Sistema de Recomendações Turísticas Utilizando Raciocínio Baseado em Casos e Geolocalização

Tourist Recommender System Using Case-Based Reasoning and Geolocation

DOI:10.34117/bjdv7n4-027

Recebimento dos originais: 07/03/2021
Aceitação para publicação: 01/04/2021

Anita Maria da Rocha Fernandes
Dra.
Instituição de atuação atual: UNIVALI – Universidade do Vale do Itajai
Endereço completo: Universidade do Vale do Itajai – UNIVALI - Campus Kobrasol – Mundo Car Shopping – São José – Santa Catarina
E-mail: anita.fernandes@univali.br

Mauricio Pasetto de Freitas
Bacharel em Ciência da Computação
Instituição de atuação atual: UNIVALI – Universidade do Vale do Itajai
Endereço completo: Universidade do Vale do Itajai – UNIVALI - Campus Kobrasol – Mundo Car Shopping – São José – Santa Catarina
E-mail: mauriciopasetto@gmail.com

RESUMO
O turismo é um setor cada vez mais relevante do ponto de vista cultural e com grande impacto econômico. Ferramentas que auxiliem o turista a ter uma melhor experiência no local visitado são cada vez mais solicitadas. Neste contexto, tem-se os Sistemas de Recomendação de Turismo. Tais sistemas servem de apoio a tomada de decisão e personalização de conteúdo, com base nas necessidades e preferências dos viajantes. O grande problema são as informações desatualizadas sobre os pontos turísticos. Neste sentido, este trabalho apresenta um sistema de recomendações turísticas que utiliza raciocínio baseado em casos e informações sobre geolocalização para apresentar aos usuários os pontos turísticos mais pertinentes ao seu perfil e com a localização atualizada.

Palavras chave: Turismo, Sistemas de Recomendação, Raciocínio Baseado em Casos, Geolocalização.

ABSTRACT
Tourism is an increasingly culturally relevant sector with a great economic impact. Tools that help tourists to have a better experience in the place visited are increasingly requested. In this context, there are Tourism Recommendation Systems. Such systems support decision making and content customization, based on the needs and preferences of travelers. The big problem is the outdated information about the sights. In this sense, this work presents a system of tourist recommendations that uses case based reasoning and information about geolocation to present users with the most relevant tourist points to their profile and with the updated location.

Key Words: Tourism, Recommendation systems, Case-Based Reasoning, Geolocation.

1 INTRODUÇÃO

O Turismo é um setor com um papel sócio econômico importante para o desenvolvimento sustentável das cidades ao redor do mundo. O volume de negócios deste setor se equipara a exportações de petróleo, produtos alimentícios ou automotivos, sendo hoje uma das principais indústrias segundo o World Tourism Organization (UNWTO, 2019). A indústria do turismo é importante para a preservação da cultura nos destinos, a proteção do meio ambiente, o crescimento econômico através da geração de empregos, criação de novas empresas, oportunidades de negócio e na contribuição ao produto interno bruto mundial.

Com o objetivo de garantir o desenvolvimento sustentável, a competitividade do setor, a melhoria da qualidade de vida do morador e do visitante e de aumentar a qualidade da experiência turística surgiu o conceito de Smart Tourism (GRETZEL et al, 2015). A contribuição do Smart Tourism refere-se principalmente à integração da infraestrutura da cidade com as tecnologias que permitem que os turistas interajam com o local, obtenham informações, se localizem, se desloquem e descubram atividades e conheçam locais de seu interesse, que possam compartilhar suas opiniões via redes sociais, que possam construir e ter um papel ativo na experiência. Tudo isso contribui com o objetivo de aumentar a qualidade e significado da experiência turística (GRETZEL et al, 2015).

Uma ferramenta importante para o Smart Tourism é o Sistema de Recomendação de Turismo (SRT). Os SRTs analisam uma grande quantidade de informações e retornam conteúdo relevante de acordo com as necessidades e preferências dos viajantes e moradores. Isto auxilia na construção de experiências turísticas e dão suporte a melhoria do empreendimento turístico (ROOPESH; TULASI, 2018).

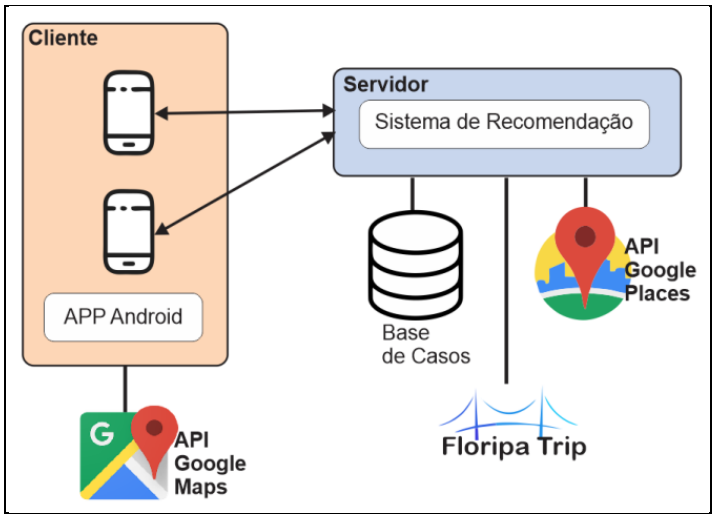
O turista atual está mais inclinado a construir seus próprios roteiros e experiência turística, utilizando serviços disponíveis on-line, ao invés de comprar pacotes com roteiros e atividades pré-estipulados. O turista também está aberto a adaptações e a buscar atividades durante a visitação da cidade. O problema principal é encontrar informações relevantes e personalizadas a cerca de um determinado destino ou item turístico.

Neste contexto, este trabalho apresenta uma contribuição para a área, através de um sistema de recomendações turísticas de pontos turísticos de interesse de acordo com o perfil do usuário e sua localização. O perfil do turista é definido pela classificação de interesse em categorias de turismo pré-derterminadas. Como estudo de caso, utilizou-se dados da cidade de Florianópolis, em Santa Catariana – Brasil. Para as recomendações, o sistema faz uso da base de casos implementada, e das bases de dados do Google Places e

do aplicativo Floripa Trip, consumidas através do uso de uma API (*Application Programming Interface*). O sistema utiliza o método de filtragem *Knowledge Based Case*, o qual faz uso do conhecimento referente aos pontos de interesse, o qual é organizado na forma de casos para executar as recomendações. O sistema faz uso do Raciocínio Baseado em Casos (RBC) para análise dos casos. Os serviços são disponibilizados aos usuários através de uma plataforma para dispositivos móveis que façam uso do sistema operacional Android. A Figura 1 apresenta a arquitetura resumida da aplicação.

O sistema é acessado pelo usuário através do celular no qual o usuário, após realizar o cadastro e definir seu perfil, poderá solicitar recomendações através dos parâmetros que ele estipular. Uma lista de recomendações de pontos de interesse é apresentada, e o usuário poderá adicionar itens a sua lista de interesse na visitação para posterior consulta, solicitar a rota de como chegar ao Ponto de Interesse (PI) selecionado e visualizar detalhes do referido PI.

Figura 1. Arquitetura do Sistema.



Nas próximas seções será apresentado o referencial teórico utilizado para a execução deste trabalho, bem como os trabalhos correlatos a este. Na sequência será apresentado o sistema em si, e os resultados e conclusões.

2 REFERENCIAL TEÓRICO

O referencial teórico deste trabalho envolveu os temas de *Smart Tourism*, Sistemas de Recomendação e Raciocínio Baseado em Casos.

2.1 SMART TOURISM

De acordo com o World Travel & Tourism Council (WTTC, 2018), o impacto global de viagens de turismo foi de 10,4% do Produto Interno Bruto (PIB), em 2017, sendo responsável por 4,6% do crescimento do PIB global, no mesmo ano. Ainda segundo WTTC (2018), um décimo dos empregos globais é suportado pelas viagens de turismo, o que representa 9,9% do emprego global. Além disto, um qunto de todos os empregos líquidos globais criados na última década estiveram dentro do setor de viagens e turismo.

No que se refere ao Brasil, segundo estudo do WTTC (2018), o impacto direto do setor de turismo na economia foi de US$ 59,6 bilhões em 2018, o equivalente a 3% do PIB. Ressalta-se que no referido ano, a contribuição total do setor foi de US$ 163 bilhões, ou seja 8,2% do PIB nacional.

Os dados apresentados reforçam a relevância do setor de turismo. Neste contexto, com o objetivo de garantir o desenvolvimento sustentável do turismo, a competitividade do setor, a melhoria da qualidade de vida do morador e do visitante, além de aumentar a qualidade da experiência turística, surgiu o conceito de *Smart Tourism*.

O conceito de *Smart Tourism* dá enfoque a sistemas instrumentados (as atividades da cidade são mensuráveis por sensores que se espalham pela cidade), interconectados (significa que cada bit produzido na cidade está conectado em alguma rede), e inteligentes (refere-se a aplicativos capazes de gerar tomadas de decisão mais precisas) (KOMNINNOS, PALLOT & SCHAFFERS, 2012). A combinação de tecnologias de informação e comunicação, de infraestrutura do destino turístico (utilização de sensores para efetuar medições e coletar informações das condições ambientais e ativos turísticos), reunir, integrar, analisar e apoiar decisões otimizadas com base no conhecimento coletivo, o que melhora a eficiência operacional e a qualidade de vida da cidade (CHOE, STIENMETZ & FESENMAIER, 2017).

Como exemplos bem sucedidos de *Smart Tourism*, tem-se Helsink e Lyon que foram eleitas como as capitais européias do *Smart Tourism* em 2019, pelo European Capital of Smart Tourism (2019), considerando os seguintes aspectos: acessibilidade dos serviços e infraestrutura, independentemente da idade, histórico cultural ou deficiência física; sustentabilidade, que se refere a proteção dos recursos naturais, redução da sazonalidade e a inclusão da comunidade local; tecnologias digitais para melhorar todos os aspectos da experiência do turismo, bem como os bens culturais e criativos em benefício do destino, da indústria e dos turistas; e cultura e criatividade para capitalizar o

patrimônio local, bem como os bens culturais e criativos em benefício do destino, da indústria e dos turistas.

A tecnologia é de suma importância para o *Smart Tourism* e suas principais contribuições para o setor referem-se a personalização de conteúdo, construção de itinerário e sugestão de atividades e PIs, como por exemplo, o uso de sistemas de recomendação, presentes na maioria das aplicações (ISINKAYE, FOLAJIMI & OJOKOH, 2015).

À seguir serão apresentados os conceitos referentes a sistemas de recomendação.

2.2 SISTEMAS DE RECOMENDAÇÃO

O crescimento exponencial da quantidade de conteúdo disponivel na web e o número de acessos contribuem para a sobrecarga de conteúdo, o que muitas vezes dificulta o acesso a informações adequadas ao interesse do usuário. Os motores de busca facilitam o acesso a informação, mas não levam em conta o perfil e preferências dos usuários, resolvendo em parte o problema. Os sistema de recomendação executam uma filtragem nesta massa de informação e devolvem conteúdo adequado de acordo com o perfil e preferências do usuário, além de prever a aceitação do usuário, a um determinado produto, serviço ou conteúdo (ISINKAYE, FOLAJIMI & OJOKOH, 2015).

Segundo Ricci, Rokach e Shapira (2015, p.1), Sistemas de Recomendação (SRs) são sistemas que fornecem sugestões para itens com maior probabilidade de interesse para um usuário específico. As sugestões estão relacionadas a vários processos de tomada de decisão, como por exemplo, quais itens comprar, qual música ouvir ou quais notícias online seria indicado ler. Em linhas gerais, os SRs fazem a diferenciação entre três modelos de abstração complementares, conforme apresentam , Rokach e Shapira (2015):

- **Itens**: são os objetos da recomendação, os quais são classificados pela complexidade e valor. Podem ter valor positivo ou negativo, dependendo da relevância do item para o usuário. A aceitação do item pelo usuário incorre em um custo negativo (a energia mental empregada, como na leitura de um artigo) ou um custo monetário real (valor pago por um pacote turístico). A complexidade de um item é definida pelo conjunto e características necessárias para definir o seu valor ou aceitação por parte do usuário.
- **Usuários**: tem um papel central em um sistema de recomendação, pois nenhuma personalização é possível sem que haja um modelo de usuário. Esse modelo define o perfil do usuário através da compilação de suas preferências e necessidades.

- **Transações:** refere-se ao conjunto de informações resultantes da interação entre o usuário e o sistema de recomendação. São dados do tipo *log* (registro de eventos) que armazenam informações importantes para o algoritmo de recomendação utilizado pelo sistema. O objeto da transação pode conter um *feedback* fornecido pelo usuário em relação ao item selecionado. As classificações são coletadas pelo sistema de recomendação e utilizadas como dados históricos para inferências futuras. Elas podem ser coletadas de forma explícita (opinião solicitada ao usuário), ou implícita (extraída da interação com o sistema de recomendação); Em um sistema de recomendação, com proceso interativo (de conversação), o usuário solicita uma recomendação e o sistema retorna um conjunto de recomendações. Neste sistema podem ser solicitas informações adicionais em relação a preferência do usuário para refinar as recomendações e troná-las mais assertivas.

Para os SRs uma questão chave é a representação do Perfil do Usuário, dado que cada SR precisa desenvolver ou manter um perfil do usuário para identificar os seus interesses, preferências e características a fim de efetuar recomendações personalizadas. Ao longo do tempo, foram desenvolvidos alguns modelos de perfil de usuário, sendo que os mais utilizados são: lista de palavras chave, vetor com avaliação numérica, os baseados em ontologias e os modelos de incerteza (BORRÁS, MORENO & VALLS, 2014).

O modelo lista de palavras chave associa uma simples lista de palavras chave ou categorias preferidas a cada usuári. Nestas categorias os itens são pré-classificados. Este modelo, de um modo geral, não produz recomendações apuradas, pois as palavras tendem a ser muito genéricas (BORRÁS, MORENO & VALLS, 2014). O modelo vetor com avaliações numéricas associa a cada usuário um vetor numérico, correspondendo a cada atributo do item, indicando o grau de interesse do usuário para cada atributo do item (BORRÁS, MORENO & VALLS, 2014). Já no modelo baseado em ontologias, o sistema faz uso de modelos semânticos e representa o conhecimento do domínio na forma de ontologia (conceitos), e um vetor de classificação é associado a cada ontologia (BORRÁS, MORENO & VALLS, 2014).

O principal objetivo do sistema de recomendação é construir relacionamento entre os produtos e os usuários, a fim de possibilitar a tomada de decisão: a seleção do produto/serviço mais adequado para um usuário específico. Para as empresas os benefícios de usar sistemas de recomendação são: o aumento da receita (aumento do número de negócios), a satisfação do cliente (contribui a manter o cliente), a personalização (levar em conta o perfil do usuário), a descoberta (de itens da preferência),

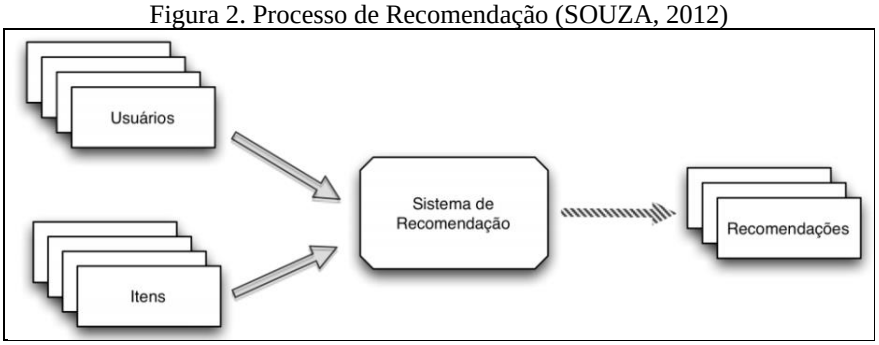
fornecimento de relatórios (cliente preciso e atualizado) (MOHAMED; KHAFAGY & IBRAHIM, 2019). Segundo Reategui e Cazella (2005) as estratégias mais utilizadas para personalizar ofertas e itens para um usuário são:

- **Lista de recomendação**: consiste na exibição de itens organizados em áreas de interesse dependendo do nicho de mercado. Por exemplo, uma loja de departamentos online agrupa produtos em categorias com por exemplo, produtos com frete grátis, agrupamento temático como Dia das Mães ou promoção de Natal, produtos mais vendidos, ou com maior desconto. Esta estratégia é de fácil implementação, pois não exige o levantamento do perfil do usuário e pode ser direcionada conforme as necessidades de marketing.
- **Avaliações de usuários**: tem por base a exibição de avaliações de produtos, serviços ou conteúdos, por parte das pessoas que já adquiriram o item em questão. Esta estratégia faz com que usuários se sintam mais seguros ao tomarem decisões de compra, pois contam, em teoria, com uma avaliação (ou uma série de avaliações) idônea em relação ao produto. É uma estratégia de fácil implementação, pois necessita apenas armazenar avaliações de usuários que adquiriram os itens e exibí-las junto ao produto.
- **Recomendações personalizadas**: baseia-se na exibição de itens de acordo com o perfil e as preferências do usuário. Esta estratégia necessita de um levantamento do perfil do usuário para fornecer as recomendações. O levantamento do perfil do usuário pode ser feito de modo explícito (fornecidas diretamente pelo usuário) e de modo implícito (como por exemplo, o levantamento de informações utilizano mineração em redes sociais).
- **Associação por conteúdos**: fundamenta-se em realizar recomendações com base na similaridade de características de um produto ou conteúdo. Esta estratégia busca associações de conteúdos, como por exemplo, livros de outros autores que escreveram sobre o mesmo tema.
- **Associação por usuário:** requer a exibição de itens de acordo com outros usuários com perfis similares que adquiriram tais itens no passado. Ou seja, se um usuário aquiriu um item A, pode ser que este usuário tenha interesse nos produtos que outros usuários adquiriram além do item A. Se baseia na ideia de que usuários que adquirem os mesmos produtos tem perfis similares e adquirem produtos similares e desta associação surge a recomendação.

2.3 PROCESSOS DE RECOMENDAÇÃO

De um modo geral os SRs utilizam um processo bem definido para gerar recomendações ao usuário. A Figura 2 ilustra este processo, e nela pode-se observar que existem duas fontes de informações, que correspondem ao Perfil do Usuário (preferências e necessidades) e aos itens (objetos da recomendação), para dar início ao processo. O elemento Sistema de Recomendação contém métodos de filtragem e regras de similaridade, que são aferidos (transações) sobre os dados de entrada para gerar as recomendações ao usuário (SOUZA, 2012).

Figura 2. Processo de Recomendação (SOUZA, 2012)



.

Os SRs são categorizados de acordo com o o método de filtragem utilizado. Cada método se baseia na forma com que as recomendações são exibidas (ROOPESH & TULASI, 2018). As principais abordagens utilizadas são: *Content-Based* (recomenda itens ao usuário, de acordo com a semelhança a produtos preferidos anteriormente), *Collaborative* (recomenda itens com base no que outros usuários semelhantes recomendaram), *Knowledge-Based* (recomenda ao usuário de acordo com suas preferências e características do item solicitado), *Demographic* (recomenda itens com base no perfil demográfico/nicho do usuário) e o *Hybrid* (utiliza recursos disponíveis das filtragens citadas anteriormente) (MOHAMED; KHAFAGY; IBRAHIM, 2019). A seguir cada um destes métodos serão brevemente apresentados.

Content-Based: este método utiliza informações sobre perfil do usuário e itens classificados/adquiridos anteriormente pelo usuário (histórico) e busca novos itens calculando a similaridade (das propriedades) com os itens do usuário, apresentando como resultado uma lista de itens com maior similaridade (BAHRAMIAN; ABBASPOUR & CLARAMUNT, 2018). A lista pode ser limitada a um número específico ou pela nota atribuída ao item. Uma das desvantagens deste método é o *cold start*, pois no início, as

recomendações não são muito precisas pela falta de base de comparações, já que o algoritmo precisa aprender para se tornar mais assertivo, o que necessita uma maior quantidade de classificações efetuadas pelo usuário. Outra desvantagem é a limitação de recomendar apenas itens similares aos classificados pelo usuário. Como vantagens, pode-se citar: atende o perfil exclusivo do usuário, sem levar em conta experiências de outros usuários; sem restrição a sugerir itens que não foram avaliados por outros usuários; e informa o porquê das recomendações *(*BAHRAMIAN; ABBASPOUR & CLARAMUNT, 2018).

Collaborative: este método faz recomendações a um usuário, de acordo com o que os usuários com gostos semelhantes classificaram. A similaridade de usuários é determinada com base no histórico de classificações. Calculando a média das preferências de usuário semelhantes para efetuar a recomendação de itens para um usuário específico (BAHRAMIAN; ABBASPOUR & CLARAMUNT, 2018). O método *Collaborative Filtering*, baseado em memória, aplica métodos estatísticos sobre os padrões de usuários ou classificações e as correlações entre eles e efetua recomendações para usuários semelhantes, o que tem um alto custo computacional, pois toda a base de dados computada. Para solucionar este problema é utilizado o método *Collaborative Filtering* com base em modelo, que agrupa usuários com alto grau de semelhança em *clusters*. Dessa forma, no cálculo da recomendação busca-se a classificação do usuário apenas do grupo ao qual o usuário pertence no *cluster*. Uma das limitações do *Collaborative Filtering* é a dependência de uma grande quantidade de dados históricos para recomendações mais assertivas. Uma das vantagens é a possibilidade de recomendar itens semelhantes a escolhidos no passado, pois conta com itens que usuários com gostos semelhantes recomendaram (BAHRAMIAN; ABBASPOUR & CLARAMUNT, 2018).

Knowledge-based: este método recomenda itens de acordo com os requisitos do usuário e no conhecimento de um determinado domínio. Com base nestas características, define-se a utilidade/relevância do item ao usuário. Neste sistema, a função de similaridade estima o quanto o usuário precisa do item, o que corresponde a recomendação efetuada pelo sistema (RICCI; ROKACH & SHAPIRA, 2015). Este método utiliza duas abordagens: baseada em casos e baseada em restrições. O *Knowledge-based* baseado em casos, utiliza conhecimento organizado na forma de casos para efetuar as recomendações, o que consiste na coleta de casos resolvidos anteriormente. Cada caso consiste basicamente em duas partes, uma parte descreve o problema (especificação) e a outra parte descreve como o problema foi resolvido (parte da solução). Para efetuar novas

recomendações (resolver novos problemas), os casos que correspondem a especificação (problema) do novo caso, são recuperados e a solução é adaptada para realizar a recomendação (resolver o problema) (AMEEN, 2019). O *Knowledge-based* baseado em restrições ou regras, gera recomendações baseadas em restrições ou regras explicitamente especificadas pelo usuário. As regras fazem o mapeamento entre requisitos do usuário e as propriedades/características do item, a base do conhecimento consiste em requisitos do usuário, propriedades dos itens e regras. Itens que estão de acordo com as regras em relação a um determinado conjunto de requisitos são gerados como recomendação (AMEEN, 2019).

Demographic: este método efetua a classificação de usuários segundo dados demográficos. O processo de recomendação funciona da seguinte forma: primeiro executa a criação de classes de usuários que possuem características demográficas semelhantes, logo após, analisa aquisições cumulativas dos usuários da classe para definir preferências de consumo para então gerar recomendações para usuários da mesma classe (RYNGKSAI & CHAMEIKHO, 2014).

***Hybrid*:** este método se baseia na combinação dos métodos citados anteriormente. De um modo geral esta combinação busca explorar as vantagens de cada método, a fim de compensar as desvantagens de um determinado método, criando assim um método hibrido (RICCI; ROKACH & SHAPIRA, 2015). Como por exemplo usar o método *Knowledge-based* para resolver problemas de *Cold Start* do método *Content-Base*d.

Além destes métodos, uma nova abordagem tem sido utilizada. O método ***Social***, executa a filtragem utilizando dados de mídias sociais como Facebook, Twitter, Instagran e outras, para realizar recomendações pessoais usando o comportamento e interação do usuário. Dados, *tags*, informações de *check-ins*, rede de amigos, comentários, fotos, vídeos são úteis para analisar e descobrir os interesses dos usuários sem adicionar tarefas adicionais ao usuário (ROOPESH & TULASI, 2018).

2.4 SISTEMA DE RECOMENDAÇÃO EM TURISMO

No turismo, o planejamento de uma viagem não é algo trivial, pelo contrário, requer investimento em pesquisa e seleção de conteúdo relativo ao(s) destino(s). Existe uma grande quantidade de informações disponíveis na Web relacionados ao destino (pontos de interesse, atrações e atividade), transporte (passagens aéreas, meios de transporte no destino específico) e acomodações (hotéis, *hostels*, casas, quartos, camping,

etc.). Essa grande quantidade de informações disponíveis em parte ajudam no processo, porém, criam uma série de problemas e dúvidas, tais como: informações incompletas ou conflitantes, a validade das informações, a confiabilidade dos agenstes, a acessibilidade dos locais, a existência de melhores ofertas, antecipação necessária e os obstáculos climáticos, que podem interferir na experiência.

Atualmente, o perfil do turista está mais voltado a construir seu próprio roteiro e experiência turística utilizando serviços on-line, ao invés de contratar agentes de viagens e a utilização de pacotes fechados de turismo. Isso se estende para a reserva de passagens aéreas/terrestres e a acomodações, levando em conta a necessidade da otimização de recursos monetários. O problema real é a busca de informações relevantes orientada ao indivíduo, a personalização e a adaptação às necessidades de usuários exigentes (NEMADE et al, 2017).

Os Sistemas de Recomendação Turística (SRT) vêm ao encontro desta problemática, para facilitar todas as etapas da viagem, encontrar informações relevantes, personalizas e atualizadas a cerca de um determinado destino ou item de turismo. Existem diferentes tipos de SRT. Os de tipo genérico apresentam informações em relação a um determinado destino (atrações, atividades, pontos de interesse), geralmente organizados em categorias como por exemplo o portal VisitFinland.com. Já os de tipo personalizado, levam em conta informações referentes às necessidades dos usuários, como por exemplo o Eventful, um sistema web de recomendação de eventos em qualquer lugar do mundo, permite o cadastro de usuário para receber recomendações de acordo com o perfil (ROOPESH & TULASI, 2018). Os SRT utilizam as mesmas abordagens utilizadas nos SRs (KESORN; JURAPHANTHONG & SALAIWARAKUL, 2017) porém, aplicadas ao domínio do turismo com diferentes funcionalidades.

2.4.1 Funcionalidades dos SRT

As funcionalidades dos Sistemas de Recomendação Turístico podem incluir destinos, pontos de interesse, rotas, criação de itinerários e os aplicados a grupos de usuários de acordo diferentes requisitos. A seguir a descrição das funcionalidades gerais dos SRT (BAHRAMIAN; ABBASPOUR & CLARAMUNT, 2018).

- **Recomendação de destinos de viagem e montagem de pacotes de turismo:** alguns SRT tem o foco na recomendação de destinos de turismo, podendo fornecer serviços de reserva/venda aos consumidores para achar melhores pacotes de viagem. Utilizam o perfil e preferências de usuários para estas recomendações

(BAHRAMIAN; ABBASPOUR & CLARAMUNT, 2018; MATE & INGLE; 2016).

- **Recomendação de lista classificada de Pontos de Interesse (PI):** alguns SRT tem o foco em listar e classificar pontos de interesse de um determinado destino, no planejamento e quando o usuário está no destino. Utilizam o perfil do usuário para efetuar a recomendação em adicional recuperar a localização automática do usuário (BAHRAMIAN; ABBASPOUR & CLARAMUNT, 2018).
- **Recomendação de rota:** alguns SRT recomendam melhores rotas para o usuário, levando

  em conta dados de contexto relacionados ao destino para predizer a rota mais indicada para

  o usuário seguir, dada a sua localização (BAHRAMIAN; ABBASPOUR & CLARAMUNT, 2018; MOCHOLI, et al, 2012; VANSTEENWEGEN et al, 2011).
- **Recomendação de viagem ou itinerário:** alguns SRT recomendam lista de pontos de interesse levando em conta uma rota ou sequência de visitação. Utilizam o perfil do usuário para estas recomendações (BAHRAMIAN; ABBASPOUR & CLARAMUNT, 2018; LIM et. al, 2017).
- **Recomendação para grupos de usuários:** alguns SRT efetuam recomendações a um grupo de usuários, levando em conta as características e necessidades gerais do grupo (BAHRAMIAN; ABBASPOUR & CLARAMUNT, 2018; GOTTAPU & MONANGI, 2017).
- **Recomendação de PI obrigatórios ou tipos de PI obrigatórios:** alguns SRT efetuam a recomendação de PI considerados obrigatórios (principais atrações e atividades) tanto pelo provedor quanto pelo o usuário. É indicado de acordo com a proximidade do usuário. PI obrigatórios devem ocupar um lugar privilegiado na lista de recomendações. Também podem categorizar PI obrigatórios para adição na lista de recomendação por pelo menos um PI do tipo indicado pelo provedor ou usuário (BAHRAMIAN; ABBASPOUR & CLARAMUNT, 2018).
- **Recomendação de PI com restrições temporais:** um SRT pode efetuar recomendações de PI levando em conta restrições temporais como horários de abertura e fechamento, para evitar a sugestão de PI que não estão/estarão

disponíveis (BAHRAMIAN; ABBASPOUR & CLARAMUNT, 2018; KLOTZ et al, 2017; VANSTEENWEGEN et al, 2011).

- **Recomendação de PI com restrições semânticas:** um SRT pode efetuar recomendações de PI levando em conta restrições semânticas como quantidade máxima de tempo ou de dinheiro no processo de seleção e encaminhamento. Pode-se restringir os PI durante as visitações, no andamento da experiência/viagem (BAHRAMIAN; ABBASPOUR & CLARAMUNT, 2018).
- **Recomendação de múltiplos dias de viagem:** um SRT pode efetuar o planejamento de múltiplos dias de viagem. Na maioria das vezes, os PI selecionados são visitados uma única vez (BAHRAMIAN; ABBASPOUR & CLARAMUNT, 2018).
- **Recomendação em redes sociais baseadas em localização:** o SRT pode efetuar recomendações adicionando conteúdo social usando serviços e recursos geográficos, levando em conta a localização do usuário (BAHRAMIAN; ABBASPOUR & CLARAMUNT, 2018; GOTTAPU & MONANGI, 2017; YU & CHEN, 2015).

Os SRT implementados de um modo geral podem implementar mais de uma das funcionalidades citadas anteriormente, dependendo do objetivo e do escopo da aplicação.

2.5 Raciocínio Baseado em Casos

Raciocínio Baseado em Casos (RBC) é uma técnica de Machine Learning (LU et al, 2016), utilizada como solução em um grande espectro de aplicações que vão desde identificar causas de conflitos no casamento (ICHWANI & SUPRATO, 2019), até a detecção de emergências em usinas nucleares (RASKOB, MÖHRLE & BAI, 2016).

RBC é definido por Duvois e Prade (2008, p.1) como sendo uma técnica de resolução de problemas que se baseia na similaridade entre o problema atual e os previamente resolvidos, que são armazenados em um repositório.

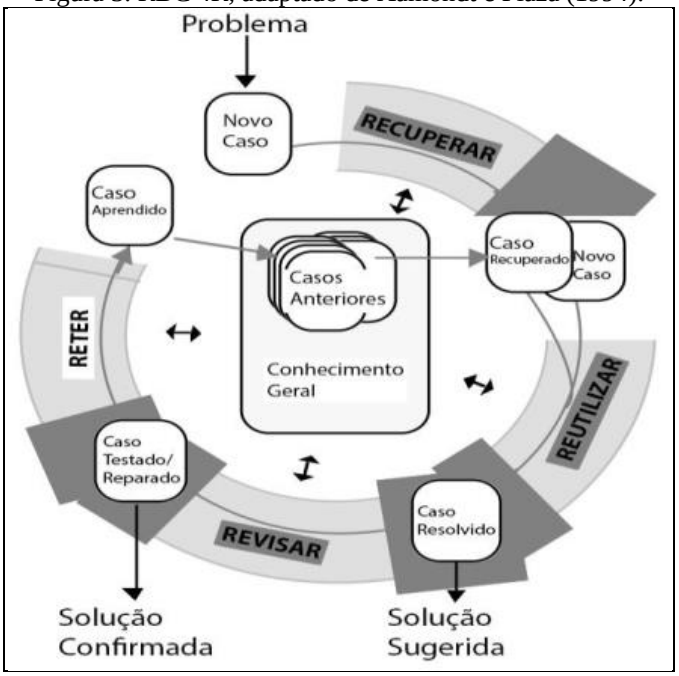
Um sistema de RBC pode armazenar conhecimento em diferentes repositórios, que são conhecidos como Repositórios de Conhecimento, sendo eles: o vocabulário (palavras, termos e conceitos do domínio da aplicação), casos (experiências anteriores), conhecimento sobre como identificar similaridade (reconhecer casos na base para resolver novos casos) e conhecimento sobre como adaptar casos (adequar casos similares a especificação de novos casos) (RICHTER; MICHAEL & WEBER, 2013). Um caso é

composto de duas partes, a parte do problema (descreve o problema ou a situação problema) e a parte da solução (descreve como o problema ou situação foi resolvido). De um modo geral o RBC armazena soluções assertivas (positivas) em uma base de casos, entretanto, soluções inadequadas ao problema (negativas) também podem ser armazenadas e servem para indicar ao sistema o que deve evitar. Sendo necessário efetuar a diferenciação entre as soluções positivas e negativas, para que o sistema saiba o que evitar e o que utilizar como solução (RICHTER; MICHAEL & WEBER, 2013).

Sistemas de RBC resolvem problemas simulando o raciocínio humano, usando o conhecimento armazenado (experiências passadas), para resolução de novos problemas. Em suma, o RBC se propõe a solucionar novos casos como base em sua similaridade com casos resolvidos anteriormente (ICHWANI & SUPRATO, 2019). Como os casos na base dificilmente representam exatamente o problema do novo caso, os sistemas RBC podem adaptar os casos recuperados e verificar se equivalem ao problema atual (VON WANGENHEIM; VON WANGENHEIM & RATEKE, 2013).

As soluções de novos casos são adicionadas a base para serem reutilizados, esta é a forma que o RBC aprende, se atualiza e se torna cada vez mais assertivo em suas soluções (ICHWANI & SUPRATO, 2019). Existem dois modelos mais utilizados para o processo RBC: o Ciclo de RBC 4R (AAMONDT & PLAZA, 1994) e o Ciclo RBC 6R (NORDLUND & SCHÄFER, 2006). O primeiro consiste em recuperar (os casos mais similares), reutilizar (os casos para tentar resolver o problema atual), revisar (a solução proposta se necessário) e reter (a nova solução como parte de um novo caso). O segundo apresenta uma variação separando em duas etapas a de aplicação (recuperar, reutilizar e revisar) e a etapa de manutenção do sistema (revisar, reter e refinar). Neste trabalho foi adotado o Ciclo RBC 4R como processo padrão, ilustrado na Figura 3.

Figura 3. RBC 4R, adaptado de Aamondt e Plaza (1994).



A representação de Casos é uma parte essencial para o desenvolvimento do RBC, todo o sistema de inferência na busca por soluções de um problema depende da estrutura e do conhecimento dos casos de um determinado domínio (SAPPAGH & ELMOGY, 2015). O RBC necessita da representação do conhecimento, que descreve os casos, e a medida de similaridade utilizada para definir a semelhança entre os casos da base e novos casos. A escolha da representação para um Sistema RBC deve levar em conta os modelos conceituais usados para projeto e representação dos casos, e as formas de implementação dos casos. A representação dos casos contém três questões, a primeira, selecionar os atributos para definir um caso, a segunda, selecionar a estrutura para representar o caso, e a última, a forma de organização dos casos na base de casos.

A base de casos pode ser armazenada em um banco de dados, arquivos de texto ou arquivos XML, não existe uma forma padrão, porém, os casos devem ser indexados para que na etapa de recuperação o RBC possa usar esta estrutura e ter acesso aos casos (SAPPAGH & ELMOGY, 2015). Existem diversas formas de representar os casos. Eles podem ser representados como um simples vetor de características ou usando qualquer formalismo representacional Inteligência Artificial como *frames*, representação orientada a objetos, predicados, redes semânticas ou regras.

A escolha da representação depende do domínio da aplicação e das informações que serão armazenadas nos casos. (SAPPAGH & ELMOGY, 2015). As representações

mais comuns são: usando vetor de características, baseada em quadros, orientada a objetos, baseada em predicados, textual, hierárquica, relacional, árvores *k-d* e redes semânticas.

2.5.1 Similaridade

No Raciocínio Baseado em Casos a similaridade é um fator essencial para a recuperação de casos. A mensuração da similaridade é determinada pela utilidade do(s) caso(s) recuperado(s) para a solução de um novo problema. Selecionar um método para o cálculo de similaridade apropriado, implica em tentar lidar de forma adequada com os relacionamentos profundos e ocultos entre características relevantes associadas a um determinado caso (PAL & SHIU, 2004). A avaliação de similaridade tem por objetivo encontrar um caso útil na solução do novo problema, sendo que, ele será útil se a descrição do problema estiver próxima a do novo problema. O objetivo é que os casos recuperados sejam análogos de tal maneira que a sua solução possa ser reutilizada de forma reciproca, isto é chamado de similaridade (RICHTER; MICHAEL & WEBER, 2013).

De um modo geral, existem duas abordagens para a recuperação de casos: baseado no cálculo da distância entre os casos, onde os casos são avaliados por uma medida métrica de similaridades; e estruturas representacionais/indexadoras dos casos, onde é efetuada uma busca na estrutura de indexação utilizada (PAL & SHIU, 2004).

3 TRABALHOS CORRELATOS

À seguir serão apresentados alguns trabalhos que serviram de base para este trabalho.

3.1 GUIDE-ME

Guide-me é um sistema de recomendação de PI baseado em localização, disponível via web, para dipositivos móveis com sistema operacional IOS. Ele permite ao usuário consultar locais de interesse turístico, utilizando um conjunto de filtros de pesquisa para explorar novos locais. Utiliza a localização atual do usuário representado através de coordenadas geométricas obtidas por conexões GPS (*Global Positioning System*) ou WiFi (*Wireless Fidelity*). Para utilizar o serviço o usuário precisa efetuar login, ou efetuar o cadastro utilizando e-mail ou conta dos serviços sociais Facebook ou Twiter. A base de dados é composta de PI de Portugal (UMANETS & FERREIRA, 2014).

O sistema sugere novos locais com base nas ações passadas do usuário e baseado na localização atual, levando em conta as preferências do usuário através do sistema de recomendação. Os usuários avaliam os locais que visitaram e o sistema de recomendação utilizada destas informações para sugerir uma lista classificada por ordem de preferência. Os usuários podem consultar PI próximos a sua localização e aplicar critérios de filtragem como país, cidade, categoria e condições climáticas para restringir os resultados. Os usuários também podem consultar locais recomendados, marcar locais como visitados ou desejados, seguir e deixar de seguir outros usuários (UMANETS & FERREIRA, 2014). O Guide-me utiliza o método de filtragem *Collaborative*, cujo processo de recomendação é baseado em avaliações de usuário semelhantes, ou seja, usuário que preferências similares. Utiliza o método *Collaborative Filtering Item-Based*, que aplica técnicas de mineração de dados para desenvolver a classificação dos usuários. Este modelo é usado para prever as preferências do usuário (UMANETS & FERREIRA, 2014).

3.2 SISTEMA DE RECOMENDAÇÃO DE LUGARES BASEADO EM LOCALIZAÇÃO E PERFIL

Lima (2016) apresenta um Sistema de Recomendação de PI baseado em localização e no perfil do usuário. Para isto, é utiliza a API Google Maps como serviço de localização e a API Google Places como base de dados para os locais a serem recomendados. O sistema de recomendação utilizará a filtragem Collaborativa, adquirindo o perfil do usuário de forma explicita (LIMA, 2016).

O serviço é disponibilizado para o sistema operacional Android e o usuário se cadastra ou efetua o login. O cadastro é utilizado para coletar as informações dos perfis de usuários. O sistema fornece informações sobre os lugares sugeridos pelo algoritmo de recomendação. O usuário pode escolher um raio de abrangência a partir da sua localização. A lista de recomendações é apresentada de forma ordenada por distância ou classificações, apresentado informações relacionadas a cada local recomendado. É possível também visualizar o local no mapa (LIMA, 2016). Um Web Service instalado em servidor online, contém os mecanismos para coletar informações sobre os lugares, gerenciar os dados dos usuários, lugares e avalições, também é responsável por calcular a similaridade entre usuário e realizar uma estimativa de classificação (LIMA, 2016).

3.3 TRIPBUDDY

O TripBuddy é um estudo para o desenvolvimento de uma aplicação Web com recursos para planejamento de viagem fazendo uso de recomendações. As recomendações, com base no comportamento de navegação do usuário na Web, são feitas utilizando o algoritmo K-*Means Clustering*. O sistema tem por objetivo fornecer informações turísticas completas, planejamento e agendamento para a elaboração de um plano de viagem, fornecendo recursos de direcionamento para o destino, a fim de fornecer informações de rotas de viagem a serem tomadas (SUMARDI et al, 2017). O TripBuddy tem como requisitos a implementação das seguintes funcionalidades: (i) recomendação de destino turístico, fornecendo destinos com base no tipo de local semelhante ao que o usuário estiver visualizando, nos destinos próximos, nas avaliações de outros turistas com perfis semelhantes e na experiência de navegação do usuário; (ii) pesquisa detalhada para encontrar destinos de viagem, permitindo que os usuários pesquisem tipos específicos de destinos, sendo que a filtragem de pesquisa é por preço, classificação, localização e categoria de destinos turísticos; plano de viagem, permitindo ao usuário definir a viagem desejada. No planejamento de recursos, os usuários organizam os destinos que gostariam de visitar e o sistema ajuda a calcular a distância mais curta para que o usuário viaje com eficiência. Também deve calcular o custo total e a duração da viagem.

3.4 PI RECOMMENDER SYSTEM FOR SOCIAL GROUPS

Gottapu e Monang (2017) apresentam um Sistema de Recomendação de Grupo de PI baseado em assinatura, o qual fornece recomendações personalizadas de locais, como restaurantes, para grupos de redes sociais móveis. Neste trabalho, são identificados locais que são usados para eventos em grupo, em seguida, uma assinatura é criada com base no tamanho do grupo, localização, horário e outros parâmetros. Sendo assim, a cada novo grupo, uma assinatura semelhante é criada e lugares são recomendados, baseados na similaridade com as assinaturas calculadas.

Os eventos de grupos são descobertos utilizando redes sociais baseadas em localização (RSBL), são adquiridos dados de *check-ins* de usuários que contém o ID (identificador) do local, juntamente o *timestamp* com a latitude, longitude e hora, para cada Ponto Único (PU). Primeiro são identificados todos os pontos únicos, em seguida, são criadas assinaturas para cada PU. Tendo em conta um PI e usuários que visitaram esse PI, são criados gráficos sociais baseados nas relações entre os usuários. Para isso, é definido um limite de intervalo de tempo, onde são extraídos todos os *timestamps*

exclusivos para o PI em específico (GOTTAPU & MONANG, 2017). A captura da assinatura do PI é extraída com base nos gráficos de eventos, nos quais as características pertinentes são obtidas para criar a assinatura. Assim que são adquiridas todas as assinaturas para todos os PIs, a recomendação de PI para novos grupos é iniciada usando estas assinaturas. Se um novo grupo solicitar uma recomendação de PI, primeiro é gerada uma assinatura para o grupo, e em seguida, são encontradas assinaturas mais próximas em relação a assinatura deste grupo. A localização destas assinaturas (PI) será recomendada para o novo grupo (GOTTAPU & MONANG, 2017).

4 O SISTEMA DESENVOLVIDO

O sistema desenvolvido apresenta as seguintes funcionalidades relacionadas a sistemas de recomendação: apresentação classificada de pontos de interesse, a recomendação de rota e recomendações baseadas em localização. Para o perfil do usuário, o mesmo define o nível de interesse para os tipos de turismo utilizando um vetor com avaliação numérica. Esta classificação numérica aliada a localização é utilizada para buscar recomendações que estejam de acordo com o interesse e localização do usuário.

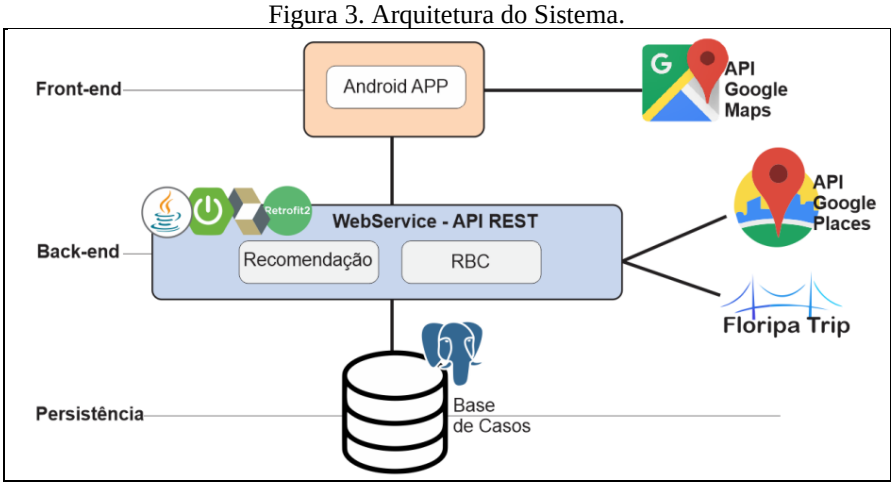
O método de filtragem utilizado neste sistema de recomendação é o *Knowledge-based cased*, o qual efetua recomendações de acordo as preferências do usuário e características do item solicitado. Este método usa conhecimento organizado na forma de casos para efetuar as recomendações. O processo de recomendação de pontos de interesse utiliza três bases de dados, a Base de Casos implementada neste trabalho e as bases de dados Google Places e FloripaTrip ambas consumidas através de API. Estas duas últimas são utilizadas para buscar novos casos, sendo posteriormente adicionados à Base de Casos, feito isso, as recomendações são recuperadas diretamente da Base de Casos.

O sistema utiliza como base o ciclo RBC composto de quatro etapas, sendo elas: recuperação (dos casos mais similares), reutilização (dos casos para tentar resolver o problema atual), revisão (da solução proposta se necessário) e retenção (da nova solução como parte de um novo caso). O ciclo RBC implementado é visto na próxima seção.

O serviço de recomendação do sistema é disponibilizado ao usuário através de aplicativo desenvolvido de forma nativa para a plataforma Android. Os serviços consumidos pelo *front-end* são disponibilizados através de Web Services Rest implementado em Java 11 utilizando Spring Boot 2.3.3, Hibernate 5.4.22.Final e Retrofit2. Para a persistência dos dados é utilizado o banco de dados PostegreSQL 12.4

R1, o qual permite a busca por localização geográfica diretamente no banco. O sistema apresenta a seguinte arquitetura, mostrada na Figura 3.

Figura 3. Arquitetura do Sistema.



4. 1 IMPLEMENTAÇÃO DO CICLO DE RACIOCÍNIO BASEADO EM CASOS

O sistema de Raciocínio Baseado em Casos utilizado, implementa quatro etapas do ciclo de RBC: recuperação (dos casos mais similares); reutilização (dos casos para tentar resolver o problema atual); revisão (da solução proposta, se necessário); e retenção (da nova solução como parte de um novo caso).

Os casos são armazenados na base de casos, utilizando a representação vetor de características, que consiste na descrição do caso na forma de um conjunto de características atributo-valor. Cada caso apresenta uma parte do problema e outra da solução. Neste trabalho, a parte do problema é representada pelo interesse do usuário nas categorias de turismo e localização; já a da solução, representa as características do ponto de interesse.

A recuperação de casos é feita quando a recomendação é solicitada pelo usuário. Os casos são recuperados da base através do cálculo de similaridade global dos casos, que é calculada através da similaridade local atributo-valor, utilizando o algoritmo de média ponderada dos k-*Nearest Neighbours*.

No cálculo de similaridade é levado em consideração o nível de interesse do usuário nas categorias (cultural, ecológico, gastronômico, compras e religioso), a localização e raio de abrangência das recomendações. Primeiramente, os casos são recuperados das API´s Google Places e Floria Trip, sendo posteriormente adicionados à base de casos implementada. Entretanto, os casos utilizados para recomendação são

originados diretamente da base de casos. A seguir, a estratégia utilizada na recuperação dos casos nas bases Google Places, Floripa Trip e na própria base de casos é apresentada.

Na Tabela 1 tem-se um exemplo de cálculo de similaridade para os casos armazenados na base. Ressalta-se que a similaridade para a distância é calculada recuperando a distância entre a localização do usuário e a do ponto de interesse, e posteriormente o menor destes valores é dividido pelo maior valor. Isto porque, o raio é calculado em linha reta, e a distância é calculada através do trajeto viário até o ponto.

Tabela 1. Similaridade entre os casos, considerando a base de casos

Atributo	Problema Pesquisado	Caso 1	Caso 2	Caso 3	Peso	Sim Caso1	Sim Caso2	Sim Caso3
Cultural	100	75	95	100	1	0,75	0,95	1
Ecológico	40	80	45	40	1	0,5	0,89	1
Gastronômico	75	60	70	75	1	0,8	0,93	1
Compras	10	35	20	10	1	0,29	0,5	1
Religioso	40	20	35	40	1	0,5	0,88	1
Distância/R	1 Km	1,5 Km	0,7 Km	1 Km	1	0,66	1	1
					Sim. Global	0,58	0,69	1

A similaridade para a distância é calculada da seguinte forma: se a distância até o local estiver dentro do raio de abrangência estipulado no momento da recomendação, a similaridade é 1, caso contrário, o raio é dividido pela distância, obtendo o valor de similaridade. Os casos retornados são enviados ao usuário no formato de recomendações.

Na recuperação dos casos na base de dados do Google Places e do Floripa Trip, os casos são recuperados através da consulta em ambas as bases por pontos de interesse, classificando-os nas categorias de interesse, e organizando os casos em memória e atribuindo similaridade, conforme mostra a Tabela 2.

Tabela 2. Similaridade entre os casos, considerando as bases Google Places e Floripa Trip

Atributo	Problema Pesquisado	Caso 1	Caso 2	Caso 3	Peso	Sim Caso1	Sim Caso2	Sim Caso3
Cultural	100	0	0	100	1	0	0	1
Ecológico	40	0	100	0	1	0	0,4	0
Gastronômico	75	0	0	0	1	0	0	0
Compras	10	100	0	0	1	0,1	0	0
Religioso	40	0	0	0	1	0	0	0
Distância/R	1 Km	2 Km	0,5 Km	1,5 Km	1	0,5	1	0,67
					Sim. Global	0,1	0,23	0,27

A diferença na recuperação dos casos da base Google Places em relação a base de casos, está no fato de que somente a similaridade da classificação do ponto de interesse é calculada como 100% e as demais preenchidas com 0%, pois não há informações a respeito das demais categorias.

O valor da similaridade para a distância é calculado da mesma forma que os casos retornados da base de casos. Os casos retornados são adicionados à base de casos.

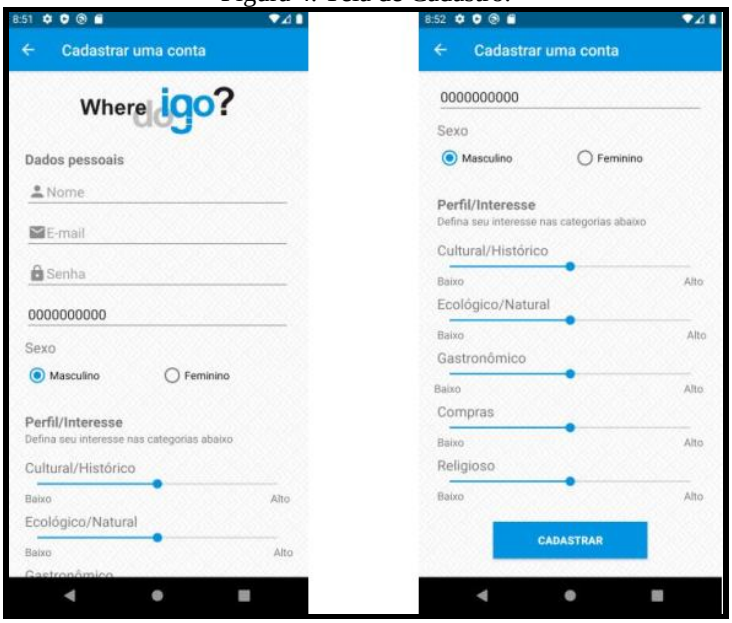
A reutilização de casos é feita de forma inalterada, ou seja, não há modificações na parte da solução do problema. Desta forma, não existe a necessidade de implementação do método de reutilização.

A revisão dos casos ocorre através do *feedback* do usuário em relação aos itens recomendados. Isto ocorre de forma implícita, quando o usuário adiciona a recomendação à lista de interesse na Visitação. Quando isto acontece, supõe-se que a recomendação foi considerada positiva e está pronto para passar para a fase de retenção. A retenção de casos inicia quando o caso passa pela fase de revisão. Desa forma, o caso que já está na base de casos é marcado como validado.

4.2 A INTERFACE DO USUÁRIO

O *frontend* criado para os usuários, é apresentado nas telas à seguir. A Figura 4 apresenta a tela de Cadastro, na qual o usuário efetua o cadastro no sistema. A mesma tela é apresentada quando o usuário edita o perfil, sendo que o campo email aparece desabilitado para a edição.

Figura 4. Tela de Cadastro.



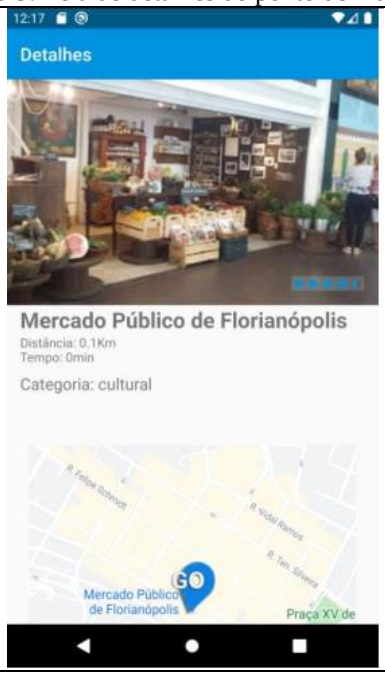
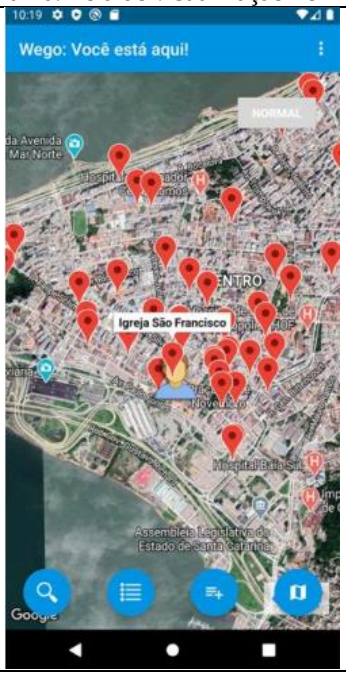
A Figura 5 apresenta a tela de login, que é exibida quando o usuário deseja efetura o login no sistema. Já a Figura 6, apresneta a tela que é exibida após o usuário efetura o login no sistema e antes do usuário solicitar as recomendações.

Figura 5. Tela de Login	Figura 6. Tela inicial de recomendação
	

A Figura 7 apresenta a tela de recomendações que é exibida quando o usuário solicita recomendações. Já a Figura 8, apresenta o layout da tela que é exibida quando o usuário acessa suas recomendações adicionadas a lista “Minha Lista”.

Figura 7. Tela de Recomendações	Figura 8. Tela relativa ao Interesse na Visitação
	

A Figura 9 apresenta mostra a tela que é exibida quando o usuário solicita detalhes de um ponto de interesse em específico. É utilizada uma tela similar a tela de detalhes de pontos de interesse do Google Maps. A Figura 10 apresenta o layout da tela que é exibida quando o usuário acessa a suas recomendações no Mapa.

Figura 9. Tela de detalhes do ponto de interesse	Figura 10. Tela de visualização no mapa.
	

5 CONSIDERAÇÕES FINAIS

O sistema desenvolvido, teve por base o conceito de Raciocínio Baseado em Casos, o qual se mostrou bstante dinâmico, apresentando diversas técnicas para a representação de dados e cálculo da similaridade. Á técnica utilizada depende da natureza do problema e na forma com que o conhecimento é adquirido. Da mesma forma, as fases do ciclo de RBC podem ser adaptadas e utilizarem diferentes abordagens, dependendo do tipo de problema que se busca resolver.

Este sistema como um todo consiste em um *backend*, uma API Rest, responsável por gerar as recomendações, e um frontend, que é um aplicativo desenvolvido para a plataforma Android, responsável por capturar o perfil e localização do usuário, solicitar as recomendações à API , e apresentá-las ao usuário.

O sistema foi validado junto a um grupo de onze usuários, que o utilizaram para buscar pontos de interesse em Florianópolis. Após o uso do aplicativo, os usuários responderam a uma enquete e os resultados foram satisfatórios. A maioria dos

participantes encontraram atrativos que estavam de acordo com o seu interesse. Isso mostra que o sistema obteve sucesso na recomendação de pontos de interesse de acordo com o perfil do usuário.

Foi possível observar que o mecanismo de cálculo da similaridade utilizado para ranquear as recomendações se mostrou eficiente, permitindo apresentar os itens de recomendação na ordem de interesse dos usuários.

A fim de dar continuidade ao estudo e desenvolvimento do Sistema, recomenda-se como melhorias: otimizar o mecanismo de recomendação RBC; aprimorar a classificação dos atrativos; aumentar a área de abrangência das recomendações; levar em consideração fatores climáticos, horários de funcionamento e custo nas recomendações; aprimorar as informações de detalhes de itens de recomendação; inserir mecanismo de avaliação de recomendações; otimizar o consumo de API's; aplicar design e usabilidade ao aplicativo; contemplar na base de recomendações eventos, vida noturna, aventura, rural e atividades; criar um histórico de deslocamento e visitação.

E como áreas de pesquisa sobre o tema, recomenda-se: busca de eventos e atividades em mídias sociais usando mineração de dados; buscar implementações de RBC comerciais e avaliar o desempenho e assertividade de recomendações; avaliação de pontos de interesse através de mineração em redes sociais; utilização de *chatbot* para a interface com o usuário criando um assistente em tempo real; criação de itinerários personalizados levando em conta o deslocamento no trânsito; utilização de dados históricos para predição de demandas; coleta de dados de comportamento do turista para posterior análise de big data gerando relatórios para a administração pública.

REFERÊNCIAS BIBLIOGRÁFICAS

AAMONDT, A.; PLAZA, E. Case-based reasoning: foundational issues, methodological variations, and system approaches. In: **AI Communications**, Spain, 1994. **Proceedings**...Spain: IDS Press, v. 7:1, p. 39-59, 1994. DOI: 10.3233/AIC-1994-7104.

AMEEN, A. Knowledge based Recommendation System in Semantic Web: A Survey. **International Journal of Computer Applications** (0975-8887), New York, v. 182, n. 43, p. 20-25, 2019. DOI: 10.5120/ijca2019918538 .

BAHRAMIAN, Z.; ABBASPOUR, R.A.; CLARAMUNT, C. Toward Geospatial Collaborative Tourism Recommender Systems. In: CHAUDHURI, S; NILANJAN RAY, N. **GIS Applications in the Tourism and Hospitality Industry.** IGN Global, 2018. p. 212-248. DOI: 10.4018/978-1-5225-5088-4.ch010

BORRÁS, J.; MORENO, A; VALLS, A. Intelligent tourism recommender Systems: A survey. **Expert Systems with Applications**, Elsevier, v. 41, n. 16, p. 7370-7389, 2014. DOI: 10.1016/j.eswa.2014.06.007.

CHOE, Y.; STIENMETZ, J.; FESENMAIER, D. R. Smart Tourism and Smart Destinations. **The SAGE International Encyclopedia of Travel and Tourism, Thousand Oaks**: Sage Publications, p. 1125-1129, 2017. DOI: 10.4135/9781483368924.n413.

DUBOIS, D.; PRADE, H. **Handbook of Research on Fuzzy Information Processing in Databases**. Hershey: IGI Global, 2008. Disponível em: <https://www.igi-global.com/chapter/handling-bipolarqueries-fuzzy-information/20350>. Acessado em: 24 de abril de 2019.

GOTTAPU, R.D.; MONANGI, L.V.S. Point-Of-Interest Recommender System for Social Groups. **Procedia Computer Science**, Elsivier, v. 114, p. 159-164, 2017. DOI: 10.1016/j.procs.2017.09.020.

GRETZEL, U., SIGALA, M., XIANG, Z. et al. Smart tourism: foundations and developments. **Electron Markets** 25, 179–188 (2015). DOI: 10.1007/s12525-015-0196-8

ICHWANI, A.; SUPRAPTO, S. Cased Based Reasoning to Identify Cause Conflicts in Marriage. **IJCCS: Indonesian Journal of Computing and Cybernetics Systems**, v. 13, n. 1, p. 1-10, 2019. DOI: 10.22146/ijccs.24861.

ISINKAYE, F.O.; FOLAJIMI, Y.O.; OJOKOH, B.A. Recommendation Systems: Principles, methods and evaluation. **Egyptian Informatics Journal**, v. 16, n. 3, p. 261-273, 2015. DOI: 10.1016/j.eij.2015.06.005

KESORN, K.; JURAPHANTHONG, W.; SALAIWARAKUL, A. Personalized Attraction Recommendation System for Tourists through Check-in Data. **IEEE Access: Institute of Electrical and Electronics Engineers**, v. 5, p. 26703-26721, 2017. DOI: 10.1109/ACCESS.2017.2778293.

KLOTZ, B.; LISENA, P., L.; TRONCY, R.; WILMS, D.; BONNET, C. Drivescover: A Tourism Recommender System Based on External Driving Factors. In: 16th Internaticional Semantic Web Conference, 2017. Vienna. **Proceedings...** França: EURECOM; Germany: BMW Research, 2017. Disponível em: https://www.researchgate.net/publication/322896234_DrIveSCOVER_A_Tourism_Recommender_System_Based_on_External_Driving_Factors>. Acessado em: 26 de abril de 2019.

KOMNINNOS, N.; PALLOT, M.; SCHAFFERS, H. Special Issue on Smart Cities and the Future Internet in Europe. **Journal of the Knowledge Economy**, v. 4, n.2, p. 119-134, 2012. DOI: 10.1007/s13132-012-0083-x

LIMA, A. M. **Um Sistema de Recomendação de Lugares Baseado em Localização e Perfil**. Monografia de Sistemas de Informação, Universidade Federal do Sergipe: 2016. Disponível em: <https://www.sigaa.ufs.br/sigaa/verProducao?idProducao=1155155&&key=526226b692e22bc1c9ecd9912f38b8f1>. Acesso em: 08 de maio de 2019.

LU, J.; BAI, D.; ZHANG, N.; YU, T.; ZHANG, X. Fuzzy Case-Based Reasoning System. **Applied Sciences**, v. 6, n. 7, 2016. DOI: 10.3390/app6070189.

MOCHOLI, J.A.; JAEN, J.; KRYNICKI, K.; CATALA, A.; PICÓN, A; CADENAS, A. Learning semantically-annotated routes for context-aware recommendations on map navigation systems, **Applied Soft Computing**, v. 12, p. 3088-3098, 2012. DOI: 10.1016/j.asoc.2012.05.010.

MOHAMED, M. H.; KHAFAGY, M. H.; IBRAHIM, M. H. Recommender Systems Challenges and Solutions Survey, In**: International Conference on Innovative Trends in Computer Engineering (ITCE**), february, Egypt, 2019 **Procceding**... IEEE Xplore Digital Library, Canadá, 2019. DOI: 10.1109/ITCE.2019.8646645.

NEMADE, G.; DESHMANE, R.; THAKARE, P.; Patil, M.; Thombre, V.D. **Smart Tourism Recommender System**. IRJET-International Research Journal of Engineering and Technology, v. 04, n. 11, p. 601-603, 2017. Disponível em: <https://www.irjet.net/archives/V5/i6/IRJET-V5I648.pdf>. Acesso em: 26 de abril de 2019.

NORDLUND, N.; SCHÄFER, H. Master's Thesis in Computing Science, Umea University: **CaseBased Reasoning in a Support system**. 2006. Disponível em: <http://www8.cs.umu.se/education/examina/Rapporter/NordlundSchafer.pdf >. Acessado em: 27 de abril de 2019.

PAL, S. R.; SHIU, S. C. K. **Fundations of Soft Case-Based Reasoning**. 2004. Hoboken: John Wiley & Sons, 20047. Acessado em: 30 de abril de 2019. Disponível em: <https://cdn.preterhuman.net/texts/science_and_technology/artificial_intelligence/Foundations%20Of%20Soft%20Case-based%20Reasoning%20-%20SANKAR%20K.%20PAL.pdf>.

RASKOB, W.; MÖHRLE, S.; BAI, S. Knowledge database and case-based reasoning. **Radioprotection**, v. 51, p. 185-186, December 2016. DOI: 10.1051/radiopro/2016069.

REATEGUI, E. B; CAZELLA, S. C.; OSÓRIO, F. S. **Personalização de Páginas Webatravés dos Sistemas de Recomendação.** 2005. Disponível em: <http://osorio.wait4.org/publications/Reategui-et-al-IHC2006.pdf> - Acessado em: 12 de novembro de 2020.

RICCI, F.; ROKACH, L.; SHAPIRA. **Recommender Systems HandBook**. 2ª ed. New York: Springer, 2015. Acessado em: 17de abril de 2019. Disponível em: <https://edyaaleh.files.wordpress.com/2016/02/recommendersystemshandbook.pdf>.

RICHTER, M. M.; WEBER, R. O. **Case-Based Reasoning**: a textbook. Springer, 2013. Disponível em: <https://www.springer.com/br/book/9783642401664#>. Acesso em: 10 de maio de 2019.

ROOPESH, L.R.; TULASI, B. A Survey of Travel Recommender System. **International Journal of Computer Sciences and Engeneering Open Access**, Bengaluru, v. 6, n. 2347-2693, September 2018. DOI: 10.13140/RG.2.2.34775.32168.

RYNGKSAI, I.; CHAMEIKHO, L. Recommender Systems: Types of Filtering Techiniques. **International Journal of Engineering Researck & Technology**, Gujarat, v. 3, n. 2278-0181, p. 251- 254, November 2014. Disponível em: <https://www.ijert.org/research/recommender-systems-types-offiltering-techniques-IJERTV3IS110197.pdf>. Acesso em: 19 de abril de 2019.

SAPPAGH, S.; ELMOGY, M. Case Based Reasoning: Case Representation Methodologies. **International Journal of Advanced Computer Science and Applications**, Vol. 6, No. 11, 2015.

SOUZA, B.F.B. Dissertação de Mestrado, Pontifícia Universidade Católica do Rio de Janeiro: **Modelos de Fatoração Matricial para Recomendação de Vídeos**, 2012. DOI: 10.17771/PUCRio.acad.19273

SUMARDI, M.; JUFERY; FRENKY; WONGSO, R; LUWINDA, F. A. TripBuddy: Travel Planner with Recommendation based on User‘s Browsing Behaviour. In: **2nd International Conference on Computer Science and Computational Intelligence**, Indonesiam 2017. **Proceedings..** Indonesia: Procedia Computer Science, v. 116, p. 326-333, 2017. DOI: 10.1016/j.procs.2017.10.084

UMANETS, A.; FERREIRA, A; LEITE, N. GuideMe: A Tourist Guide with a Recommender System and Social Interaction. In: Conference on Electronics, Telecommunications and Computers, Lisboa 2013. **Proceedings..** Elsevier, v. 17, p. 407-414, 2014. DOI: 10.1016/j.protcy.2014.10.248.

UNWTO. World Tourism Organization. **Tourism:** an economic and Social phenomenon. 2019. Disponível em: <http://www2.unwto.org/content/why-tourism>. Acesso em: 27 de março de 2019.

VANSTEENWEGEN, P.; SOUFFRIAU, W.; BERGHE, G.V.; OUDHEUSDEN, D.V. The City Trip Planner: An expert system for tourists. **Expert Systems with Applications**, v. 38, n. 6, p. 6540-6546, June 2011. DOI: 10.1016/j.eswa.2010.11.085.

VON WANGENHEIM, A.; Von Wangenheim, C. e Rateke. **Raciocínio Baseado em Casos**. 2ª ed. Barueri: Manole. 2013.

WTTC, World Travel & Tourism Concil. **Economic Impact:** Brazil. 2018. Disponível em: <https://www.wttc.org/economic-impact/benchmark-reports/country-results/>. Acesso em: 27 de março de 2019

YU, Y; CHEN, X. A Survey of Point-of-Interest Recommendation in Location-Based Social Networks. 2015 AAAI Workshop. **Proceedings of ...** Disponível em: <https://www.aaai.org/ocs/index.php/WS/AAAIW15/paper/viewFile/10132/10253>. Acesso em: 26 de abril de 2019.