254–266, 2014.
- ZHANG, H.-R.; MIN, F. Three-way recommender systems based on random forests. **Knowledge-Based Systems**, Elsevier, v. 91, p. 275–286, 2016.
- ZHEN, C. **Impact of Ride-Sourcing Services on Travel Habits and Transportation Planning**. Tese (Doutorado) — University of Pittsburgh, 2015.

## APÊNDICE A – Questionário Aplicado

### Compartilhamento de Corridas/Viagens através de Aplicativos de Smartphone

#### INFORMAÇÕES SOBRE A PESQUISA:

Prezado (a) voluntario (a), você está sendo convidado (a) para participar de uma pesquisa sobre o COMPARTILHAMENTO DE CORRIDAS OU VIAGENS POR SISTEMAS DE TRANSPORTE PRIVADO POR APLICATIVOS DE SMARTPHONE, vinculado ao Programa de Pós-graduação em Engenharia de Sistemas e Automação da Universidade Federal de Lavras – UFLA.

Este questionário é destinado para fins **Meramente Acadêmicos**.

Sua contribuição se dará através das respostas a este questionário.

Todas as informações coletadas nesta pesquisa são sigilosas e sua identidade será preservada.

Questões Iniciais:		
<b>Qual a faixa etária você se encontra:</b>		
<input type="radio"/> Menor ou igual a 19 = faixa 1 <input type="radio"/> 20 a 29 = faixa 2 <input type="radio"/> 30 a 49 = faixa 3 <input type="radio"/> Maior que 50 = faixa 4		
Qual sua idade exata? _____		
<hr/>		
<input type="radio"/> Feminino <input type="radio"/> Masculino <input checked="" type="radio"/> Outros: <input type="text"/>		
<b>Relacionamento:</b>		
<input type="radio"/> Solteiro(a) <input type="radio"/> Casado(a) <input type="radio"/> Divorciado(a) <input type="radio"/> Viúvo(a) <input type="radio"/> Separado(a) <input type="radio"/> Relacionamento Sêrio <input type="radio"/> Outros: <input type="text"/>		
<b>Grau de Instrução:</b>		
<input type="radio"/> Ensino Fundamental <input type="radio"/> Ensino Médio <input type="radio"/> Ensino Superior <input type="radio"/> Técnico <input checked="" type="radio"/> Pós Graduado <input type="radio"/> Mestrado <input type="radio"/> Doutorado		

### COMPARILHAMENTO DE CORRIDA/VIAGEM

Os aplicativos de transporte privado, como Uber, Cabify ou 99Pop, possibilitam a conexão entre passageiros e motoristas para a prestação de serviços de transporte urbano. Recentemente uma modalidade de compartilhamento de corridas/viagens possibilita que duas ou mais pessoas, que possuam trajetos similares, dividam o serviço, utilizando assim apenas um veículo (ex. UberPool). Tal serviço favorece ao usuário a redução no custo do transporte em até 40%, o tempo de viagem pode ser alterado devido a rodas adicionais e o veículo é compartilhado com outra pessoa desconhecida.

**Você alguma vez utilizou transporte provado por aplicativo (ex: Uber, Cabify, WillGo, 99Pop)?**

Já Utilizei     
  Utilizo com Frequência     
  Nunca Utilizei

Pense sobre compartilhar uma corrida ou viagem com alguma pessoa desconhecida. Baseado nisto marque a opção com relação ao grau de aceitação ao realizar o compartilhamento, sendo que quanto maior a nota melhor sua experiência de compartilhamento (1 estrela = Muito baixa aceitabilidade ★ - 5 estrelas = Muito alta aceitabilidade ★★★★★)

Questões	1 ★	2 ★★	3 ★★★	4 ★★★★	5 ★★★★★
1) Eu compartilharia uma corrida/viagem com uma pessoa desconhecida	<input type="radio"/>				
2) Eu compartilharia uma corrida/viagem com um casal desconhecido	<input type="radio"/>				
3) Eu compartilharia uma corrida/viagem com pessoas do gênero oposto ao meu.	<input type="radio"/>				
4) Eu compartilharia corrida/viagem com pessoas opostas a minha opinião política.	<input type="radio"/>				
5) Eu compartilharia uma corrida/viagem com pessoas solteiras.	<input type="radio"/>				

6) Eu compartilharia uma corrida/viagem com pessoas com hobby diferente do meu.	<input type="radio"/>				
7) Eu compartilharia uma corrida/viagem com pessoas com algum tipo união estável	<input type="radio"/>				
8) Eu compartilharia uma corrida/viagem com pessoas que falassem sobre futebol	<input type="radio"/>				
9) Eu compartilharia uma corrida/viagem com pessoas que torcem para times rivais ao meu (ex. Palmeiras x Corinthians, Atlético x Cruzeiro)	<input type="radio"/>				
10) Eu compartilharia uma corrida/viagem com pessoas de opinião religiosa diferente da minha	<input type="radio"/>				
11) Eu compartilharia uma corrida/viagem com pessoas que transportassem animais (cachorro ou gato)	<input type="radio"/>				
12) Ao compartilhar uma corrida/viagem eu desejo não dialogar com outras pessoas	<input type="radio"/>				
13) Ao compartilhar uma corrida/viagem, em caso de eu escolher não dialogar com outras pessoas, desejo que elas saibam disso previamente de alguma forma	<input type="radio"/>				

As próximas questões têm como objetivo identificar o nível de importância dos assuntos abordados anteriormente.

Baseado nisto marque a opção que mais você se relaciona sobre os assuntos tratados (1 estrela = Baixa Relação ★ - 5 estrelas = Alta Relação ★★★★★)

Questões	1 ★	2 ★★	3 ★★★	4 ★★★★	5 ★★★★★
1) Qual a relevância da sua opção política?	<input type="radio"/>				
2) Qual a relevância da sua opção religiosa?	<input type="radio"/>				
3) Qual a relevância da sua orientação sexual em um convívio social?	<input type="radio"/>				
4) Qual a relevância da sua opção por esporte? (Escolha de um time de futebol, basquete, atleta, etc.)	<input type="radio"/>				

Marque a opção que de acordo com o nível de importância dos assuntos tratados (1 estrela = Baixa Importância★ - 5 estrelas = Alta Importância★★★★★)

Questões	1 ★	2 ★★	3 ★★★	4 ★★★★	5 ★★★★★
Qual a importância da sua opção de hobby?	<input type="radio"/>				
Qual a importância que animais possuem para você? (cachorros e gatos)	<input type="radio"/>				
Qual é a importância em se socializar com novas pessoas?	<input type="radio"/>				
Qual a importância de socializar com pessoas com quem você possa se envolver?	<input type="radio"/>				