



**Rafael Oliveira
Mendonça**

**Recomendação de pontos de interesse baseada
em contexto, geolocalização e feedback implícito**

**Recommendation of points of interest based on
context, geolocation and implicit feedback**



**Rafael Oliveira
Mendonça**

**Recomendação de pontos de interesse baseada
em contexto, geolocalização e feedback implícito**

**Recommendation of points of interest based on
context, geolocation and implicit feedback**

Dissertação apresentada à Universidade de Aveiro para cumprimento dos requisitos necessários à obtenção do grau de Mestre em Engenharia de Computadores e Telemática, realizada sob a orientação científica do Doutor (José Manuel Matos Moreira), Professor auxiliar do Departamento de Eletrónica, Telecomunicações e Informática da Universidade de Aveiro.

Aos meus pais, Vitalina e Augusto.

o júri / the jury

presidente / president

Prof. Doutora Pétia Georgieva Georgieva

Professora Auxiliar da Universidade de Aveiro

vogais / examiners committee

Prof. Doutora Mariana Curado Malta

Professora Adjunta do Instituto Superior de Contabilidade e Administração do Porto

Prof. Doutor José Manuel Matos Moreira

Professor Auxiliar da Universidade de Aveiro

**agradecimentos /
acknowledgements**

Quero agradecer a todos os que me acompanharam ao longo desta jornada. À família Cruz, à Filipa, aos amigos de Mira, aos amigos que fiz nesta cidade e à Tuna Universitária de Aveiro. Agradeço ao professor José Moreira, que me orientou neste trabalho, estando sempre disponível e com bastante paciência.

Palavras Chave

sistema de recomendação, contexto, geolocalização, feedback implícito.

Resumo

Atualmente, a quantidade de informação existente dificulta o processo de seleção de informação relevante para o utilizador, devido à falta de conhecimento ou tempo por parte do mesmo. Deste modo foram desenvolvidos sistemas de recomendação com o intuito de auxiliar o utilizador na descoberta de informação útil. Existem diversas técnicas de recomendação que podem ser aplicadas dependendo do domínio em que o sistema se encontra inserido, dos objetivos do utilizador e da opinião fornecida por este. Os sistemas de recomendação tradicionais apenas consideram as entidades utilizador e item, ignorando a informação contextual, sendo que esta desempenha um importante papel na tomada de decisão dos utilizadores. Nesta dissertação são desenvolvidos dois métodos de recomendação orientados ao contexto, sendo um primeiro baseado na frequência contextual e o segundo na personalização. Para isto foram analisadas as técnicas de recomendação existentes, formas de inclusão do contexto no processo de recomendação e métodos de avaliação destes sistemas. Estes dois métodos foram instanciados e avaliados recorrendo à análise de um conjunto de dados referentes a visitas efetuadas por utilizadores a pontos de interesse na cidade de Nova Iorque (recolhidos no foursquare). Os dois métodos de recomendação relacionam a situação contextual no momento da recomendação com a frequência de visitas efetuadas aos pontos de interesse. No primeiro método são consideradas as visitas efetuadas por todos os utilizadores, já no segundo método apenas são consideradas as visitas efetuadas pelo utilizador que requer a recomendação. Para avaliação dos métodos propostos, foi usada a métrica de *hit-rate* e a métrica baseada no fator de decréscimo. Para além disto é efetuada uma comparação entre métodos utilizados e o método de dominância contextual desenvolvido em trabalhos anteriores. O método de dominância contextual supera a frequência contextual no caso em que a situação contextual é constituída por todas as dimensões, apresentando um erro menor e uma maior cobertura. O método baseado na frequência contextual supera o método baseado na personalização em termos de cobertura, contudo o erro é maior. Verifica-se também, que quanto maior for o nível de generalização dos pontos de interesse usado nos métodos de recomendação, maior é o erro e a cobertura. Os resultados obtidos através desta avaliação permitem obter a influência de cada dimensão contextual e o impacto do uso dos níveis hierárquicos nos métodos de recomendação.

Keywords

recommender system, context, geolocation, implicit feedback.

Abstract

Nowadays, the large amount of existing data makes the selection of relevant information difficult for the users. This way, recommendation systems were developed to assist users in finding useful information. There are several recommendation techniques that can be applied depending on the application domains, user's goals and preferences. Traditional recommendation systems only consider the data about users and items, ignoring context information that also plays a relevant role in decision making. In this work two context-oriented methods of recommendation are developed, one based on contextual frequency and a second one based on personalization. Existing recommendation techniques were analyzed, as well as how to consider context in the recommendation process and methods of evaluation of these systems. The two methods were instantiated and evaluated using datasets about visits of users to points of interest in New York City collected on foursquare. These methods rely on the relationship between the contextual status at the time of the recommendation and the frequency of visits made to the points of interest in similar contextual conditions. The first method considers the visits made by all users, and in the second one only uses the visits made by the user that requires the recommendation. The proposed methods are evaluated using a hit-rate metric and a metric based on a decreasing factor. The performance of these methods is compared with the performance of a method based on contextual dominance proposed in previous work. The performance of the method based on contextual dominance is better than the performance of the method based on contextual frequency when all dimensions defining the contextual status are used, presenting a smaller error and a greater coverage. The method based on the contextual frequency exceeds the performance method based on personalization in terms of coverage, but the error is greater. The results show that errors and coverage increase with the level of generalization of the points of interest used in the recommendation methods. The results obtained through this evaluation allow us to infer about the influence of each contextual dimension and the impact of the use of the hierarchical levels in the recommendation methods.

CONTEÚDO

CONTEÚDO	i
LISTA DE FIGURAS	iii
LISTA DE TABELAS	v
GLOSSÁRIO	vii
1 INTRODUÇÃO	1
1.1 Enquadramento	1
1.2 Objetivos	2
1.3 Estrutura	2
2 ESTADO DA ARTE	5
2.1 Sistemas de Recomendação	5
2.2 Contexto nos Sistemas de Recomendação	8
2.2.1 O que é o Contexto	8
2.2.2 Modelação do Contexto	8
2.2.3 Inclusão do Contexto no processo de Recomendação	10
2.3 Avaliação dos sistemas de Recomendação	11
2.3.1 Paradigmas de avaliação	12
2.3.2 Métricas de precisão	13
2.4 Aplicações	16
3 METODOLOGIA	19
3.1 Conceitos	20
3.2 Modelo Multidimensional de Recomendação	20
3.3 Processo de Recomendação	22
3.4 Dominância Contextual	23
3.5 Frequência Contextual	24
3.6 Personalização	25
4 CASO DE ESTUDO	27
4.1 Conjunto de dados	27
4.2 Entidades	29
4.3 Modelo multidimensional de recomendação	30
4.4 Tecnologias Aplicadas	33
5 AVALIAÇÃO EXPERIMENTAL	35
5.1 Objetivos e condicionantes do sistema	35
5.2 Metodologia	35
5.2.1 Segmentação do conjunto de dados	36

5.2.2	Métricas	36
5.2.3	Cenários e parâmetros de avaliação	36
5.3	Resultados	37
5.3.1	Dominância Contextual versus Frequência Contextual	37
5.3.2	Frequência Contextual Ponto de interesse, Subcategoria e Categoria	39
5.3.3	Personalização Subcategoria versus Categoria	41
5.3.4	Frequência Contextual versus Personalização	42
5.4	Discussão	44
6	CONCLUSÃO	47
	REFERÊNCIAS BIBLIOGRÁFICAS	49

LISTA DE FIGURAS

3.1	Cubo - Representação do espaço de recomendação orientado ao contexto	21
4.1	Modelo Multidimensional de recomendação	31
4.2	Taxonomia - Ponto de Interesse	31
5.1	Erro médio das recomendações referentes aos métodos dominância e frequência contextual.	39
5.2	Erro médio associado a recomendações obtidas pela frequência contextual tendo em conta o ponto de interesse, subcategoria e categoria.	40
5.3	Erro médio associado a recomendações por subcategoria e categoria.	42
5.4	Erro médio associado a recomendações por subcategoria nos métodos de frequência contextual e de personalização.	43
5.5	Erro médio associado a recomendações por categoria nos métodos de frequência contextual e de personalização.	43

LISTA DE TABELAS

2.1	Matriz de confusão	14
4.1	Informação estatística do conjunto de dados	28
5.1	Dominância Contextual - Ponto de Interesse	38
5.2	Frequência Contextual - Ponto de Interesse	38
5.3	Frequência Contextual - Subcategoria	40
5.4	Frequência Contextual - Categoria	40
5.5	Personalização - Subcategoria	41
5.6	Personalização - Categoria	41

GLOSSÁRIO

ARHR	<i>Average Reciprocal Hit Rate</i>
CSV	<i>Comma-Separated Values</i>
DCG	<i>Discount Cumulative Gain</i>
DFM	<i>Dimensional Fact Model</i>
HR	<i>Hit-Rate</i>
IDCG	<i>Ideal Discount Cumulative Gain</i>
JSON	<i>JavaScript Object Notation</i>
MAE	<i>Mean Absolute Error</i>
MSE	<i>Mean Squared Error</i>
NDCG	<i>Normalized Discount Cumulative Gain</i>
NMAE	<i>Normalized Mean Absolute Error</i>
NRMSE	<i>Normalized Root Mean Squared Error</i>
OLAP	<i>Online Analytical Processing</i>
RMSE	<i>Root Mean Squared Error</i>
SNAP	<i>Stanford Network Analysis Project</i>
SVM	<i>Support Vector Machine</i>
UTC	<i>Universal Time Coordinated</i>

INTRODUÇÃO

1.1 ENQUADRAMENTO

Vivemos numa época onde a informação é de fácil acesso, pois devido à evolução tecnológica é possível a partilha e acesso desta informação através de diversos dispositivos em qualquer parte do globo. Desta facilidade de partilha advém uma enorme quantidade de informação gerada por cada um de nós, que resulta num excesso de informação que inunda os utilizadores. Devido a esta quantidade de informação, os sistemas de informação retornarão um enorme conjunto de resultados, onde o utilizador deve ser capaz de filtrar a informação que lhe é relevante. De forma a que esta filtragem seja possível o indivíduo deve possuir capacidades de análise e julgamento a fim de selecionar o que lhe convém. Ora isto nem sempre é possível devido ao fato da falta de conhecimento, ou tempo, pois este torna-se um processo longo.

Assim de forma a contornar este excesso de informação, são necessárias ferramentas que auxiliam o indivíduo no processo de filtragem da informação. Estas ferramentas são designadas de sistemas de recomendação e como o próprio nome indica fornecem recomendações baseadas nos interesses e necessidades de quem as requisita.

Estes sistemas servem-se assim de perfis criados com base nos comportamentos prévios dos indivíduos de forma a fornecerem recomendações. Estes perfis podem conter os interesses e necessidades do indivíduo assim como os seus dados demográficos (Gavalas et al., 2014). A recomendação é tipicamente apresentada na forma de uma lista que contém os itens relevantes ao utilizador, ou através de uma previsão do quão relevante é um item para este utilizador. Desta forma a recomendação de itens ajuda o utilizador na descoberta de itens relevantes.

Inicialmente, com o crescimento do comércio eletrónico, estes sistemas tinham como função, auxiliar os clientes na escolha de produtos relevantes, perante um grande conjunto de produtos apresentados aos mesmos (noticias, livros, etc). Mais tarde na área de turismo, estes sistemas foram usados com o intuito de auxiliar o utilizador, recomendando viagens, atividades e pontos de interesse de acordo com as suas preferências e restrições impostas (Kabassi, 2010; Werthner and Ricci, 2004). Hoje em dia podemos encontrar estes sistemas incorporados em sites que exibem um enorme conjunto de itens pertencentes a diversos domínios, (Youtube, Netflix) (Gouin-Vallerand and De La Cruz, 2013).

A maior parte destes sistemas de recomendação tem apenas em conta as entidades *Utilizador* e *Item* ignorando a informação contextual associada. Em alguns domínios como por exemplo o turismo,

é essencial integrar a informação contextual no processo de recomendação como forma de recomendar itens a utilizadores para um determinado contexto. Assim, as recomendações apresentadas podem diferir de acordo com condições de contexto, como a estação do ano. Por exemplo no inverno podem ser recomendadas estâncias de esqui e no verão recomendadas praias. Estes sistemas adaptam assim as recomendações a uma situação específica em que os itens serão consumidos, colmatando a limitação apresentada nos sistemas tradicionais.

1.2 OBJETIVOS

O projeto proposto tem como objetivo determinar a influência das dimensões contextuais e, do uso dos níveis hierárquicos nas recomendações obtidas. Desta forma procedeu-se à exploração de métodos e análise de dados relacionados com a recomendação orientada ao contexto tendo em conta a geolocalização e opinião implícita por parte do utilizador. Para a instanciação e avaliação destes métodos, foi selecionado um conjunto de dados obtidos pela rede social baseada em localização *Foursquare*. Este conjunto de dados contém visitas efetuadas por utilizadores a pontos de interesse, tendo associadas a si uma localização e uma marca temporal bem definidas. Após esta recolha de dados, a cada visita foi adicionada a informação contextual correspondente através da sua localização e marca temporal. Por fim os métodos de recomendação propostos foram avaliados recorrendo a um conjunto de métricas.

1.3 ESTRUTURA

O resto do documento encontra-se estruturado da seguinte forma:

Estado de arte. Neste capítulo são abordadas as técnicas utilizadas nos sistemas de recomendação. É apresentado o significado do contexto e como este se enquadra nos sistemas de recomendação atuais. Para além disto são apresentados protocolos de avaliação e métricas utilizadas nestes protocolos, sendo por fim apresentados alguns sistemas de recomendação existentes no domínio turismo.

Metodologia. Este capítulo apresenta o problema em causa assim como os métodos de recomendação abordados para a resolução deste. Os dois primeiros métodos baseiam-se na popularidade dos pontos de interesse e o terceiro método baseia-se na personalização. Por fim, é mostrada a modelação de dados abordada de forma a integrar a informação contextual no processo de recomendação.

Caso de estudo. Neste capítulo é apresentada a instanciação do problema descrito na metodologia, sendo apresentado o conjunto de dados considerado para o caso de estudo, os processos de pré-processamento, a extração de informação e enriquecimento de dados. Para além disto são caracterizadas as entidades de acordo com o caso de estudo e é apresentada instanciação do modelo de dados.

Avaliação experimental. Neste capítulo é abordada a metodologia utilizada para avaliação dos métodos de recomendação, descrevendo a estratégia de segmentação do conjunto de dados e as métricas utilizadas para avaliação destes métodos. São também apresentados os cenários de teste propostos para avaliação dos métodos, assim como os resultados obtidos e respectiva discussão.

Conclusão. Neste capítulo são apresentadas as conclusões relativas a esta dissertação, apresentando o contributo obtido através da realização desta. Por fim é feita referência a possível trabalho futuro com base no apresentado.

ESTADO DA ARTE

Hoje em dia, com a abundância de informação existente, a tarefa de um utilizador encontrar informação relevante é na maior parte das vezes dispendiosa. Os sistemas de recomendação vieram assim facilitar esta interação, proporcionando ao utilizador recomendações baseadas nas suas preferências e interesses.

2.1 SISTEMAS DE RECOMENDAÇÃO

Os sistemas de recomendação têm como objetivo sugerir itens que se adequam ao utilizador com base nas preferências e restrições impostas por este. Face à falta de conhecimento ou tempo por parte do utilizador, os sistemas auxiliam o utilizador na descoberta de itens que lhe sejam úteis. De entre um conjunto de itens, o sistema determina assim a utilidade de cada item, recomendando o item com maior utilidade, ou apresentando uma lista de itens ordenada pela sua utilidade.

Adomavicius and Tuzhilin (2005b) apresentam uma definição formal do sistema de recomendação, sendo que é esta a definição levada em conta neste projeto. Dado um utilizador u pertencente ao conjunto de utilizadores U e dado um item i pertencente ao conjunto de itens I , a função utilidade u , que define o valor que o item i tem para o utilizador u é dada por:

$$u : U \times I \rightarrow \text{Avaliação} \quad (2.1)$$

Dado que apenas algumas avaliações são conhecidas no espaço de recomendação, o problema do sistema de recomendação consiste na extrapolação de avaliações para todo o espaço de recomendação.

Nos sistemas de recomendação, a utilidade de um item para um utilizador é representada pela avaliação efetuada por este. Esta avaliação pode ser determinada através da opinião explícita do utilizador relativa ao item, ou pode ser determinada implicitamente através da análise comportamental do mesmo. No caso em que a opinião é explícita, o utilizador é solicitado a avaliar o item recorrendo a uma escala de classificação. Esta escala pode ser quantitativa, onde o intervalo pode ser contínuo ou discreto, ou pode ser qualitativa obedecendo a uma determinada ordem (ordinal).

No caso onde a opinião é implícita, a avaliação do utilizador é obtida através da análise do comportamento deste, recorrendo por exemplo às compras efetuadas, ao tempo em que este esteve numa página web ou ao número de vezes que ouviu uma determinada música. Embora esta última abordagem seja menos invasiva, esta traz algumas desvantagens. Através desta aproximação não é possível deduzir quais os itens que o utilizador não gosta. Para além disto a análise comportamental pode não ser clara, pois o utilizador pode ter comprado um certo item e não ter gostado deste (Hu et al., 2008).

A informação sobre o utilizador, o tipo de item a recomendar e a forma como o utilizador fornece a sua opinião, são fatores importantes na escolha da técnica de recomendação a utilizar. Adomavicius and Tuzhilin (2005b) consideram três técnicas de recomendação, nomeadamente a filtragem por conteúdo, filtragem colaborativa e a híbrida. Burke (2007) estende esta classificação, sendo que será aqui também referenciada a filtragem baseada no conhecimento.

Filtragem por conteúdo. Na filtragem por conteúdo, a recomendação de itens é feita com base na semelhança entre os itens a recomendar e os itens já avaliados pelo utilizador. Nesta abordagem, cada item é composto por um conjunto de características que o definem. O utilizador tem associado a si um perfil que contém os seus gostos e preferências. Este perfil é construído com base na análise das características de cada item avaliado pelo utilizador. A recomendação passa assim por determinar a semelhança entre as características dos itens a recomendar e o perfil do utilizador, dado que os itens com maior grau de semelhança serão os recomendados (Adomavicius and Tuzhilin, 2005b). Visto que esta técnica baseia-se nas características dos itens, é necessária a extração destas, de forma a construir o perfil do utilizador e efetuar recomendações. Embora este processo de extração possa ser automatizado no caso de itens textuais, como por exemplo documentos e páginas web, não se torna tão fácil a extração para itens multimédia (áudio ou vídeo), sendo necessário recorrer a especialistas no domínio para a extração de características, tarefa esta que se torna dispendiosa para um elevado número de itens. Outra das limitações é denominada de super-especialização. Visto que esta técnica só permite recomendar itens com elevado grau de semelhança, os itens recomendados futuramente serão muito parecidos com os já recomendados, ou seja o sistema nunca recomendará nada de novo ao utilizador. Por fim é necessário que o utilizador avalie um número considerável de itens para que o sistema deduza as suas preferências efetivamente. Caso isto não aconteça o utilizador receberá recomendações pouco relevantes. Esta limitação é conhecida como o problema de novo utilizador, sendo um dos problemas que fazem parte do *cold-start*, também presente na técnica de filtragem colaborativa (Burke, 2007; Aggarwal, 2016).

Filtragem Colaborativa. Na filtragem colaborativa, não é necessária a caracterização dos itens de forma a obter recomendações. Estas são obtidas através da correlação entre utilizadores com base nos seus gostos, ou através da correlação entre itens com base no seu consumo por parte dos utilizadores. Para além disto, nesta aproximação o utilizador não necessita de um perfil explícito, visto que o seu perfil é refletido através do seu histórico (Bellogín, 2012). Esta técnica de recomendação pode ser baseada em modelo ou baseada em memória. Nas aproximações baseadas em modelo, são desenvolvidos modelos estatísticos determinando padrões entre os pares utilizador e item, com o objetivo de determinar a utilidade do item. Outros modelos são criados à base da fatorização de matrizes que permitem a redução do espaço de recomendação, obtendo os fatores latentes que relacionam o utilizador e o item (Hu et al., 2008). Os modelos baseados em memória são também referidos como modelos baseados em vizinhança, pois a utilidade dos itens é determinada através desta vizinhança, que pode ser construída com base nos utilizadores ou nos itens. Na primeira aproximação, as avaliações

efetuadas pelos utilizadores com gostos semelhantes ao utilizador alvo, são usadas para determinar a utilidade dos itens a serem recomendados. Os utilizadores com gostos semelhantes ao utilizador alvo são designados por vizinhos, formando assim uma vizinhança com este (Aggarwal, 2016). Na última aproximação, são determinados padrões de consumo dos itens por parte dos utilizadores. Esta aproximação foi introduzida de forma a contornar o problema de escalabilidade na recomendação. Ou seja, à medida que o número de utilizadores aumenta no sistema, o esforço computacional para definir a vizinhança entre utilizadores também aumenta. A *Amazon* faz uso desta técnica no seu sistema de recomendação (Linden et al., 2003).

Para além da aproximação baseada em memória ser de fácil implementação, é ainda possível gerar uma explicação para cada item recomendado através da análise do histórico dos utilizadores. Contudo estes métodos não são efetivos no caso onde o espaço de recomendação é esparso (Su and Khoshgoftaar, 2009). Outras limitações que põem em causa o rigor da recomendação são, a introdução de novos utilizadores e a introdução de novos itens no sistema. Tal como acontece os sistemas de recomendação baseados no conteúdo, o utilizador é obrigado a classificar uma série de itens de modo a que o sistema possa oferecer recomendações relevantes. O problema dos novos itens, refere-se à quantidade de utilizadores que os classificam até estes poderem ser recomendados (Adomavicius and Tuzhilin, 2005b).

Filtragem Baseada no Conhecimento. Esta aproximação é normalmente aplicada nos domínios onde os itens são complexos e raramente avaliados. Nestes casos, é preferível que o utilizador tenha controlo no processo de recomendação impondo assim restrições. Através do conhecimento sobre os itens e utilizadores, são inferidas relações entre as necessidades destes e possíveis recomendações (Burke, 2007; Pu et al., 2012). Visto que esta aproximação se baseia nas restrições impostas pelo utilizador e no conhecimento acerca das características dos itens, não existe o problema de *cold-start*, sendo esta técnica muitas das vezes complementar às técnicas de filtragem colaborativa e por conteúdo (Aggarwal, 2016). Contudo, para que sejam fornecidas recomendações é necessária a aquisição do conhecimento sobre os itens existentes, o mapeamento entre as necessidades do utilizador e os itens que as possam satisfazer e por fim, obter conhecimento acerca do utilizador (Burke, 2002).

Híbridos. Nesta aproximação são combinadas múltiplas técnicas de recomendação de forma obter alguma sinergia entre estas. Através da combinação destas técnicas é possível contornar as lacunas existentes em cada uma, como por exemplo o problema de *cold-start* presente na filtragem colaborativa e nos sistemas baseados no conteúdo (Burke, 2002). Adomavicius and Tuzhilin (2005b) apresentam quatro formas de relacionar a filtragem baseada em conteúdo e a filtragem colaborativa. Em Burke (2002) são apresentadas sete aproximações para a criação de sistemas híbridos. Na primeira aproximação são combinadas as características inerentes às fontes de dados utilizadas por cada técnica. Na segunda aproximação, o processo de recomendação é efetuado por etapas, onde as características obtidas na primeira etapa servem de entrada para a técnica de recomendação presente na segunda etapa. Na terceira aproximação, a pontuação de cada item resulta de uma soma pesada das pontuações obtidas por cada técnica de recomendação. A quarta aproximação, baseia-se na escolha da técnica mais apropriada para a geração de recomendações de acordo com a informação obtida e o objetivo destas recomendações. No quinto caso, são apresentados ao utilizador os itens recomendados por cada técnica de recomendação. No sexto caso, as técnicas de recomendação estão dispostas em cascata, permitindo assim refinar as recomendações. No último caso, é criado um modelo de recomendação através da primeira técnica que será utilizado pela segunda.

2.2 CONTEXTO NOS SISTEMAS DE RECOMENDAÇÃO

Os sistemas de recomendação tradicionais sugerem itens com base nos interesses do utilizador, ignorando a informação contextual. Apesar dos interesses de cada utilizador não se alterarem ao longo do tempo, a avaliação de um item pode ser influenciada por vários fatores adicionais, sendo que em certos domínios, um mesmo item pode proporcionar experiências diferentes consoante o contexto em questão (Baltrunas and Ricci, 2009). Por exemplo no domínio turístico, a experiência de visitar um jardim zoológico é completamente diferente se for num dia chuvoso ou num dia solarengo.

2.2.1 O QUE É O CONTEXTO

O contexto é um conceito estudado e usado em várias áreas, como a Ciência da Computação, Filosofia e Psicologia. É um conceito complexo e multifacetado, visto que a cada área lhe é atribuída uma definição. No dicionário Priberam¹ o termo contexto é definido como um conjunto de circunstâncias que rodeiam um acontecimento.

Centrando agora no caso dos sistemas de recomendação e nas suas áreas envolventes. Em exploração de dados, o contexto refere-se a eventos que caracterizam e determinam para um dado sujeito, as preferências deste. Já na área do comércio eletrónico, o contexto representa a intenção de compra por parte do utilizador, separando assim os contextos de acordo com o propósito da compra. Por exemplo a compra pode ser efetuada com o intuito de oferta, sendo que esta pode ter diferentes alvos, como a namorada ou os pais, contudo a compra pode ser efetuada para o utilizador que requer a recomendação (Palmisano et al., 2008).

Dey (2001) define o contexto como qualquer informação que possa ser utilizada para caracterizar a situação de uma entidade, onde esta entidade pode ser uma pessoa, lugar ou objeto relevante na interação do utilizador com o sistema, incluindo o utilizador e o sistema. O mesmo autor refere ainda que um sistema orientado ao contexto, tem como objetivo fornecer informação relevante ao utilizador com base no contexto, sendo esta relevância dependente da tarefa do utilizador.

Dourish (2004) introduz duas visões sobre o contexto, a visão representativa e a interativa. Na primeira, o contexto é visto como um tipo de informação definido e estável, independente da atividade, podendo ser descrito, através de um conjunto de atributos definidos à priori (Abbar et al., 2009). Na visão interativa, o contexto é caracterizado dinamicamente, pois nesta visão, a relação entre o contexto e a atividade é cíclica, ou seja, o contexto surge da atividade mas também a influencia (Anand and Mobasher, 2007).

2.2.2 MODELAÇÃO DO CONTEXTO

O objetivo dos sistemas de recomendação é estimar a avaliação para itens que ainda não foram avaliados pelo utilizador.

$$u : U \times I \rightarrow \text{Avaliação}$$

¹www.priberam.pt

É de salientar que estes sistemas não consideram algum tipo de informação contextual. Como os sistemas de recomendação orientados ao contexto estimam as avaliações tendo em conta a informação contextual, incorporando o contexto C nesta função, temos que:

$$u : U \times I \times C \rightarrow \text{Avaliação} \quad (2.2)$$

Sendo C representado pelas dimensões contextuais (tempo, localização entre outras), o resultado da função avaliação representa o conjunto avaliações efetuadas pelo conjunto utilizadores ao conjunto de itens num dado contexto.

Seguindo a taxonomia de Dourish, Adomavicius and Tuzhilin (2015) classificam os sistemas de recomendação orientados ao contexto com base em dois aspetos, o conhecimento dos fatores contextuais por parte do sistema de recomendação e a alteração destes fatores ao longo do tempo. Em relação ao primeiro aspeto são representadas três situações, na primeira o contexto é totalmente definido, isto é, a sua estrutura e os seus valores são explícitos. Na segunda o contexto é parcialmente definido (só parte da informação contextual é explícita) e na terceira o contexto é desconhecido. O segundo aspeto refere-se ao fato do contexto ser estático – as características contextuais e a estrutura são imutáveis – ou dinâmico – podendo adicionar ou remover fatores contextuais e alterar a estrutura associada a estes fatores. Destas dois aspetos base, resultam seis tipos de sistemas de recomendação, onde num dos extremos o contexto é estático e totalmente explícito e no outro extremo o contexto é dinâmico e implícito. Neste projeto será dada maior importância à visão representativa, onde o contexto é explícito e imutável.

O contexto pode ser composto por diversos aspetos contextuais, onde cada um destes define uma particularidade deste. Cada um destes aspetos pode ter associado a si uma estrutura complexa, refletindo assim a complexidade da informação contextual. Como forma de modelar esta informação contextual, habitualmente recorre-se a uma estrutura hierárquica. Esta estrutura pode ser representada através de duas formas. Na primeira, a informação contextual é definida através de um conjunto de K dimensões contextuais. Cada dimensão contextual é composta por um conjunto de q atributos, $K = K^1, \dots, K^q$, onde a abstração converge para o nível K^q (Adomavicius and Tuzhilin, 2001; Palmisano et al., 2008). Na segunda, a informação contextual é representada através do modelo de dados multidimensional utilizado em aplicações *Online Analytical Processing* (OLAP). A grande diferença entre estes dois tipos de modelação, reside no facto de que no último caso a informação é definida através hierarquias OLAP, enquanto no primeiro caso a hierarquia é generalizada, podendo ser representada através de árvores, grafos entre outros tipos de taxonomias (Aggarwal, 2016).

Sendo o contexto definido à priori e tendo associada uma estrutura imutável, torna-se necessária a identificação e aquisição da informação contextual. A informação contextual pode ser obtida explicitamente, onde o sistema interage com os utilizadores e outras fontes de informação como forma de adquirir a informação contextual. Esta informação também pode ser obtida de forma implícita através do meio (Palmisano et al., 2008; Abbar et al., 2009), ou pode ser deduzida através de meios estatísticos ou técnicas utilizadas no campo da exploração de dados (Adomavicius and Tuzhilin, 2010, 2015).

Nem todos os fatores contextuais adquiridos pelo sistema são relevantes ou úteis de acordo com o propósito da recomendação, onde a relevância destes fatores pode variar consoante o domínio em que esta recomendação é aplicada. Assim, a escolha dos fatores contextuais pode ser feita recorrendo a especialistas no domínio em que o sistema está inserido ou através de uma abordagem computacional,

onde estes fatores são selecionados através de métodos estatísticos ou técnicas utilizadas em exploração de dados (Adomavicius and Tuzhilin, 2010). Em Adomavicius and Tuzhilin (2001), o conjunto de fatores contextuais é determinado recorrendo a especialistas, sendo de seguida aplicados testes estatísticos com o objetivo de identificar quais os fatores realmente relevantes. Baltrunas et al. (2012) obtêm a relevância dos fatores contextuais através da realização de um inquérito. Neste inquérito é solicitada a opinião do utilizador acerca da influência do fator contextual na avaliação de um determinado ponto de interesse, sendo assim possível verificar o impacto que cada fator contextual exerce nas preferências do utilizador.

2.2.3 INCLUSÃO DO CONTEXTO NO PROCESSO DE RECOMENDAÇÃO

Identificados e obtidos os fatores contextuais, é agora necessário incluí-los no método de recomendação de forma a obter recomendações relevantes. Segundo Adomavicius and Tuzhilin (2010) a informação contextual pode ser incluída em várias etapas do processo de recomendação. Os autores apresentam três abordagens designadas por pré-filtragem, pós-filtragem e modelação contextual.

Pré-Filtragem. Nesta abordagem a informação contextual é utilizada como filtro, de forma a obter o espaço de recomendação relevante para um determinado contexto, que será usado na geração de recomendações. Uma das vantagens deste método é a possibilidade de serem utilizadas técnicas de recomendação tradicionais, pois com aplicação deste filtro, obtém-se uma redução dimensional, em que espaço de recomendação passa a considerar as dimensões *Utilizador* e *Item*. Contudo o contexto considerado na filtragem pode ser muito restrito, levantando assim problemas de esparsidade, pois para esse contexto poderá existir pouca informação para a geração de recomendações relevantes. Desta forma em Adomavicius and Tuzhilin (2001) introduziu-se o conceito de pré-filtragem generalizada que permite assim a generalização do contexto, onde as avaliações são agregadas a um dado nível contextual, contornando assim a esparsidade. Baltrunas and Ricci (2009) introduziram uma aproximação de pré filtragem designada *item split*, onde cada item é decomposto em vários itens fictícios tendo em conta o contexto em que estes foram avaliados. Semelhante a esta ideia, mas agora aplicado a utilizadores, Baltrunas and Amatriain (2009) apresentam uma aproximação a que lhe dão o nome de *user split*, onde cada utilizador tem associado a si um conjunto de perfis, sendo que cada perfil representa este utilizador num dado contexto.

Pós-Filtragem. Nesta aproximação, a informação contextual é inicialmente ignorada, sendo criada a matriz bi-dimensional através da agregação das avaliações efetuadas sobre todos os valores contextuais. Após a recomendação ter sido efetuada com base nesta matriz, a informação contextual é utilizada no ajuste da lista de recomendação obtida. Este ajuste pode ser efetuado de duas formas. Na primeira, são ignorados os itens considerados irrelevantes, e na segunda, é feito um ajuste a lista de recomendações relativamente à situação contextual. Ambas as formas ajustam a avaliação estimada, sendo este ajuste efetuado através de métodos heurísticos ou métodos baseados em modelo. O primeiro foca-se nas características referentes aos itens que são relevantes para um dado utilizador num dado contexto, usando estas características para o ajuste das recomendações. No método baseado em modelo, é calculada a probabilidade de consumo dos itens por parte do utilizador num dado contexto, usando esta probabilidade para o ajuste das recomendações. Após o cálculo das probabilidades, estas podem ser usadas para filtrar os itens que se encontrem abaixo de um limiar predefinido ou para o ajuste das

avaliações obtidas (Aggarwal, 2016; Adomavicius and Tuzhilin, 2010).

Panniello et al. (2009) fazem uma comparação entre a pós-filtragem e a pré-filtragem exata *EPF*. O método de pós-filtragem baseia-se no cálculo da probabilidade do consumo do item por parte do utilizador num dado contexto. O autor dá o nome de *Filter-PoF* no caso em que é definido um limiar e *Weight-PoF* no caso em que a probabilidade é utilizada no ajuste das avaliações estimadas. Através dos resultados obtidos, o autor conclui que o *Filter-PoF* é mais eficaz do que o *EPF*, que por sua vez é mais eficaz que o *Weight-PoF*. O autor conclui assim que a comparação entre a pós-filtragem e a pré-filtragem depende do tipo de pós-filtragem aplicada.

Modelação Contextual. Tanto na pré-filtragem como na pós-filtragem o problema de recomendação é reduzido a duas dimensões e a informação contextual é utilizada no pré-processamento ou pós-processamento. Desta forma, a avaliação de um item baseia-se apenas na relação entre o utilizador e item. Na modelação contextual o problema torna-se multidimensional, sendo que a avaliação é resultado das relações entre o utilizador, o item e o contexto. Desta forma foram desenvolvidos algoritmos de recomendação baseados em memória e baseados em modelo. Adomavicius and Tuzhilin (2005a) com base nos métodos de vizinhança já aplicados nos sistemas de recomendação tradicionais, introduzem uma nova medida de semelhança n-dimensional que incorpora a dimensão contexto. Panniello and Gorgoglione (2012) apresentam um método também baseado em memória denominado de vizinhos contextuais, onde são consideradas quatro variantes deste método, Mdl1, Mdl2, Mdl3 e Mdl4. Este método adota a filtragem colaborativa baseada no utilizador, onde para cada utilizador u e contexto c é definido um perfil contextual, $Perfil(u, c)$. Desta forma, se a dimensão contextual tiver duas condições contextuais, serão construídos dois perfis para cada utilizador. Estes perfis contextuais serão utilizados para determinar a proximidade entre utilizadores, definindo a vizinhança para o utilizador u no contexto c . As variantes apresentadas definem o conjunto de perfis contextuais que são considerados para a determinação da vizinhança.

Foram também desenvolvidos métodos baseados em modelo, onde alguns destes métodos aplicam a fatorização de matrizes. Visto que o contexto faz parte do espaço de recomendação, esta fatorização é aplicada a uma matriz multidimensional (Karatzoglou et al., 2010; Baltrunas et al., 2011b; Hidasi and Tikk, 2012). Oku et al. (2006) incorporam diretamente as dimensões contextuais no espaço de recomendação através de uma técnica *machine-learning* designada *Support Vector Machine* (SVM), donde resulta o hiperplano que funcionará como classificador para futuras recomendações.

2.3 AVALIAÇÃO DOS SISTEMAS DE RECOMENDAÇÃO

De forma a que haja uma ideia clara sobre a qualidade algoritmos de recomendação, torna-se crucial a avaliação dos sistemas de recomendação. Para que a comparação entre sistemas ou algoritmos seja possível, é assim necessária uma forma comum para a avaliação destes (Hernández del Olmo and Gaudioso, 2008). Assim é necessária uma escolha adequada de protocolos e métricas de avaliação, de forma a compreender a efetividade destes, podendo por vezes uma só métrica não ser suficiente para avaliar os objetivos destes sistemas.

2.3.1 PARADIGMAS DE AVALIAÇÃO

A avaliação de sistemas pode decorrer de três formas, duas delas com o auxílio de participantes, medindo o impacto que os sistemas têm na interação com estes, e a outra, recorrendo a um conjunto de dados. Estas três formas de avaliação são a *online*, a *user-studies* e a *offline*.

User-studies. Este método pretende avaliar o impacto que os sistemas de recomendação têm nos utilizadores através de experiências em ambientes controlados. Desta forma, são recrutados participantes que são convidados a interagir com o sistema de recomendação, desempenhando tarefas definidas. É assim possível adquirir informação relativa às ações desempenhadas pelo utilizador e opiniões deste acerca da qualidade das recomendações, podendo assim obter uma perceção sobre a efetividade do sistema. Neste método, para além de ser possível efetuar uma análise comparativa sobre algoritmos escolhidos no processo de recomendação, também é possível avaliar outros aspetos inerentes aos sistemas de recomendação, como por exemplo a interface que o sistema apresenta ao utilizador. Contudo, sendo estas experiências efetuadas num ambiente controlado, onde os participantes devem efetuar tarefas específicas, os resultados tendem a conter desvios, pois os participantes estão cientes que estão sob observação (Gunawardana and Shani, 2009; Aggarwal, 2016).

Online. Este método deve ser adotado no momento em que os sistemas de recomendação estão totalmente implementados ou já se encontram no mercado. A grande diferença deste método para o acima apresentado, reside na escolha dos participantes que testam o sistema. Neste caso os participantes em causa, são utilizadores reais do sistema. Esta abordagem permite a recolha de resultados menos suscetíveis a desvios, visto que a experiência não é efetuada num ambiente controlado.

Embora este método traduza o impacto direto que o sistema tem sob o utilizador, é um método dispendioso e que não pode ser posto em prática numa fase inicial do desenvolvimento do processo de recomendação, pois o sistema não estará à disposição destes (Gunawardana and Shani, 2009; Aggarwal, 2016).

Offline. Esta técnica é usada frequentemente na fase de desenvolvimento dos sistemas de recomendação. Normalmente esta técnica é utilizada para avaliar o poder de previsão que os algoritmos de recomendação apresentam.

Para avaliar os algoritmos de recomendação é necessário simular o processo *online*, onde os utilizadores fornecem a sua opinião acerca das recomendações obtidas. Normalmente este processo é efetuado recorrendo a um conjunto de dados que contém as interações passadas dos utilizadores. De seguida, são filtradas algumas dessas interações de forma a simular a avaliação dada pelo participante (Gunawardana and Shani, 2009; Aggarwal, 2016). O conjunto formado pelas interações que serão filtradas, é denominado como conjunto de teste, sendo que o conjunto formado pelas restantes interações é denominado como conjunto de treino. Na prática os conjuntos de dados não se apresentam divididos. Deste modo o sistema de avaliação deve ser capaz de segmentar o conjunto nestes dois.

Existem diversas formas de segmentar este conjunto de dados. Assumindo que o conjunto de dados é definido por S e o conjunto de teste por E . Como $E \subset S$, o segmento $S - E$ é usado para o treino do sistema de recomendação. A este tipo de segmentação é dado o nome de *hold-out*. Outro método popular de segmentação é designado como validação cruzada. Este método consiste na partição do conjunto de dados em q partições de igual dimensão. Em cada iteração é usada uma partição para o conjunto de teste e as restantes $q - 1$ para conjunto de treino. Este processo tem q iterações, utilizando cada uma das q partições para o conjunto de teste. Assim, erro obtido corresponde à média de todos os erros obtidos em cada repetição (Gunawardana and Shani (2009)).

2.3.2 MÉTRICAS DE PRECISÃO

Este conjunto de métricas é bastante usado no método de avaliação *offline*. Estas métricas têm como objetivo avaliar o rigor das previsões feitas pelo sistema de recomendação. Dependendo do objetivo do sistema de recomendação, este pode ser avaliado através das avaliações que este prevê (baseadas em erro), ou através da qualidade de listas de recomendação que produz (baseadas em classificação).

Métricas baseadas em erro. Estas métricas são aplicadas nos casos em que o objetivo do sistema de recomendação é estimar avaliações. As métricas usadas são a *Mean Absolute Error* (MAE), a *Mean Squared Error* (MSE), a *Root Mean Squared Error* (RMSE), a *Normalized Root Mean Squared Error* (NRMSE) e a *Normalized Mean Absolute Error* (NMAE) (Bobadilla et al., 2013).

Seja $r_{u,j}$ a avaliação dada pelo utilizador u a um item j presente em E e $\hat{r}_{u,j}$ a avaliação estimada pelo algoritmo de recomendação. O erro para uma dada entrada é dado por $e_{u,j} = \hat{r}_{u,j} - r_{u,j}$, podendo ser aplicado às métricas mencionadas para o cálculo do erro obtido no conjunto E .

$$MAE = \frac{\sum_{(u,j) \in E} |e_{u,j}|}{|E|} \quad (2.3)$$

$$RMSE = \sqrt{\frac{\sum_{(u,j) \in E} e_{u,j}^2}{|E|}} \quad (2.4)$$

A RMSE é normalmente usada em aplicações onde é exigida estabilidade e rigor na previsão para diversos itens, pois penaliza grandes desvios (Herlocker et al., 2004). Numa situação onde são utilizados vários conjuntos de dados para avaliação, são empregues as métricas normalizadas. Com o uso destas métricas é assim possível lidar com as diferentes escalas de classificação usadas em cada conjunto de dados.

$$NRMSE = \frac{RMSE}{r_{max} - r_{min}} \quad (2.5)$$

$$NMAE = \frac{MAE}{r_{max} - r_{min}} \quad (2.6)$$

Métricas baseadas em classificação. Estas métricas são usadas para avaliar os sistemas de recomendação que têm como objetivo fornecer uma lista de recomendação. Esta lista é constituída por um conjunto de itens que podem ou não ser relevantes para o utilizador. A avaliação das listas pode ser quantitativa ou qualitativa, a primeira refere-se ao número de itens relevantes apresentados na lista e a última refere-se à posição do item na lista.

Avaliação quantitativa. Refere-se à fração de itens relevantes apresentados na lista. As métricas comuns para esta avaliação são a *Precision* e a *Recall*. A *Precision* define a probabilidade de um item selecionado na lista ser relevante, enquanto que a *Recall* define a probabilidade de um item relevante constar na lista de recomendação. Esta última é definida através da razão entre os itens relevantes apresentados na lista de recomendação e o número total de itens relevantes (Herlocker et al., 2004).

Através 2.1 são definidos os termos que fazem parte da tarefa de recomendação.

Tabela 2.1: Matriz de confusão

	Recomendado	Não Recomendado
Relevante	Verdadeiro-Positivo (vp)	Falso-Negativo (fn)
Irrelevante	Falso-Positivo (fp)	Verdadeiro-Negativo (vn)

Com base nestes termos é assim possível definir a *Precision* e a *Recall*.

$$Precision = \frac{\#vp}{\#vp + \#fp} \quad (2.7)$$

$$Recall = \frac{\#vp}{\#vp + \#fn} \quad (2.8)$$

A percentagem de itens relevantes está relacionada com o tamanho da lista de recomendação. Se a lista for muito pequena, o sistema irá omitir grande parte dos itens relevantes. No caso da lista ser muito grande, o sistema irá propor muitos itens irrelevantes para o utilizador. Verifica-se assim a relação inversa entre a *Precision* e a *Recall* que pode ser determinada através da curva *Precision-Recall* (Gunawardana and Shani, 2009).

Em Deshpande and Karypis (2004) a métrica *recall* é definida como *Hit-Rate* (HR) ,

$$HR = \frac{\text{Número de Hits}}{n}. \quad (2.9)$$

O *Número de Hits* representa o número de itens presentes no conjunto de teste que fazem parte da lista de recomendação retornada para cada utilizador. Assim quando a HR toma o valor de 1.0, todos os itens no conjunto de teste foram recomendados.

Avaliação qualitativa. Estes métodos têm em conta a posição ocupada pelos itens na lista. Idealmente a lista apresentada deve estar ordenada pelo grau de relevância de cada item, estando os lugares cimeiros da lista ocupados pelos itens mais relevantes para o utilizador. No caso da opinião ser explícita, os itens que têm uma avaliação maior são mais úteis para o utilizador e consequentemente devem ocupar os primeiros lugares da lista.

Uma das métricas utilizadas neste tipo de avaliação é a *Normalized Discount Cumulative Gain* (NDCG), onde cada item tem uma relevância associada, ou seja o seu ganho ($g_{u,j}$). Para itens a que não foi atribuída avaliação, o seu ganho é nulo. Este ganho é cumulativo, pois os ganhos da lista são somados. Antes desta soma é dado um desconto de fator logarítmico que está associado à posição em que o item se encontra na lista. Desta forma obtemos a *Discount Cumulative Gain* (DCG), sendo que o pior valor possível é o nulo. Considerando o conjunto de itens omitidos para cada utilizador como I_u e v_j a posição ocupada na lista,

$$DCG = \sum_{j \in I_u} \frac{g_{u,j}}{\log_2(v_j + 1)}. \quad (2.10)$$

Habitualmente o ganho $g_{u,j}$ assume um valor exponencial em função da relevância do item $rel_{u,j}$. Esta relevância pode ser obtida através da opinião explícita ou através das vezes que o item foi consumido.

$$g_{u,j} = 2^{rel_{u,j}} - 1 \quad (2.11)$$

De forma a comparar as DCG's obtidas para cada recomendação é necessário normalizar a métrica. A normalização é definida através da razão entre a DCG obtida e a *Ideal Discount Cumulative Gain* (IDCG) que representa o valor ideal. Este valor ideal é obtido através do cálculo da DCG para a lista ordenada pelo grau de relevância. A razão entre dois valores toma valores entre 0 e 1.

$$NDCG = \frac{DCG}{IDCG} \quad (2.12)$$

Outra métrica usada habitualmente em casos onde a opinião é implícita é a *Average Reciprocal Hit Rate* (ARHR), onde a pontuação de um item $r_{u,j} \in \{0, 1\}$. Nesta métrica o desconto atribuído a cada item é de $\frac{1}{v_j}$, onde v_j representa a posição ocupada pelo item na lista.

$$ARHR = \sum_{j \in I_u} \frac{r_{u,j}}{v_j} \quad (2.13)$$

As métricas acima apresentadas não funcionam para casos onde as listas de recomendação são de tamanho variável. Ou seja, tomando o exemplo de duas recomendações, onde a primeira retorna uma lista com dois itens e a segunda uma lista com quatro itens. Para cada uma destas recomendações o item relevante ocupar a segunda posição quer dizer que, no primeiro caso estaria no último lugar da lista, mas no segundo estaria a meio da tabela, tendo a mesma pontuação. De forma a contornar este aspeto, Miranda (2013) introduz uma métrica baseada no fator de decréscimo, que relaciona a posição do item com o tamanho da lista retornada.

$$Erro = \left(\frac{1}{n-1} \times v_j \right) \times 100, \quad v_j \in [0, n-1], \quad (2.14)$$

onde n representa o tamanho da lista de recomendação.

Herlocker et al. (2004); Gunawardana and Shani (2009) apresentam em detalhe as métricas referidas acima. Os autores afirmam ainda que o uso destas métricas por si só não são suficientes para avaliação do sistema de recomendação, pois a satisfação do utilizador e utilidade do sistema para o mesmo não se reflete apenas no poder de previsão dos sistemas. Os autores abordam outros aspetos que devem ser considerados, como a confiança, a singularidade e a diversidade.

Caso o sistema tenha um poder preditivo de grau elevado, este gera recomendações de itens já avaliados pelo utilizador ou itens muito parecidos a estes. Apesar de as mesmas não serem relevantes, dada a familiarização do utilizador com os itens recomendados, o utilizador deposita confiança no sistema.

A introdução de diversidade e singularidade nos itens recomendados, permite ao utilizador descobrir itens com os quais poderá não estar familiarizado. Além desses aspetos, o sistema pode recomendar itens que causam surpresa ao utilizador. Tomando como exemplo um sistema de recomendação que sugere restaurantes e um utilizador que já foi a um restaurante indiano. O sistema introduz singularidade quando sugere um restaurante paquistanês, pois em termos culinários estes dois são

parecidos. Mas se sugerir um restaurante japonês, causa um efeito de surpresa (atribuída ao acaso), pois aqui é tido em conta não a semelhança culinária (em termos de sabor e técnicas culinárias de confeção), mas o seu interesse por diferentes estilos de cozinha internacional. Deste modo é necessário um compromisso entre a precisão, diversidade e singularidade. Sinha and Swearingen (2002) realizaram um estudo com cinco sistemas de recomendação no domínio da música com o objetivo de concluir qual o papel da transparência nas recomendações. Os autores concluíram assim que os utilizadores confiam mais em sistemas onde lhes é fornecida uma explicação para a recomendação obtida. Pu et al. (2012) apresentaram um conjunto de medidas de avaliação dos sistemas de recomendação centradas no utilizadores. Os autores definem um ciclo de vida na interação utilizador-sistema, definindo também métricas para avaliar cada etapa deste ciclo. Os autores abordam várias opções para cada etapa, formas de o utilizador expressar as suas preferências, algoritmos para previsão das avaliações e formas de exibição das recomendações. Os autores avaliam cada etapa que constitui o ciclo de vida, deixando diretivas para futuros projetistas deste tipo de sistemas.

2.4 APLICAÇÕES

Nesta secção são referidos alguns sistemas de recomendação e protótipos que consideram a informação contextual na geração de recomendações. Visto que o trabalho proposto baseia-se na recomendação de pontos de interesse orientados ao contexto com base em geolocalização e opinião implícita, os sistemas apresentados encontram-se inseridos no domínio do turismo.

As primeiras aplicações que surgiram neste domínio foram guias turísticos, onde as recomendações são obtidas através de um conjunto de restrições impostas pelo utilizador, representando assim as suas preferências e objetivos. O primeiro guia turístico eletrónico capaz de fornecer percursos personalizados foi o GUIDE (Cheverst et al., 2000). Este guia foi desenvolvido para a cidade de Lancaster. Um dos fatores contextuais considerados por este guia é o idioma do utilizador, permitindo assim ajustar a informação apresentada sobre os pontos de interesse. A geração de percursos é baseada na hora de funcionamento dos pontos de interesse, no momento do dia e nos pontos de interesse já visitados. Para além deste guia turístico existem outros com uma aproximação semelhante a este, como por exemplo o INTRIGUE (Svizzera et al., 2003) e UbiqTO (Che, 2004), guias turísticos para a cidade de Turim. O COMPASS (Setten et al., 2004) é outro exemplo de guia turístico. Este seleciona os pontos de interesse a serem recomendados através de um raio de ação centrado na localização atual do utilizador atribuindo a pontuação a cada um destes pontos de acordo com os interesses do utilizadores e os fatores contextuais.

Os guias turísticos apresentados, baseiam a geração de recomendações nas restrições e objetivos impostos pelos utilizador, sujeitando o utilizador ao preenchimento de questionários com o objetivo de obter as recomendações.

Em contraste com esta aproximação, surgiram sistemas que tem em conta as visitas efetuadas por outros utilizadores com gostos semelhantes ao utilizador que requer a recomendação. Ou seja, estes sistemas baseiam-se na filtragem colaborativa. O ReRex foi um sistema proposto em Baltrunas et al. (2011a) para a cidade de Bolzano. Neste sistema são recomendados pontos de interesse recorrendo à filtragem colaborativa orientada ao contexto. Associada à recomendação dos pontos de interesse é explicado o motivo pelo qual estes pontos foram recomendados.

O sistema de recomendação presente na rede social baseada em localização Foursquare também utiliza a filtragem colaborativa na geração de recomendações. Neste sistema são determinadas as semelhanças entre pontos de interesse e entre utilizadores. As recomendações também são acompanhadas de uma explicação evidenciando os pontos de interesse que foram previamente visitados pelos amigos do utilizador (Moore, 2011).

METODOLOGIA

Neste capítulo, é exposto o problema proposto assim como os conceitos inerentes a este. De seguida é apresentada a modelação deste problema, relacionando as entidades e acontecimentos presentes neste. Esta modelação segue o paradigma OLAP, onde o espaço de recomendação é representado através de um modelo multidimensional. Com este modelo é possível definir hierarquias OLAP associadas a determinadas dimensões que constituem o espaço de recomendação. Estas hierarquias permitem assim contornar a esparsidade existente no conjunto de dados, permitindo a agregação de avaliações a diferentes níveis hierárquicos.

É também apresentado o processo de recomendação, onde são descritas as tarefas que o constituem. O processo de recomendação é assim composto pela aquisição da situação contextual considerada no momento de recomendação, de seguida é efetuada a filtragem dos pontos de interesse com base na localização do utilizador e por fim é calculada e atribuída a pontuação a cada um destes pontos de interesse baseada no método de recomendação considerado. Os métodos considerados relacionam a situação contextual atual com o número de visitas efetuadas a cada ponto de interesse.

São apresentados três métodos de recomendação, sendo que os dois primeiros são métodos de popularidade e o último é um método de personalização.

O primeiro método, denominado de dominância contextual é apresentado em Miranda (2013). Este método faz uso de uma matriz constituída pelas condições contextuais dominantes para cada ponto de interesse. A pontuação atribuída a um ponto de interesse é determinada através da comparação das condições contextuais que compõem a situação contextual atual, com as condições contextuais dominantes associadas ao ponto. Neste método é possível atribuir pesos a cada dimensão contextual.

O segundo método apresentado é denominado de frequência contextual e, tal como o nome indica calcula a frequência de visitas efetuadas na situação contextual atual para cada ponto de interesse. Ou seja, a pontuação atribuída a um ponto de interesse resulta da razão entre as visitas efetuadas ao ponto na situação contextual atual e o total de visitas efetuadas ao ponto. Desta forma a pontuação obtida para um ponto de interesse representa a influência que a situação contextual atual exerce na visita a esse ponto.

O terceiro e último método, representa uma particularidade da frequência contextual, na medida em que a pontuação para cada ponto de interesse é calculada seguindo o mesmo princípio, só que neste caso apenas são contabilizadas as visitas efetuadas pelo utilizador que requer a recomendação. Desta

forma é assim introduzida a personalização na frequência contextual. Neste método o cálculo de cada ponto de interesse é obtido através da hierarquia associada à dimensão ponto de interesse. Ou seja, para cada ponto de interesse serão agregadas as visitas efetuadas com base nível hierárquico a que este pertence. Assim se dois pontos de interesse pertencerem ao mesmo nível hierárquico terão a mesma pontuação.

Problema. O problema apresentado neste projeto consiste na recomendação de pontos de interesse tendo em conta a situação contextual no momento da recomendação, a geolocalização e a opinião implícita por parte do utilizador. A recomendação deverá ser apresentada ao utilizador na forma de uma lista que contém os pontos de interesse ordenados pela sua relevância. Dado que apenas se sabe que um utilizador esteve num determinado ponto de interesse, não é possível obter a avaliação do utilizador para esse mesmo ponto.

3.1 CONCEITOS

O problema apresenta três entidades e um acontecimento que as relaciona. Este acontecimento representa uma visita efetuada por um utilizador a um ponto de interesse numa dada situação contextual.

As três entidades e o acontecimento são definidas da seguinte forma:

- (1) Utilizadores $U = (u_1, \dots, u_k)$.
- (2) Pontos de Interesse $P = (p_1, p_2, p_3, \dots, p_l)$.
- (3) Contexto C é composto por várias dimensões contextuais (C_1, \dots, C_m) . Cada dimensão contextual é definida através de um conjunto de valores designados de condições contextuais $C_i = (K_1, \dots, K_n)$. Desta forma a situação contextual E é representada pela atribuição de uma condição contextual a cada dimensão $E = (K_1, \dots, K_n)$.

Considerando como exemplo as dimensões contextuais C_1 e C_2 Temperatura e Momento do Dia respetivamente, $C_1 = (frio, ameno, quente) \wedge C_2 = (manhã, tarde, noite)$, uma possível situação contextual considerando estas dimensões seria $E = (ameno, noite)$.

- (4) Visita V representando um acontecimento caracterizado pelo utilizador U , ponto de interesse P e uma situação contextual E .

3.2 MODELO MULTIDIMENSIONAL DE RECOMENDAÇÃO

É necessário definir e modelar o espaço de recomendação constituído pelas entidades apresentadas acima, de forma a que seja possível gerar recomendações.

Considerando D_1 e D_2 como as dimensões *Utilizador* e *Ponto de Interesse*. Caso $D_1 \subseteq A_{11} \wedge D_2 \subseteq A_{21}$ o espaço de recomendação é bi-dimensional. Contudo no caso em que $D_1 \subseteq A_{11} \wedge D_2 \subseteq A_{21}, \dots, A_{2m}$ o espaço passa a ser $n + m$ dimensional. Sendo o primeiro caso aplicado por exemplo na filtragem colaborativa, onde os identificadores representam os atributos que definem D_1 e D_2 . Já o segundo

caso é aplicado por exemplo na filtragem baseada em conteúdo, onde A_{11} representa o identificador do utilizador e o conjunto A_{21}, \dots, A_{2m} representa as características do item.

Considerando a dimensão D_i representada por um subconjunto de características A_{ij} , ($j = 1, \dots, k_i$) tal que $D_i \subseteq A_{i1} \times A_{i2} \times \dots \times A_{ik_i}$ e S o espaço de recomendação,

$$S = Utilizador \times Ponto\ de\ interesse. \quad (3.1)$$

Contudo, estes sistemas representam os acontecimentos com base nestas duas dimensões ignorando qualquer tipo de informação contextual. De forma a que seja possível suportar esta informação contextual, é necessário estender assim o espaço de recomendação de forma a incorporar a dimensão relativa ao contexto.

O contexto pode ser representado através de uma dimensão, caracterizada pelo conjunto de z fatores contextuais, definindo assim cada situação contextual. Ou pode ser decomposto em z dimensões, em que cada uma representa um fator contextual. Ou seja, no primeiro caso $S = Utilizador \times Ponto\ de\ Interesse \times Contexto$, onde o $Contexto \subseteq C_1, C_2, \dots, C_z$. Já no segundo caso, o espaço de recomendação é estendido a z dimensões correspondentes aos fatores contextuais.

$$S = D_1 \times D_2 \times \dots \times D_n, \quad n \geq 2 \quad (3.2)$$

O espaço de recomendação S pode ser visualizado através de um cubo, representado na figura 4.1. O cubo é composto por um grupo de células, cada uma identificada pelos valores das dimensões do cubo.

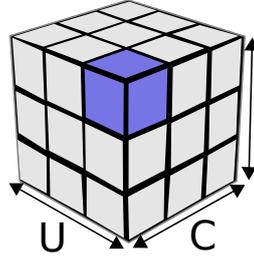


Figura 3.1: Cubo - Representação do espaço de recomendação orientado ao contexto

Tomando como exemplo, $S = Utilizador \times Ponto\ de\ Interesse \times Localização$. A dimensão *Utilizador* é definida por $Utilizador \subseteq Nome \times Naturalidade \times Idade$ sendo que um conjunto de utilizadores tem associado a si um certo nome, naturalidade e idade. Da mesma forma, a dimensão *Ponto de Interesse* é definida por $Ponto\ de\ Interesse \subseteq Nome \times Localização$ onde a um conjunto de pontos de interesse está associado um nome e um endereço. Por fim, a dimensão *Localização* é definida como $Localização \subseteq Latitude \times Longitude$ onde a um conjunto de localizações está associada uma latitude e uma longitude. Enquanto a maior parte dos sistemas fornecem apenas recomendações de um só tipo, como por exemplo, recomendação de n itens a um utilizador, este modelo multidimensional possibilita recomendações incluindo mais do que uma dimensão.

Hierarquias. Cada dimensão pode ter associada a si um conjunto de níveis que formam uma hierarquia, possibilitando a análise desta a vários níveis.

Formalmente, uma hierarquia L é definida através de vários níveis, onde $L = L_1, \dots, L_m$, ALL representa um subconjunto finito de níveis e, \prec simboliza a ordem parcial entre os níveis tal que, $L_1 \prec L_2 \prec \dots \prec ALL$, onde o topo da hierarquia corresponde ao nível ALL .

Considerando a hierarquia associada a dimensão Localização, os níveis hierárquicos são a região, a cidade, o país e *ALL*, estando apresentados por ordem crescente relativamente ao grau de detalhe. A relação entre dois níveis é dada pela função $anc_{L_1}^{L_2}$. Esta função atribui assim o valor do domínio de L_2 , ao valor do domínio em L_1 . Por exemplo, $anc_{cidade}^{país}(Aveiro) = Portugal$ (Vassiliadis and Skiadopoulos, 2000; Stefanidis et al., 2007; Aggarwal, 2016).

O uso de hierarquias permite assim a segmentação de dimensões, podendo ser possível a agregação de acontecimentos. Desta forma, é possível determinar o número de visitas efetuadas por utilizadores do sexo masculino.

Para além disso, existe a possibilidade de combinação de dimensões. Por exemplo se forem consideradas as dimensões *Utilizador*, *Ponto de Interesse* e *Localização*, é possível determinar o número de visitas a bares em Aveiro efetuadas por utilizadores do sexo masculino. Com o uso destas hierarquias é ainda possível efetuar recomendações orientadas a um determinado grupo populacional. Para além disto, o uso das hierarquias permite também contornar a esparsidade existente no espaço de recomendação.

3.3 PROCESSO DE RECOMENDAÇÃO

De forma a que seja possível efetuar recomendações, cada sistema tem de efetuar um conjunto de tarefas. Este conjunto de tarefas representa assim o processo de recomendação. O processo apresentado para a solução do problema é composto por quatro tarefas.

Inicialmente é adquirida a situação contextual atual, de seguida é efetuada uma filtragem de pontos de interesse tendo em conta a localização do utilizador, é atribuída uma pontuação a cada ponto de interesse e por fim, é apresentada uma lista de pontos de interesse ordenada pela sua pontuação.

Aquisição do contexto. Neste passo são extraídas as condições contextuais que definem a situação contextual no momento da recomendação. Para cada uma das dimensões contextuais consideradas na situação contextual atual, é adquirida a condição contextual atual.

Embora em alguns sistemas de recomendação seja necessária a especificação da situação contextual por parte do utilizador, nesta abordagem essa situação contextual é adquirida recorrendo a agentes externos (Adomavicius and Tuzhilin, 2010, 2015).

Filtragem baseada na localização. Esta filtragem tem como objetivo a seleção de pontos de interesse que se encontram numa determinada área. Esta área é definida através de um raio de ação centrado num dado ponto, onde este ponto corresponde à localização atual do utilizador. O uso desta filtragem, permite assim que do conjunto de todos os pontos existentes, apenas seja atribuída pontuação aos presentes na área. Para além da redução do esforço computacional, pois apenas será atribuída pontuação aos pontos selecionados, demonstra-se em Levandoski et al. (2012) que os utilizadores manifestam maior interesse em locais perto de si.

Pontuação dos pontos de interesse. Considerando o conjunto de pontos selecionados através da filtragem efetuada no passo anterior, é calculada e atribuída uma pontuação a cada um destes pontos. A pontuação de cada ponto depende dos critérios e métodos de recomendação considerados por cada sistema. A pontuação atribuída a cada ponto de interesse nos métodos apresentados, baseia-se na relação entre a situação contextual atual e o número de visitas efetuadas em cada ponto de interesse.

Por fim, o conjunto de pontos de interesse é ordenado por ordem de decrescente com base na sua pontuação.

Apresentado o processo de recomendação, serão agora apresentadas as três abordagens tomadas em consideração para o cálculo da pontuação dos pontos de interesse. Nas duas primeiras abordagens, o cálculo da pontuação de cada ponto de interesse é baseado no histórico de todos os utilizadores. Desta forma, a lista de recomendação apresentada é a mesma independentemente do utilizador que a requer, onde os pontos de interesse populares na situação contextual atual aparecem nos lugares cimeiros. Na terceira abordagem, o cálculo de cada ponto de interesse é baseado apenas no histórico do utilizador que requer a recomendação, introduzindo assim a personalização no método de recomendação. Através da análise do comportamento do utilizador, é possível inferir as preferências deste relativas ao tipo de ponto de interesse numa dada situação contextual. Esta preferência por tipo de ponto de interesse numa dada situação contextual é assim utilizada no cálculo de cada ponto de interesse.

3.4 DOMINÂNCIA CONTEXTUAL

A dominância contextual é apresentada face à difícil implementação de métodos de filtragem colaborativa onde a opinião do utilizador é implícita (Miranda, 2013). O autor assume uma visão representativa do contexto, onde este é totalmente definido à priori e imutável.

A atribuição da pontuação a cada ponto, baseia-se nas condições contextuais que definem a situação contextual no momento da recomendação. Considerando a Visita V , composta pela localização do ponto de interesse L e o instante de tempo T em que foi efetuada, a situação contextual associada a cada visita é representada por $E(V)$.

A uma localização, podem estar associadas várias visitas habitualmente com marcas temporais diferentes. Como cada visita tem associada a si uma situação contextual, uma localização terá associada a si um conjunto de situações contextuais.

Seja DC , a matriz de dominância contextual de dimensões $m \times n$, onde m representa a cardinalidade de Localizações e n a cardinalidade das dimensões contextuais. Esta matriz contém a situação contextual dominante para cada localização, sendo composta pelas condições contextuais mais frequentes em cada dimensão contextual. O valor da condição contextual para cada dimensão contextual é obtida através do cálculo da moda, Mo , nessa dimensão.

$$DC = \begin{pmatrix} Mo(P_1, D_1) & Mo(P_1, D_2) & \cdots & Mo(P_1, D_n) \\ Mo(P_2, D_1) & Mo(P_2, D_2) & \cdots & Mo(P_2, D_n) \\ \vdots & \vdots & \ddots & \vdots \\ Mo(P_m, D_1) & Mo(P_m, D_2) & \cdots & Mo(P_m, D_n) \end{pmatrix}$$

Pontuação do ponto de interesse. O cálculo do ponto de interesse é efetuado com base na situação contextual atual e na matriz de dominância contextual. Considerando esta situação contextual

atual $E(L_{now}, T_{now})$, a pontuação atribuída a um ponto de interesse é dada por:

$$comp(x, y) = \begin{cases} 1, & \text{se } x = y \\ 0, & \text{se } x \neq y \end{cases} \quad (3.3)$$

$$Pontuação(P) = \sum_{i=1}^m comp(E_i, M_{(P,i)}) \times w_i \quad w \in [0, 1] \wedge Score(P) \in [0, m] \quad (3.4)$$

A pontuação é assim obtida através da comparação das condições contextuais para uma dada dimensão. Em que E_i representa a condição contextual da situação contextual atual pertencente a dimensão i e $M_{(P,i)}$ a condição contextual dominante na dimensão i . Por fim w_i representa o peso dado à dimensão i .

3.5 FREQUÊNCIA CONTEXTUAL

Como se pode observar em 3.4, a matriz de dominância contextual só armazena uma condição contextual por dimensão. Desta forma é apenas considerada a condição contextual que obteve mais visitas. Assim o método não cobre os casos em que o conjunto de condições é amodal, bimodal ou multimodal.

Para além disto, no caso unimodal, caso a frequência de duas ou mais condições contextuais seja semelhante, a pontuação para um dado ponto é drasticamente influenciada. Tomando como exemplo o caso em que num dado ponto de interesse observaram-se 12 visitas no Verão e 11 no Outono. Consequentemente a condição dominante é o Verão. Caso a recomendação seja feita no Outono, como a condição não coincide com a condição contextual dominante, este ponto de interesse sofrerá uma penalização nessa estação do ano.

De modo a amortizar estas penalizações, ao invés da relevância contextual ser obtida através da matriz de dominância, esta resultará da frequência de visitas que foram efetuadas na situação contextual atual.

Pontuação do ponto de interesse. A pontuação atribuída em cada ponto de interesse situado no raio de ação, representa a influência contextual na tomada de decisão de uma visita ao respetivo ponto. Esta influência é assim calculada com base na frequência de visitas feitas a cada ponto de interesse na situação contextual atual E .

Influência do contexto na visita a um ponto de interesse. Este fator representa a frequência de visitas efetuadas a um ponto de interesse numa dada situação contextual. A frequência contextual é obtida através da razão entre o número de visitas efetuadas a um ponto de interesse numa situação contextual, $\#Visita_{PE}$ e o número total de visitas efetuadas a este ponto de interesse $\#Visita_P$.

$$Inf(P, E) = \frac{\#Visita_{PE}}{\#Visita_P} \quad (3.5)$$

Desta forma a pontuação é dada por:

$$\text{Pontuação}(P, E) = \text{Inf}(P, E) \quad (3.6)$$

A pontuação atribuída a cada ponto de interesse é assim dada pela influência da situação contextual atual na visita ao ponto de interesse.

Caso a situação contextual seja definida por diversas dimensões, pode dar-se o caso de não existirem visitas aos pontos de interesse nessa situação contextual e por consequência estes pontos de interesse terão pontuação nula. Através do uso da hierarquia associada à dimensão ponto de interesse, os pontos podem ser segmentados através dos níveis hierárquicos, por exemplo por subcategoria ou categoria. Este facto, possibilita assim a agregação de visitas contornando a especificidade da situação contextual atual. Desta forma a pontuação atribuída ao ponto de interesse, resulta da agregação de visitas efetuadas com base no nível hierárquico a que este pertence, para a situação contextual atual. Logo é possível efetuar recomendações a vários níveis hierárquicos.

3.6 PERSONALIZAÇÃO

Os métodos acima descritos baseiam-se nas visitas aos pontos de interesse por todos os utilizadores. Nestes métodos, os pontos mais populares são os que aparecem nos lugares cimeiros da lista, sendo que a lista de recomendação fornecida é a mesma independentemente do utilizador que a requer.

Com o objetivo de obter listas de recomendação que se ajustem aos gostos e preferências do utilizador, é necessária a análise comportamental do utilizador que requer a recomendação. Esta análise é realizada com base nas visitas efetuadas pelo utilizador aos pontos de interesse numa dada situação contextual.

Este método de personalização é uma particularidade da frequência contextual, visto que o cálculo da pontuação para cada ponto de interesse baseia-se apenas nas visitas efetuadas pelo utilizador.

Pontuação do ponto de interesse. Visto que neste método apenas são consideradas as visitas efetuadas pelo utilizador, é necessária uma forma de relacionar os pontos de interesse visitados com os pontos de interesse desconhecidos pelo utilizador, de forma a que lhes possa ser atribuída uma pontuação. Esta relação é obtida através do uso da hierarquia associada à dimensão ponto de interesse.

Através da hierarquia associada à dimensão ponto de interesse, é possível segmentar o conjunto de pontos de interesse com base no nível hierárquico. Através desta segmentação é possível obter as preferências do utilizador para o nível hierárquico numa dada situação contextual. As preferências são obtidas através da agregação de visitas efetuadas pelo utilizador numa dada situação contextual, para um dado nível hierárquico. Assim a pontuação atribuída a um ponto de interesse será obtida

através da razão entre o número de visitas efetuadas ao nível a que o ponto está associado, numa dada situação contextual e, o número total de visitas efetuadas a esse nível.

$$Inf(U, L_n, E) = \frac{\#Visitas(U, anc_P^{L_n}, E)}{\#Visitas(U, anc_P^{L_n})} \quad (3.7)$$

Assim a pontuação para cada ponto de interesse é dada por:

$$Pontuação(U, P, E) = Inf(U, L_n, E) \quad (3.8)$$

CASO DE ESTUDO

Este capítulo apresenta a instanciação do problema descrito no capítulo anterior, explicando os passos necessários para a implementação e avaliação do processo de recomendação orientado ao contexto. Desta forma será apresentado o conjunto de dados escolhido, assim como os processos necessários para o enriquecimento deste. São também caracterizadas as entidades com base no conjunto de dados, assim como as dimensões contextuais consideradas. É discutido o tratamento do conjunto de dados obtido, a instanciação do modelo e o processo de recomendação. Será também abordada a importância das hierarquias na geração de recomendações. Por fim será discutido o uso das tecnologias aplicadas.

4.1 CONJUNTO DE DADOS

O problema apresentado tem associado a si aspetos como o contexto, geolocalização e opinião implícita por parte do utilizador. Desta forma, é necessária a obtenção de dados relativos a visitas efetuadas por utilizadores a pontos de interesse, tendo associadas a si uma localização e uma marca temporal. Assim, realizou-se uma pesquisa de conjunto de dados disponíveis, de forma a ser possível a instanciação e avaliação do processo de recomendação.

Inicialmente foram considerados dois conjuntos de dados disponibilizados pelo *Stanford Network Analysis Project* (SNAP)¹. Estes conjuntos de dados, são referentes à interação de utilizadores nas redes sociais baseadas em localização, nomeadamente Brightkite e Gowalla, que neste momento se encontram inativas. Cada registo neste conjunto de dados é composto por cinco campos: o identificador do utilizador, a marca temporal da visita, a localização do utilizador na forma de latitude e longitude e o identificador do ponto de interesse visitado. Visto que estas redes sociais se encontram inativas, não foi possível obter mais informação a partir da já existente, pois nenhuma das redes fornece serviços para tal. Ainda assim, de forma a obter informação relativa aos pontos de interesse, recorreu-se a um dos serviços disponíveis pelo Geonames², nomeadamente o `findNearbyPOIOSM`. Para uma dada localização, este serviço disponibiliza informação sobre pontos de interesse na proximidade desta. Após terem sido efetuados alguns pedidos sem sucesso, esta abordagem foi descartada. Visto que estes conjuntos de dados não poderiam ser enriquecidos, optou-se por pesquisar outros conjuntos de dados,

¹<https://snap.stanford.edu/data>

²<https://www.geonames.org>

até que foram encontrados dados relativos a outra rede social baseada em localização, o Foursquare (Yang et al., 2015).

Foursquare. Foursquare é uma rede social baseada em localização, que tem como objetivo recomendar pontos de interesse aos utilizadores dependendo da sua localização atual. Fundada no final de 2008, esta rede social permite aos utilizadores usarem os dispositivos móveis como forma de interação com o meio que os rodeia, permitindo assim a partilha em tempo real da sua localização e da sua opinião acerca dos pontos de interesse visitados. Para além do uso da localização do utilizador para efetuar recomendações, esta rede permite a procura pontos de interesse por área ou nome. O sistema usado na rede gera recomendações personalizadas com base no histórico de visitas do utilizador, gostos deste e opiniões de amigos. Para além disto, o Foursquare disponibiliza serviços onde podem ser consultadas informações referentes aos pontos de interesse.

O conjunto de dados utilizados, contém informação relativa a visitas efetuadas a pontos de interesse na cidade de Nova Iorque, recolhidos na rede Foursquare entre Abril de 2012 e Fevereiro de 2013. Na tabela 4.1 é apresentada informação acerca do conjunto de dados.

Tabela 4.1: Informação estatística do conjunto de dados

Visitas	188321
Utilizadores	1083
Pontos de Interesse	12206
Categorias	9
Subcategorias	455
Duração	03 Abril 2012 - 16 Fevereiro 2013

Cada visita cada é composta por oito campos:

- (1) Identificador do utilizador
- (2) Identificador do ponto de interesse (Identificador Foursquare)
- (3) Identificador da categoria associada ao ponto de interesse (Identificador Foursquare)
- (4) Nome da categoria relativa ao ponto de interesse
- (5) Latitude
- (6) Longitude
- (7) Desfasamento temporal da visita em relação ao *Universal Time Coordinated* (UTC)
- (8) Marca temporal relativa à visita em UTC

A informação relativa às visitas foi adquirida no formato *Comma-Separated Values* (CSV), sendo necessária a extração dos campos de cada registo para preenchimento das tabelas existentes na base de dados. O conjunto de dados não apresenta informação relativa ao utilizador e ponto de interesse. Para além disto, apenas existe informação sobre a marca temporal e a localização relativas à visita. Assim foi necessário recorrer a agentes externos como forma de obter a informação contextual relativa a cada visita e obter informação adicional sobre os pontos de interesse.

Agentes Externos. Como forma de enriquecer o conjunto de dados, recorreu-se a dois agentes externos, nomeadamente Foursquare e Forecastio. Estes agentes fornecem serviços, que permitem obter informação adicional relativa aos pontos de interesse e, ao contexto de cada visita. A informação adicional relativa aos pontos de interesse é obtida através do identificador do ponto de interesse. Já a informação contextual é obtida através da localização e da marca temporal associada a cada visita.

Pontos de interesse. Os atributos relativos ao ponto de interesse foram capturados através de pedidos efetuados a um dos serviços disponibilizado pelo Foursquare. Desta forma foi desenvolvida uma rotina que faz uso da "Venue API",³ fornecida pelo Foursquare, onde para cada identificador de um ponto de interesse é efetuado um pedido, que devolve toda a informação relativa a esse ponto. A informação é obtida no formato *JavaScript Object Notation* (JSON), sendo de seguida armazenada.

Contexto. Através da localização e da marca temporal de uma visita é possível obter parte do contexto, nomeadamente o estado climatérico e a temperatura. Para a a recolha desta informação, foram efetuados pedidos ao serviço disponibilizado pelo Forecastio. Desta forma, foi desenvolvida uma rotina que, através do serviço disponibilizado pelo Forecastio, "time machine"⁴ permite para uma dada localização e marca temporal, obter informação relativa ao estado climatérico e temperatura (Forecastio). Esta informação também é obtida no formato JSON. Dado o facto de só ser possível efetuar um pedido por minuto, optou-se por uma estratégia que tem como objetivo reduzir o número de pedidos. Desta forma agruparam-se as visitas num intervalo de uma hora, sendo que todas as visitas efetuadas nessa hora terão a mesma condição climatérica e temperatura. Para além disto, todos os pedidos efetuados são para a localização de Nova Iorque. Ou seja o pedido efetuado para todas as visitas em Nova York entre as 14:00 e as 14:59 do dia 5 janeiro de 2013 será da forma, *latitude* = 40.730610, *longitude* = -73.935242, *timestamp* = 1357394400, onde esta marca temporal (*timestamp*) descreve a diferença em segundos entre o tempo atual e a data de 1 de Janeiro de 1970, *Unix Timestamp*. A informação relativa à estação do ano, momento do dia e momento da semana foi obtida através de rotinas que envolvem funções fornecidas pelo sistema de gestão de base de dados.

4.2 ENTIDADES

Após o conjunto de dados ter sido enriquecido, procedeu-se à caracterização das entidades apresentadas em 3.1.

Utilizador. Esta entidade apenas apresenta uma única característica, sendo esta o seu identificador. Esta escassez de informação, deve-se aos direitos de privacidade aplicados pelo agente externo que fornece as atividades referentes a cada utilizador.

Ponto de interesse. O ponto de interesse tem como características chave, um identificador único, uma localização, uma categoria e uma subcategoria.

³<https://developer.foursquare.com/docs/venues/venues>

⁴<https://darksky.net/dev/docs/time-machine>

Contexto. A informação contextual é descrita através de cinco dimensões, em que cada dimensão é definida por um conjunto de condições contextuais.

Temperatura

- Frio
- Ameno
- Quente

Momento do Dia

- Manhã
- Tarde
- Noite

Condição Climatérica

- Céu Limpo
- Céu Nublado
- Vento e Céu Nublado
- Céu Coberto
- Chuva
- Vento e Chuva
- Neve
- Nevoeiro
- Vento
- Arejado
- Aguaceiros
- Seco

Estação do Ano

- Primavera
- Verão
- Outono
- Inverno

Momento da Semana

- Dia de Trabalho
- Fim de Semana

4.3 MODELO MULTIDIMENSIONAL DE RECOMENDAÇÃO

Nesta secção é apresentada a instanciação do modelo multidimensional de recomendação. O modelo descreve as visitas efetuadas pelos utilizadores U a pontos de interesse P num dado contexto. Este contexto é composto pelas dimensões, momento do dia D , momento da semana W , estação do ano A , estado climatérico F e temperatura T . Desta forma espaço de recomendação S é definido por:

$$S = U \times P \times D \times W \times A \times F \times T \quad (4.1)$$

A figura 4.1, apresenta o esquema relativo a essas visitas. O esquema é apresentado de acordo com a notação *Dimensional Fact Model* (DFM) (Rizzi, 2008).

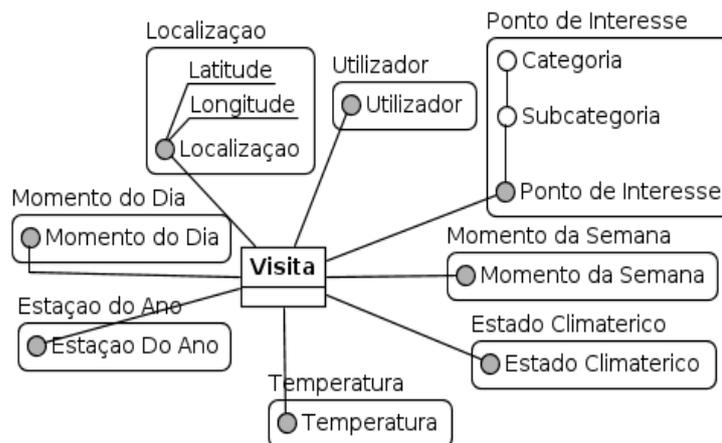


Figura 4.1: Modelo Multidimensional de recomendação

Na figura 4.1 verifica-se a presença de oito dimensões relacionadas entre si através da tabela de factos. Cada uma destas dimensões é caracterizada pelo subconjunto de características:

- $Utilizador \subseteq Identificador$
- $Ponto\ de\ Interesse \subseteq Identificador \times Nome \times Endere\c{o} \times Subcategoria \times Categoria$
- $Momento\ do\ dia \subseteq Identificador \times Designa\c{c}\tilde{a}o$
- $Momento\ da\ semana \subseteq Identificador \times Designa\c{c}\tilde{a}o$
- $Esta\c{c}\tilde{a}o\ do\ Ano \subseteq Identificador \times Designa\c{c}\tilde{a}o$
- $Estado\ Climat\acute{e}rico \subseteq Identificador \times Designa\c{c}\tilde{a}o$
- $Temperatura \subseteq Identificador \times Designa\c{c}\tilde{a}o$
- $Localiza\c{c}\tilde{a}o \subseteq Identificador \times Latitude \times Longitude$

Hierarquias nos métodos de recomendação. As hierarquias permitem analisar as dimensões a vários níveis de detalhe. Para além disto o uso de hierarquias pode contornar a esparsidade existente no conjunto de dados. No modelo multidimensional apenas a dimensão ponto de interesse tem associada a si uma hierarquia. Desta forma, é assim possível agregar as visitas efetuadas por subcategoria ou por categoria. A figura 4.2 ilustra a hierarquia associada à dimensão ponto de interesse.

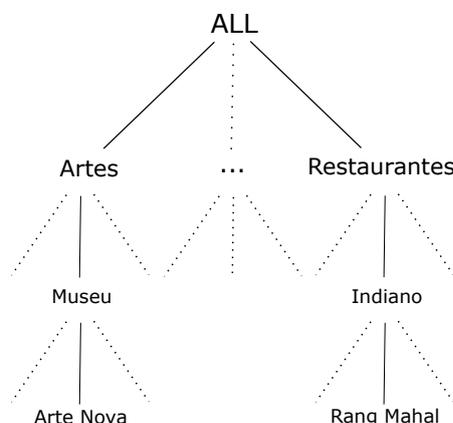


Figura 4.2: Taxonomia - Ponto de Interesse

Os métodos de recomendação apresentados em 3.5 e 3.6 baseiam-se na frequência de visitas aos pontos de interesse que são visitados para uma dada situação contextual. Caso a situação contextual atual seja composta por todas as dimensões contextuais, pode dar-se o caso de não existirem visitas aos pontos de interesse para essa mesma situação contextual. Se ao invés de calcular a frequência para cada ponto de interesse, esta for efetuada para subcategorias ou categorias, o problema da esparsidade poderá ser ultrapassado em muitos casos. No método descrito em 3.6, o uso da hierarquia permite relacionar os pontos de interesse já visitados pelo utilizador com os pontos a visitar por este. Sem o uso desta hierarquia não era possível efetuar recomendações personalizadas.

4.4 TECNOLOGIAS APLICADAS

Dada à necessidade de armazenamento e análise de dados foi utilizado o sistema de base de dados PostgreSQL. Este sistema foi escolhido, pois permite uma extensão onde é possível manipular objetos espaciais (PostGIS).

As rotinas responsáveis pela execução de pedidos aos agentes externos foram desenvolvidas através da linguagem de programação Python. Para além disso, tanto os métodos de recomendação como a interface para a base de dados foram desenvolvidos recorrendo a esta linguagem.

AVALIAÇÃO EXPERIMENTAL

Neste capítulo será abordada a avaliação dos métodos de recomendação, permitindo comparar a efetividade destes. Para que esta avaliação seja efetuada, é necessário determinar os objetivos e condicionantes que fazem parte do sistema de recomendação. Visto que a avaliação segue o protocolo *offline*, será também abordada a estratégia de segmentação do conjunto de dados, assim como as métricas utilizadas na avaliação. Por fim, serão apresentados e discutidos os resultados obtidos através da avaliação efetuada.

5.1 OBJETIVOS E CONDICIONANTES DO SISTEMA

Como já foi referido anteriormente, o sistema de recomendação fornece uma lista de pontos de interesse. Nesta lista, os pontos de interesse estão ordenados pela sua pontuação, que se baseia na contagem de visitas, tendo associadas a si uma situação contextual. Consequentemente, esta pontuação depende assim destas situações contextuais. Logo, um dos objetivos desta avaliação passa pela análise do comportamento dos utilizadores, de forma a determinar os fatores que influenciam a sua tomada de decisão. Para além disto, no caso dos métodos de frequência contextual e de personalização, poderão existir problemas derivados da esparsidade existente no conjunto de dados. Assim outro dos objetivos, é verificar a influência do uso da hierarquia associada à dimensão ponto de interesse na obtenção de recomendações.

5.2 METODOLOGIA

A avaliação dos métodos de recomendação neste projeto segue o protocolo *offline*. Este protocolo visa simular um cenário real de avaliação dos sistemas de recomendação, recorrendo a um conjunto de dados que contém o histórico de visitas efetuadas a pontos de interesse.

Como forma de simular a avaliação efetuada num cenário real, o conjunto de dados é segmentado em duas partições, sendo estas a partição de treino e a partição de teste. Assim a partição de treino é utilizada no treino dos métodos e a partição de teste é usada na avaliação destes. Sendo estas partições

disjuntas, as visitas presentes na partição de teste não entram no treino dos métodos, pretendendo-se desta forma obter resultados próximos dos obtidos nos cenários reais.

5.2.1 SEGMENTAÇÃO DO CONJUNTO DE DADOS

A segmentação do conjunto de dados baseia-se no método *hold-hout*. Deste modo existe apenas um conjunto de treino e teste disponível para avaliação dos métodos. Dado que cada visita tem associada a si uma marca temporal, o conjunto de dados é assim dividido, recorrendo a este intervalo. Para cada utilizador são retiradas vinte por cento das suas visitas. Desta forma o conjunto de teste é formado por vinte por cento das visitas registadas no conjunto de dados e o conjunto de treino é composto pelas restantes visitas.

5.2.2 MÉTRICAS

Devido à diversidade de métricas existentes, é necessária a escolha das que mais se adequam aos objetivos do sistema de recomendação e condicionantes associadas a este.

As métricas de previsão de avaliações baseiam-se no poder de previsão do sistema de recomendação. Embora estas métricas sejam bastante utilizadas na avaliação dos sistemas de recomendação, estas não se enquadram no objetivo do problema. Pois para além de este sistema não possuir opiniões explícitas por parte do utilizador, as recomendações obtidas são na forma de uma lista.

Dado que a amostra retirada do conjunto de teste apenas considera uma visita por utilizador, não é possível assim obter a relevância de outros itens para cada utilizador. Assim foram postas de parte a *precision* e a NDCG. Para além disto, como cada lista de recomendação pode ter dimensão variável, a métrica ARHR também foi posta de parte. Assim foi utilizada a métrica HR e a métrica baseada no fator de decréscimo, onde esta última representa o erro obtido, com base na posição do ponto de interesse para cada recomendação.

5.2.3 CENÁRIOS E PARÂMETROS DE AVALIAÇÃO

O sistema de recomendação fornece recomendações de acordo com os parâmetros que lhe são fornecidos. Para avaliação dos métodos de recomendação foram considerados os seguintes parâmetros:

- Momento da semana
- Momento do dia
- Estação do ano
- Estado climatérico
- Temperatura
- Localização
- Raio de ação

- Identificador do utilizador
- Nível hierárquico

Parte destes parâmetros são definidos através da informação associada a cada visita presente na amostra, sendo estes a localização, o identificador do utilizador e a informação contextual associada à visita. Desta forma é necessário definir o raio de ação e o nível hierárquico. Como já foi referido acima, não é possível através dos dados fornecidos, obter a localização do utilizador no momento da tomada de decisão. Deste modo foi definido um raio de 400 metros, assumindo o pressuposto de que o utilizador se encontrava a pé no momento da tomada de decisão (Duncan et al., 2011). Quanto ao nível hierárquico, este pode assumir três valores, sendo estes, o próprio ponto de interesse que foi visitado, a subcategoria e a categoria a que este pertence. Através deste parâmetro, é assim possível para os métodos de frequência contextual e de personalização, que a pontuação atribuída a cada ponto de interesse possa ser associada a uma subcategoria ou categoria.

Foram definidos cenários de teste para cada um dos métodos de recomendação. Estes cenários têm como objetivo demonstrar a relevância das dimensões contextuais e o uso dos níveis hierárquicos nas recomendações.

Para o método de dominância contextual, apenas foram definidos dois cenários. No primeiro, a situação contextual considera apenas uma dimensão e no segundo, a situação contextual engloba todas as dimensões contextuais. Visto que este método não permite a agregação de visitas por nível, os cenários acima só são aplicados ao nível do ponto de interesse.

Para o método de frequência contextual foram definidos os mesmos cenários, replicando-os para as recomendações efetuadas por subcategoria e categoria. Para o método de personalização, foram apenas definidos cenários para os casos onde a recomendação é efetuada por subcategoria e categoria, dado que este método não efetua recomendações ao nível do ponto de interesse.

5.3 RESULTADOS

Nesta secção serão apresentados e discutidos os resultados obtidos em cada cenário de teste. Inicialmente é efetuada uma comparação entre a dominância contextual e a frequência contextual. De seguida são apresentados os resultados obtidos para o método de frequência contextual, nos casos onde a recomendação é efetuada por ponto de interesse, subcategoria e categoria. São também apresentados os resultados referentes ao método de personalização que tem em conta as recomendações por subcategoria e categoria. Por fim, será efetuada a comparação entre o método de frequência contextual e de personalização.

5.3.1 DOMINÂNCIA CONTEXTUAL VERSUS FREQUÊNCIA CONTEXTUAL

Nas tabelas 5.1 e 5.2 são apresentados os resultados obtidos para cada cenário de teste, utilizando os métodos de dominância contextual e frequência contextual. A métrica HR, está associada ao número de pontos de interesse presentes no conjunto de teste, que aparecem na lista de recomendação de dimensão n , em que n varia entre dois e trinta e dois. O erro médio é obtido através da métrica

baseada no fator de decréscimo, que tem em conta a posição que o ponto de interesse ocupa na lista. Por fim, é apresentada a cobertura, que representa a percentagem de recomendações onde o ponto de interesse teve pontuação não nula.

Tabela 5.1: Dominância Contextual - Ponto de Interesse

	Hit-Rate					Erro médio	Cobertura
	Top-2	Top-4	Top-8	Top-16	Top-32		
Momento Dia	0.281	0.393	0.502	0.609	0.718	0.358	0.661
Momento Semana	0.232	0.335	0.449	0.561	0.653	0.429	0.796
Estado Climatérico	0.222	0.335	0.449	0.534	0.624	0.453	0.870
Temperatura	0.236	0.342	0.465	0.575	0.665	0.435	0.617
Estação Ano	0.245	0.359	0.479	0.581	0.671	0.409	0.594
Todas	0.324	0.446	0.548	0.663	0.759	0.281	0.998

Tabela 5.2: Frequência Contextual - Ponto de Interesse

	Hit-Rate					Erro médio	Cobertura
	Top-2	Top-4	Top-8	Top-16	Top-32		
Momento Dia	0.262	0.367	0.497	0.617	0.716	0.344	0.950
Momento Semana	0.210	0.321	0.449	0.555	0.624	0.442	0.974
Estado Climatérico	0.186	0.306	0.410	0.524	0.611	0.495	0.976
Temperatura	0.225	0.332	0.454	0.563	0.654	0.421	0.946
Estação Ano	0.260	0.368	0.484	0.574	0.677	0.375	0.914
Todas	0.285	0.417	0.541	0.644	0.749	0.337	0.523

O gráfico 5.1 ilustra a comparação do erro médio obtido nos métodos de dominância contextual e frequência contextual. Para cada método também é possível obter a comparação entre as situações contextuais consideradas.

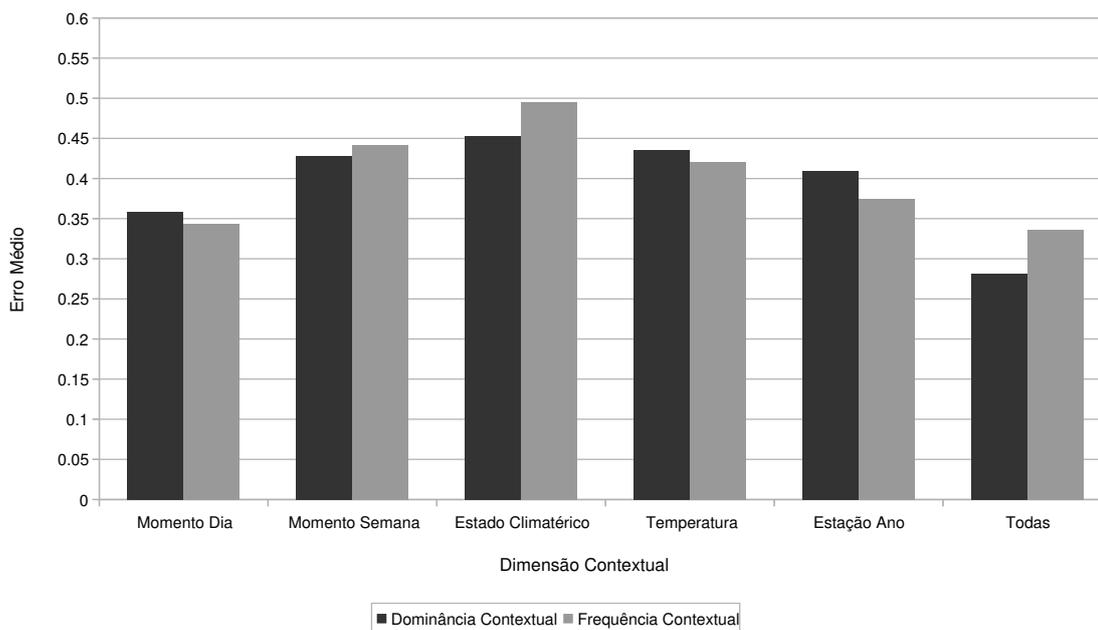


Figura 5.1: Erro médio das recomendações referentes aos métodos dominância e frequência contextual.

Através da análise do gráfico 5.1 é possível constatar que cada dimensão contextual tem um impacto diferente nas recomendações obtidas. Verifica-se que para o método de dominância contextual, as dimensões que apresentam menor erro são, o momento do dia, a estação do ano, o momento da semana, a temperatura e o estado climatérico. Já no caso da frequência contextual, estas dimensões são, o momento do dia, a estação do ano, a temperatura, o momento da semana e o estado climatérico. Constata-se também, que o menor erro médio é obtido no caso em que a situação contextual é composta por todas as dimensões contextuais.

A frequência contextual apresenta um menor erro médio em relação à dominância contextual nas dimensões momento do dia, temperatura e estação do ano, apresentando um maior erro médio nas restantes dimensões. Em termos de HR, verifica-se que a dominância contextual supera a frequência contextual, evidenciando-se nos casos em que o ponto de interesse aparece nos dois e quatro primeiros lugares. Em termos de cobertura, a dominância contextual supera a frequência contextual no caso em que a situação contextual é composta por todas as dimensões. Já no caso em que a situação contextual é definida apenas por uma dimensão, a dominância contextual é superada pela frequência contextual.

5.3.2 FREQUÊNCIA CONTEXTUAL

PONTO DE INTERESSE, SUBCATEGORIA E CATEGORIA

Nas tabelas 5.3 e 5.4 são apresentados os resultados obtidos para o método de frequência contextual no caso onde a situação contextual é composta por uma dimensão e, no caso onde esta é constituída por todas as dimensões contextuais.

Tabela 5.3: Frequência Contextual - Subcategoria

	Hit-Rate					Erro médio	Cobertura
	Top-2	Top-4	Top-8	Top-16	Top-32		
Momento Dia	0.260	0.368	0.487	0.605	0.707	0.354	0.976
Momento Semana	0.214	0.330	0.451	0.557	0.650	0.435	0.991
Estado Climatérico	0.196	0.309	0.406	0.515	0.609	0.500	0.984
Temperatura	0.224	0.320	0.449	0.557	0.650	0.436	0.968
Estação Ano	0.254	0.359	0.473	0.573	0.670	0.394	0.946
Todas	0.278	0.402	0.514	0.620	0.717	0.356	0.605

Tabela 5.4: Frequência Contextual - Categoria

	Hit-Rate					Erro médio	Cobertura
	Top-2	Top-4	Top-8	Top-16	Top-32		
Momento Dia	0.248	0.365	0.483	0.590	0.694	0.402	0.994
Momento Semana	0.236	0.344	0.461	0.559	0.670	0.437	1.000
Estado Climatérico	0.206	0.314	0.416	0.535	0.642	0.500	0.996
Temperatura	0.233	0.339	0.451	0.553	0.645	0.469	0.992
Estação Ano	0.237	0.352	0.458	0.563	0.676	0.440	0.982
Todas	0.249	0.353	0.480	0.577	0.684	0.415	0.725

O gráfico 5.2 apresenta o erro médio obtido em cada um dos cenários de teste aplicados ao método de frequência contextual.

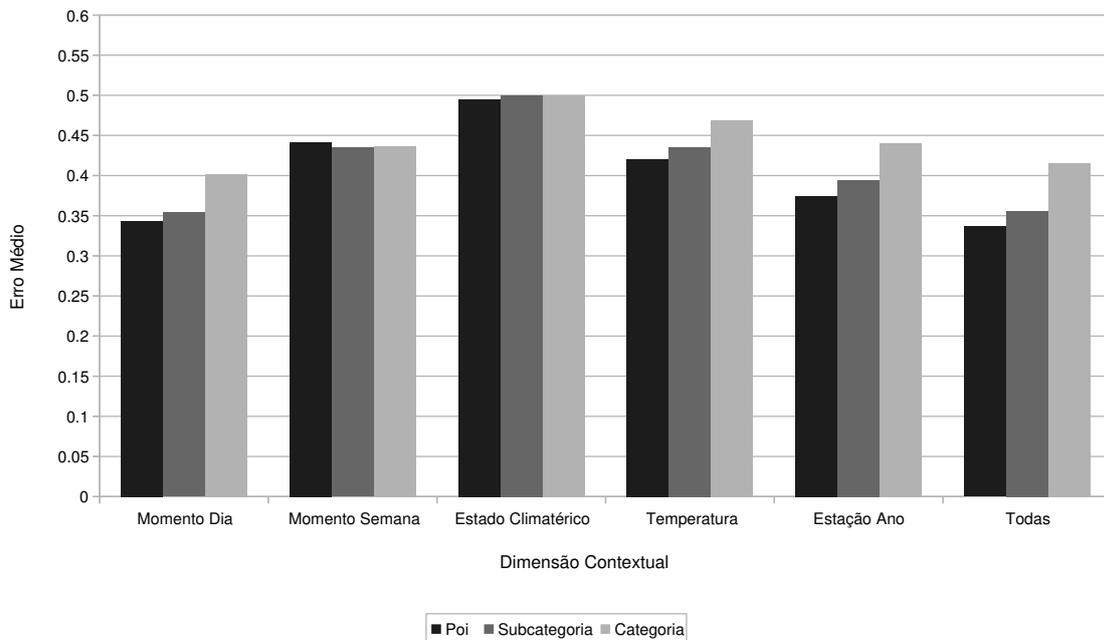


Figura 5.2: Erro médio associado a recomendações obtidas pela frequência contextual tendo em conta o ponto de interesse, subcategoria e categoria.

Como se pode constatar no gráfico 5.2, no cenário de recomendação por subcategoria, as dimensões contextuais que apresentam menor erro são, o momento do dia, a estação do ano, o momento da semana, a temperatura e o estado climatérico. Já no caso da recomendação por categoria, estas dimensões são, o momento do dia, o momento da semana, a estação do ano, a temperatura e o estado climatérico.

Verifica-se que, com o uso da subcategoria e categoria na geração de recomendações, o erro médio aumenta e os valores referentes à métrica HR diminuem, contudo a cobertura também aumenta.

5.3.3 PERSONALIZAÇÃO

SUBCATEGORIA VERSUS CATEGORIA

Nas tabelas 5.5 e 5.6 são apresentados os resultados referentes às recomendações efetuadas pelo método de personalização para os cenários de recomendação por subcategoria e categoria.

Tabela 5.5: Personalização - Subcategoria

	Hit-Rate					Erro médio	Cobertura
	Top-2	Top-4	Top-8	Top-16	Top-32		
Momento Dia	0.280	0.410	0.525	0.655	0.747	0.175	0.774
Momento Semana	0.254	0.364	0.498	0.609	0.719	0.196	0.788
Estado Climatérico	0.220	0.344	0.456	0.571	0.661	0.207	0.785
Temperatura	0.215	0.350	0.489	0.614	0.702	0.207	0.737
Estação Ano	0.238	0.370	0.500	0.617	0.731	0.189	0.730
Todas	0.299	0.437	0.548	0.643	0.737	0.182	0.375

Tabela 5.6: Personalização - Categoria

	Hit-Rate					Erro médio	Cobertura
	Top-2	Top-4	Top-8	Top-16	Top-32		
Momento Dia	0.216	0.307	0.416	0.534	0.655	0.302	0.961
Momento Semana	0.178	0.279	0.388	0.493	0.626	0.328	0.977
Estado Climatérico	0.174	0.253	0.369	0.456	0.566	0.388	0.980
Temperatura	0.175	0.266	0.372	0.478	0.597	0.363	0.953
Estação Ano	0.189	0.284	0.392	0.493	0.622	0.338	0.938
Todas	0.221	0.326	0.452	0.552	0.673	0.260	0.543

A figura 5.3 ilustra o erro médio obtido nas recomendações efetuadas por subcategoria e categoria, nos casos onde a situação contextual é definida apenas por uma dimensão e por todas as dimensões.

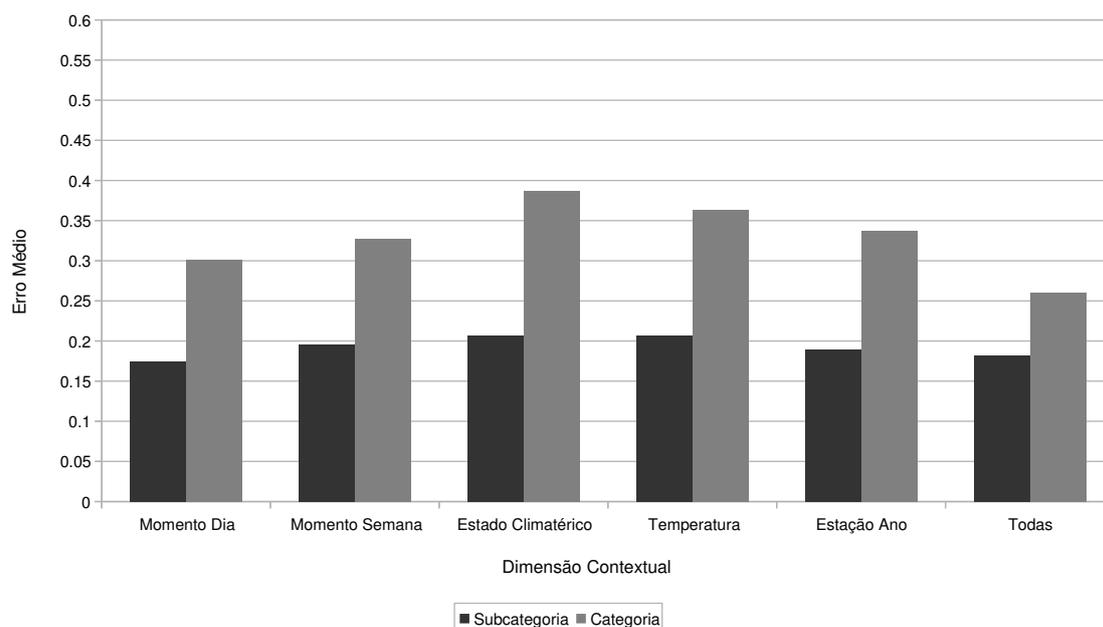


Figura 5.3: Erro médio associado a recomendações por subcategoria e categoria.

Como é possível verificar através da figura 5.3, nas recomendações efetuadas por subcategoria, as dimensões contextuais que apresentam menor erro são, o momento do dia, a estação do ano, o momento da semana, a temperatura e o estado climático. Já no caso em que as recomendações são efetuadas por categoria, as dimensões que apresentam menor erro são, o momento do dia, o momento da semana, a estação do ano, a temperatura e o estado climático. Também se verifica que as recomendações por subcategoria tem menor erro médio e maiores valores de HR em relação às recomendações efetuadas por categoria. Contudo pela tabelas 5.5 e 5.6 verifica-se que a recomendação por categoria apresenta uma maior cobertura nas recomendações efetuadas.

5.3.4 FREQUÊNCIA CONTEXTUAL VERSUS PERSONALIZAÇÃO

As figuras 5.4 e 5.5 apresentam o erro médio obtido para os métodos de frequência contextual e de personalização, nos cenários de recomendação por subcategoria e categoria.

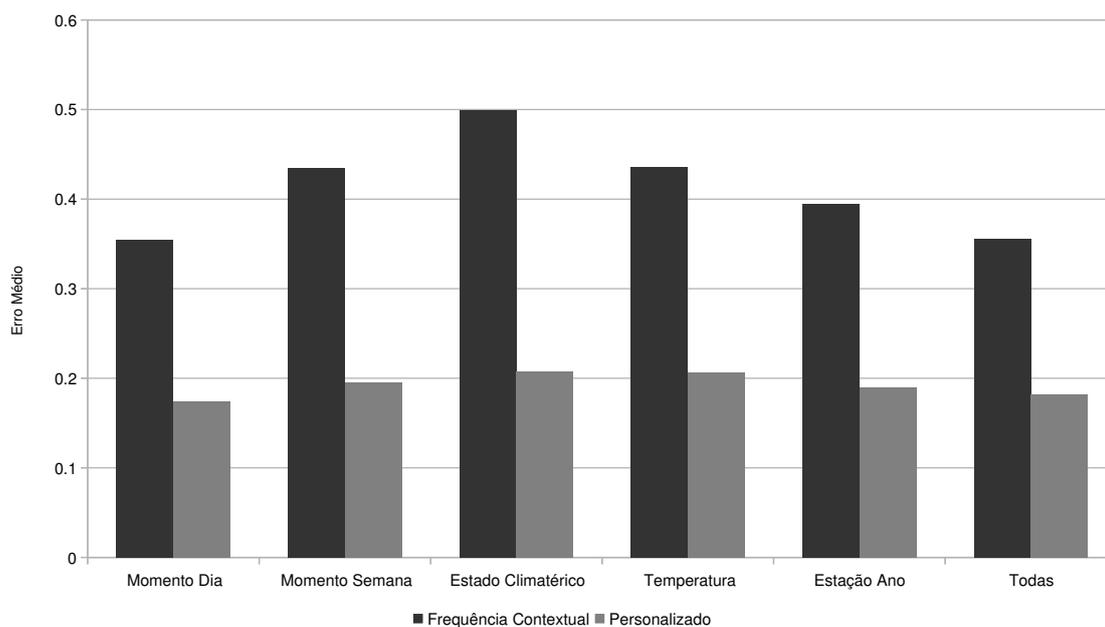


Figura 5.4: Erro médio associado a recomendações por subcategoria nos métodos de frequência contextual e de personalização.

Através da análise da figura 5.4, é possível verificar que o método de personalização apresenta um menor erro médio e um HR maior em relação ao método de frequência contextual, contudo também apresenta uma menor cobertura.

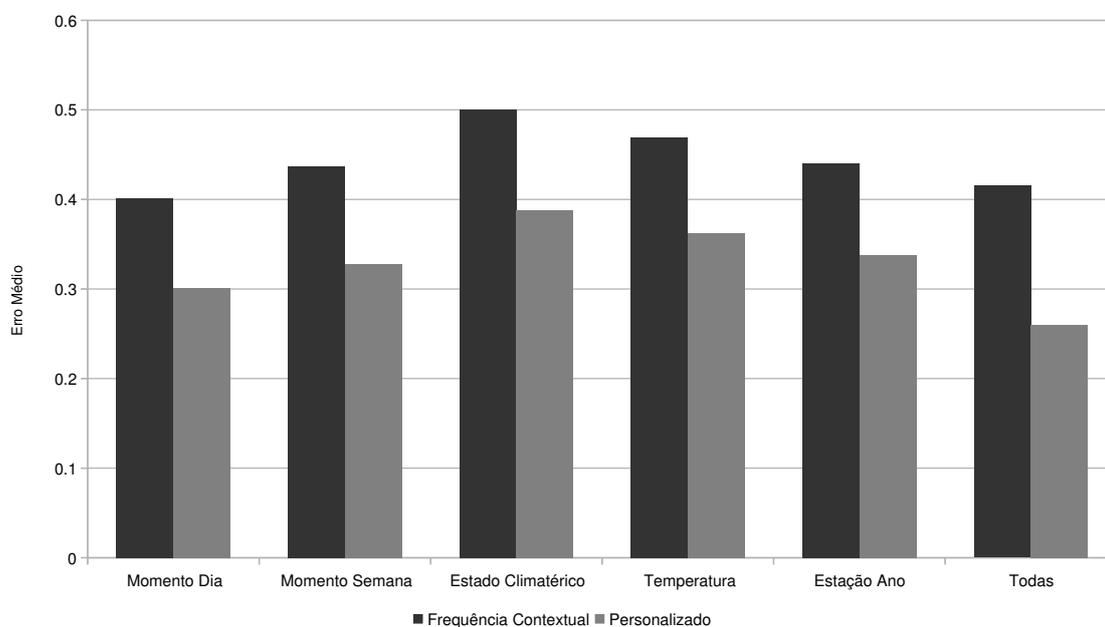


Figura 5.5: Erro médio associado a recomendações por categoria nos métodos de frequência contextual e de personalização.

Recorrendo à figura 5.5 verifica-se que o método de personalização apresenta um menor erro médio

e HR maior, em relação à frequência contextual. Contudo o método de personalização apresenta uma menor cobertura em relação ao método de frequência contextual. Verifica-se também que a diferença do erro médio obtido entre os métodos é maior no caso da recomendação efetuada por subcategoria.

5.4 DISCUSSÃO

Nesta secção serão discutidos os resultados obtidos em 5.3, apresentando assim as vantagens e desvantagens de cada método de recomendação. Como se pode verificar através dos resultados obtidos, existe uma relação entre a métrica HR e o erro médio obtido através da métrica baseada no fator de decréscimo. Desta forma, as vantagens e desvantagens de cada método serão discutidas com base no erro médio e na cobertura.

Verifica-se que o método de dominância apresenta vantagens nos cenários onde a situação contextual é composta por todas as dimensões contextuais, pois apresenta um menor erro médio em relação à frequência contextual, tendo quase o dobro da cobertura. No entanto para o caso em que a situação contextual é definida apenas por uma dimensão, o método de frequência contextual apresenta uma maior cobertura em todos os casos, e em 3 destes, apresenta menor erro médio. Isto deve-se ao modo como os métodos calculam a pontuação para cada ponto de interesse. Na dominância, a pontuação atribuída a cada ponto de interesse resulta da soma de cada dimensão contextual considerada. Assim quanto maior for o número de dimensões consideradas, maior será a probabilidade da pontuação atribuída não ser nula. Já no caso da frequência contextual acontece o inverso, ou seja, quantas mais dimensões forem consideradas, maior é a probabilidade da pontuação ser nula.

Em relação ao método de frequência contextual, verifica-se que o uso dos níveis hierárquicos influencia as recomendações obtidas. À medida que o nível usado para recomendação é maior, maior é o erro médio obtido, contudo a cobertura também é maior. Isto deve-se ao facto da pontuação atribuída a um ponto de interesse resultar da agregação das visitas efetuadas por subcategoria, ou categoria. Ou seja, a pontuação atribuída a um ponto de interesse pertencente a uma subcategoria, resulta da soma das visitas feitas àquela subcategoria numa dada situação contextual. Logo, quanto mais se sobe na hierarquia, maior é a probabilidade de existirem visitas para uma dada situação contextual fazendo com que a pontuação atribuída não seja nula.

No método de personalização, os efeitos do uso dos níveis hierárquicos são os mesmos que no método de frequência contextual. Ou seja, à medida que se sobe na hierarquia, maior é o erro médio, mas a cobertura também é maior.

Embora a frequência contextual apresente uma maior cobertura relativamente ao método de personalização, este último apresenta menor erro médio nas recomendações obtidas. Isto deve-se ao facto da pontuação atribuída a cada ponto de interesse no método de frequência contextual, considerar as visitas de todos os utilizadores na subcategoria ou categoria associada ao ponto. Já no caso do método de personalização, a pontuação do ponto de interesse, só tem em conta as visitas efetuadas pelo utilizador na subcategoria ou categoria associada ao ponto. Assim, no método de frequência contextual a lista de recomendação obtida é igual para todos os utilizadores, enquanto a lista obtida

através do método de personalização é ajustada ao utilizador.

CONCLUSÃO

Foi proposto nesta dissertação, a análise e desenvolvimento de um processo de recomendação orientado ao contexto, com base em geolocalização e opinião implícita. De forma a desenvolver um processo de recomendação, foram exploradas técnicas de recomendação existentes. Visto que se trata de um processo de recomendação orientado ao contexto, também foram averiguadas abordagens acerca da modelação da informação contextual e inclusão desta no processo de recomendação. Foram também exploradas métricas de avaliação, com o intuito de determinar a efetividade dos métodos de recomendação abordados. Para a implementação e avaliação do processo de recomendação, foi selecionado um conjunto de dados. Este conjunto contém visitas efetuadas por utilizadores a pontos de interesse, que posteriormente foi enriquecido com informação relativa aos pontos de interesse e contexto, recorrendo a agentes externos. Com base neste conjunto de dados e nos métodos de recomendação abordados, procedeu-se à avaliação destes métodos.

Foram definidas à priori cinco dimensões contextuais que representam assim o contexto no processo de recomendação, nomeadamente o momento do dia, o momento da semana, a temperatura, a estação do ano e o estado climatérico. O processo de recomendação tem como tarefas, a aquisição da situação contextual atual, seguido da filtragem de pontos de interesse com base na localização atual e um raio de ação definido. Após ter sido feita esta filtragem, é aplicado o método de recomendação atribuindo uma pontuação a cada ponto de interesse dentro desse raio de ação. Por fim é apresentada uma lista composta pelos pontos de interesse ordenados pela pontuação.

Foram desenvolvidos dois métodos de recomendação, o primeiro método baseia-se num sistema de popularidade e o segundo é baseado num sistema de personalização. Estes dois métodos, responsáveis pela pontuação a um ponto de interesse, baseiam-se na frequência de visitas efetuadas a esse ponto de interesse numa dada situação contextual. No primeiro método são consideradas todas as visitas ao ponto de interesse e no segundo método apenas as visitas do utilizador são consideradas. De forma a combater a esparsidade, foi implementado um modelo de dados multidimensional, onde a dimensão ponto de interesse tem associada a si uma hierarquia composta por níveis. Sendo estes o próprio ponto de interesse, a subcategoria e a categoria. Assim no caso do método baseado em popularidade é possível efetuar recomendações por ponto de interesse, subcategoria e categoria, e no método baseado em personalização é possível efetuar recomendações por subcategoria e categoria.

Para a implementação deste processo de recomendação, selecionou-se um conjunto de dados obtido através da rede social baseada em localização *Foursquare*. Este conjunto de dados contém visitas efetuadas a pontos de interesse na cidade de Nova Iorque. De forma a determinar a informação contextual associada a cada visita e obter informação adicional relativa aos pontos de interesse, recorreu-se a agentes externos, nomeadamente o *Foursquare* e o *Forecastio*.

A métrica HR e a métrica baseada no fator de decréscimo apresentada em Miranda (2013), foram as propostas para avaliação dos métodos de recomendação, devido à opinião implícita por parte dos utilizadores, e devido à dimensão das listas de recomendação ser variável. Esta avaliação tem assim como objetivo determinar a influência das dimensões contextuais e uso de níveis hierárquicos nas recomendações.

Em relação às dimensões contextuais, verifica-se que o momento do dia é a dimensão para a qual se obtém menor erro médio. Verifica-se também que na maior parte dos métodos, o menor erro médio é obtido no caso em que a situação contextual é composta por todas as dimensões.

Através dos resultados obtidos, conclui-se que o método apresentado em Miranda (2013) é vantajoso em relação ao método de frequência contextual no caso onde a situação contextual é composta por todas as dimensões contextuais, pois apresenta um menor erro médio e uma maior cobertura. Contudo, no caso em que a situação contextual é composta apenas por uma dimensão, o método proposto supera a dominância contextual em termos de erro médio para três das dimensões e, em termos de cobertura supera para as cinco dimensões. Verifica-se também que o uso dos níveis hierárquicos, subcategoria e categoria no método de frequência contextual e de personalização, resultam num maior erro médio, mas também tendem a ter uma maior cobertura. Em relação a estes métodos, verifica-se que embora a frequência contextual supere o método de personalização em termos de cobertura, este é superado em termos de erro médio. Pode-se assim concluir que existe nos métodos apresentados um compromisso entre a cobertura e o erro médio.

Através do objetivo proposto nesta dissertação, foi possível consolidar conhecimentos relativamente à linguagem Python, devido à maior parte das rotinas terem sido escritas nesta linguagem. Dado o sistema ser também orientado a geolocalização, foi possível obter conhecimento relativo à manipulação de dados geoespaciais em base de dados, usando para este fim o sistema de gestão de base de dados PostgreSQL e a extensão denominada de PostGIS.

Com base no que foi desenvolvido neste projeto, poderá ser concebida uma aplicação de forma a integrar o processo de recomendação. Para além disto, ainda poderão ser determinadas as dimensões contextuais relevantes a incluir neste processo.

REFERÊNCIAS BIBLIOGRÁFICAS

- (2004). UbiquiTO: A Multi-device Adaptive Guide. In *Mobile Human-Computer Interaction*, volume 3160 of *LNCS*, pages 538–540.
- Abbar, S., Bouzeghoub, M., and Stéphane, L. (2009). Context-Aware Recommender Systems : A Service-Oriented Approach. In *3rd International Workshop on Personalized Access, Profile Management, and Context Awareness in Databases, PersDB 2009 - In Conjunction with VLDB 2009*, pages 1–6.
- Adomavicius, G. and Tuzhilin, A. (2001). Multidimensional recommender systems: A data warehousing approach. In Fiege, L., Mühl, G., and Wilhelm, U., editors, *Electronic Commerce*, volume 2232 of *Lecture Notes in Computer Science*, pages 180–192. Springer Berlin Heidelberg.
- Adomavicius, G. and Tuzhilin, A. (2005a). Incorporating Context into Recommender Systems Using Multidimensional Rating Estimation Methods. In *Proceedings of the 1st International Workshop on Web Personalisation, Recommender Systems and Intelligent User Interfaces, ICETE '05*, pages 3–13.
- Adomavicius, G. and Tuzhilin, A. (2005b). 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*, 17(6):734–749.
- Adomavicius, G. and Tuzhilin, A. (2010). Context-aware recommender systems. In *Recommender Systems Handbook: A Complete Guide for Research Scientists and Practitioners*, volume 23, page 37. Springer.
- Adomavicius, G. and Tuzhilin, A. (2015). Context-aware recommender systems. *AI Magazine*, 32:67–80.
- Aggarwal, C. C. (2016). *Recommender Systems: The TextBook*. Springer International Publishing.
- Anand, S. S. and Mobasher, B. (2007). Contextual Recommendation. In Berendt, B., Hotho, A., Mladenic, D., and Semeraro, G., editors, *From Web to Social Web: Discovering and Deploying User and Content Profiles*, pages 142–160. Springer Berlin Heidelberg.
- Baltrunas, L. and Amatriain, X. (2009). Towards Time-Dependant Recommendation based on Implicit Feedback. In *Workshop on Context-aware Recommender Systems in conjunction with the 3rd ACM Conference on Recommender Systems, RecSys '09*.
- Baltrunas, L., Ludwig, B., Peer, S., and Ricci, F. (2011a). Context-aware places of interest recommendations and explanations. In *19th International Conference on User Modeling, Adaptation and Personalization, UMAP '11*, pages 19–26.
- Baltrunas, L., Ludwig, B., Peer, S., and Ricci, F. (2012). Context relevance assessment and exploitation in mobile recommender systems. *Personal and Ubiquitous Computing*, 16(5):507–526.

- Baltrunas, L., Ludwig, B., and Ricci, F. (2011b). Matrix Factorization Techniques for Context Aware Recommendation. In *Proceedings of the Fifth ACM Conference on Recommender Systems, RecSys '11*, pages 301–304.
- Baltrunas, L. and Ricci, F. (2009). Context-based Splitting of Item Ratings in Collaborative Filtering. In *Proceedings of the Third ACM Conference on Recommender Systems, RecSys '09*, pages 245–248. ACM.
- Bellogín, A. (2012). *Performance prediction and evaluation in Recommender Systems: an Information Retrieval perspective*. PhD thesis, Escuela Politécnica Superior, Universidad Autónoma de Madrid.
- Bobadilla, J., Ortega, F., Hernando, A., and Gutiérrez, A. (2013). Recommender systems survey. *Knowledge-Based Systems*, 46:109–132.
- Burke, R. (2002). Hybrid recommender systems: Survey and experiments. *User Modeling and User-Adapted Interaction*, 12(4):331–370.
- Burke, R. (2007). Hybrid Web Recommender Systems. In Brusilovsky, P., Kobsa, A., and Nejdl, W., editors, *The Adaptive Web: Methods and Strategies of Web Personalization*, pages 377–408. Springer Berlin Heidelberg.
- Cheverst, K., Davies, N., Mitchell, K., Friday, A., and Efstratiou, C. (2000). Developing a context-aware electronic tourist guide: Some issues and experiences. In *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems, CHI '00*, pages 17–24.
- Deshpande, M. and Karypis, G. (2004). Item-based top- N recommendation algorithms. *ACM Transactions on Information Systems*, 22(1):143–177.
- Dey, A. K. (2001). Understanding and Using Context. *Personal and Ubiquitous Computing*, 5(1):4–7.
- Dourish, P. (2004). What we talk about when we talk about context. *Personal and Ubiquitous Computing*, 8(1):19–30.
- Duncan, D. T., Aldstadt, J., Whalen, J., Melly, S. J., and Gortmaker, S. L. (2011). Validation of Walk Score for estimating neighborhood walkability: An analysis of four US metropolitan areas. *International Journal of Environmental Research and Public Health*, 8(11):4160–4179.
- Forecastio. Retrieved from <https://darksky.net/>.
- Foursquare. Retrieved from <https://pt.foursquare.com>.
- Gavalas, D., Konstantopoulos, C., Mastakas, K., and Pantziou, G. (2014). Mobile recommender systems in tourism. *Journal of Network and Computer Applications*, 39(1):319–333.
- Gouin-Vallerand, C. and De La Cruz, J. A.-M. (2013). Analysis of a context-aware recommender system model for smart urban environment. In *Proceedings of International Conference on Advances in Mobile Computing & Multimedia, MoMM '13*, pages 13:13–13:17.
- Gunawardana, A. and Shani, G. (2009). A Survey of Accuracy Evaluation Metrics of Recommendation Tasks. *The Journal of Machine Learning Research*, 10:2935–2962.

- Herlocker, J. L., Konstan, J. A., Terveen, L. G., and Riedl, J. T. (2004). Evaluating collaborative filtering recommender systems. *ACM Transactions on Information Systems (TOIS)*, 22(1):5–53.
- Hernández del Olmo, F. and Gaudioso, E. (2008). Evaluation of recommender systems: A new approach. *Expert Systems with Applications*, 35(3):790–804.
- Hidasi, B. and Tikk, D. (2012). Fast als-based tensor factorization for context-aware recommendation from implicit feedback. In *Proceedings of the 2012 European Conference on Machine Learning and Knowledge Discovery in Databases - Volume Part II, ECML PKDD'12*, pages 67–82.
- Hu, Y., Volinsky, C., and Koren, Y. (2008). Collaborative filtering for implicit feedback datasets. In *2008 Eighth IEEE International Conference on Data Mining*, pages 263–272.
- Kabassi, K. (2010). Personalizing recommendations for tourists. *Telematics and Informatics*, 27(1):51–66.
- Karatzoglou, A., Amatriain, X., Baltrunas, L., and Oliver, N. (2010). Multiverse Recommendation: N-dimensional Tensor Factorization for Context-aware Collaborative Filtering. In *Proceedings of the Fourth ACM Conference on Recommender Systems, RecSys '10*, pages 79–86.
- Levandovski, J. J., Sarwat, M., Eldawy, A., and Mokbel, M. F. (2012). LARS: A location-aware recommender system. In *2012 IEEE 28th International Conference on Data Engineering*, pages 450–461.
- Linden, G., Smith, B., and York, J. (2003). Amazon.com recommendations: item-to-item collaborative filtering. *IEEE Internet Computing*, 7(1):76–80.
- Miranda, M. (2013). Recomendação de pontos de interesse em tempo real com base em contexto. Master’s thesis, Universidade de Aveiro.
- Moore, J. (2011). Building a recommendation engine, foursquare style. Retrieved from <http://engineering.foursquare.com/category/foursquare-engineering-blog/>.
- Oku, K., Nakajima, S., Miyazaki, J., and Uemura, S. (2006). Context-Aware SVM for Context-Dependent Information Recommendation. In *7th International Conference on Mobile Data Management, Mobile Data Management '06*.
- Palmisano, C., Tuzhilin, A., and Gorgoglione, M. (2008). Using Context to Improve Predictive Modeling of Customers in Personalization Applications. *IEEE Transactions on Knowledge and Data Engineering*, 20(11):1535–1549.
- Panniello, U. and Gorgoglione, M. (2012). Incorporating context into recommender systems: An empirical comparison of context-based approaches. *Electronic Commerce Research*, 12(1):1–30.
- Panniello, U., Tuzhilin, A., Gorgoglione, M., Palmisano, C., and Pedone, A. (2009). Experimental Comparison of Pre- vs. Post-filtering Approaches in Context-aware Recommender Systems. In *Proceedings of the Third ACM Conference on Recommender Systems, RecSys '09*, pages 265–268.
- Pu, P., Chen, L., and Hu, R. (2012). Evaluating recommender systems from the user’s perspective: Survey of the state of the art. *User Modeling and User-Adapted Interaction*, 22(4-5):317–355.

- Rizzi, S. (2008). Conceptual modelling solutions for the datawarehouse. *Information Science Reference*, pages 208–227.
- Setten, M. V., Pokraev, S., Koolwaaij, J., Instituut, T., and Box, P. O. (2004). Context-Aware Recommendations in the Mobile Tourist Application COMPASS. In Nejdil, W. and Bra, P. D., editors, *Adaptive Hypermedia and Adaptive Web-Based Systems*, volume 3137 of *Lecture Notes in Computer Science*, pages 235–244.
- Sinha, R. and Swearingen, K. (2002). The role of transparency in recommender systems. In *Extended Abstracts on Human Factors in Computing Systems, CHI EA '02*, pages 830–831.
- Stefanidis, K., Pitoura, E., and Vassiliadis, P. (2007). A context-aware preference database system. *International Journal of Pervasive Computing and Communications*, 3(4):439–460.
- Su, X. and Khoshgoftaar, T. M. (2009). A Survey of Collaborative Filtering Techniques. *Advances in Artificial Intelligence*, 2009:1–19.
- Svizzera, C., Informatica, D., and Torino, U. (2003). INTRIGUE : Personalized Recommendation of Tourist Attractions. *Applied Artificial Intelligence*, 17:687–714.
- Vassiliadis, P. and Skiadopoulou, S. (2000). Modelling and optimisation issues for multidimensional databases. In *Advanced Information Systems Engineering*, volume 1789 of *Lecture Notes in Computer Science*, pages 482–497.
- Werthner, H. and Ricci, F. (2004). E-commerce and tourism. *Communications of the ACM - The Blogosphere*, 47(12):101–105.
- Yang, D., Zhang, D., Zheng, V. W., and Yu, Z. (2015). Modeling user activity preference by leveraging user spatial temporal characteristics in lbsns. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 45(1):129–142.