



Departamento de Ciências e Tecnologias da Informação

Sistema de Recomendação Colaborativa de Restaurantes com Dispositivos Móveis

Paulo Alexandre Pinto Albuquerque

Dissertação submetida como requisito parcial para obtenção do grau de
Mestre em Engenharia Informática

Orientadora:

Prof. Doutora Isabel Machado Alexandre,
Prof. Auxiliar
ISCTE – IUL

Outubro, 2012

Agradecimentos

Quero agradecer à minha família, especialmente aos meus pais e à minha mulher por todo o apoio e incentivo que me deram, tanto ao longo do mestrado como na elaboração do projeto de dissertação.

Agradeço à Prof. Doutora Isabel Alexandre por ter aceite orientar o projeto de dissertação, pela disponibilidade que sempre demonstrou, desde o acolhimento da ideia original até ao suporte na resolução de diversos desafios encontrados ao longo do tempo.

Por fim quero agradecer a todos os colegas e amigos que me ajudaram ao longo do desenvolvimento do projeto pelo apoio e entusiasmo que me transmitiram, bem como pelo *feedback* quanto ao *design* e usabilidade da aplicação móvel.

Resumo

O crescimento exponencial da informação a que as pessoas estão sujeitas, provocou a necessidade de existência de sistemas que ajudassem os utilizadores a filtrarem os dados que recebiam. Surgiu portanto uma classe de sistemas dedicados a esse fim denominados de sistemas de recomendação.

Os sistemas de recomendação tentam minimizar este problema, filtrando a informação menos relevante, deixando apenas aquela que mais interessa a cada utilizador. De entre os vários tipos de sistemas, os baseados em técnicas de filtragem colaborativa foram os mais bem sucedidos comercialmente, podendo ser encontrados em grandes distribuidores a nível mundial tais como a Amazon ou a NetFlix.

Entretanto, assiste-se a uma alteração na forma como os utilizadores acedem a portais de comércio eletrónico e a guias de turismo especializados, tendo-se passado da utilização de um computador como forma de acesso, para a utilização de dispositivos móveis tais como *smartphones* e *tablets*.

As capacidades de georreferenciação dos dispositivos móveis, conjuntamente com o acesso permanente à Internet, permite que estes sejam utilizados para o fornecimento de serviços baseados na localização do dispositivo. Neste contexto implementou-se um algoritmo de filtragem colaborativa, para o qual foi desenvolvida uma prova de conceito de uma aplicação móvel de recomendação de restaurantes.

O algoritmo de recomendação foi avaliado quanto à precisão com que faz previsões das avaliações dos utilizadores, utilizando-se uma base de dados pública de investigação (MovieLens), tendo-se obtido resultados comparáveis com outras publicações. Foram elaborados testes adicionais de aceitação da aplicação móvel junto dos utilizadores, cujos resultados se revelaram muito positivos.

Palavras chave:

Filtragem Colaborativa, Dispositivos Móveis, Serviços Baseados em Localização, Sistemas de Recomendação

Abstract

The exponential growth of information that people are exposed to, has created a need for the existence of systems that could help users to filter the incoming data. So a class of systems named recommender systems started to help deal with the issue.

These systems have eased the problem by filtering the information, leaving only the part that is of most interest to each user. Of the various kinds of recommender systems, the ones based on collaborative filtering have had the most commercial success, being found in world-class retailers as Amazon and on online DVD renting websites as NetFlix.

Meanwhile there has been a change in the way users access e-commerce and tourism portals, moving away from the standard use of a desktop computer to new mobile devices as smartphones and tablets. The geo-referencing capabilities of these mobile devices that are permanently connected to the Internet, allows for the delivery of services based on the device location.

In this context a collaborative filtering algorithm has been implemented and a proof of concept of a mobile restaurant recommender application developed to support it. The recommendation algorithm precision in predicting user ratings has been tested with success in a public research database (MovieLens), with results comparable to other publications. The mobile application has been subject to user acceptance tests resulting in a very positive feedback from the users.

Keywords:

Collaborative Filtering, Mobile devices, Location Based Services, Recommender Systems

Índice

AGRADECIMENTOS	I
RESUMO.....	II
ABSTRACT	III
ÍNDICE DE FIGURAS	VI
ÍNDICE DE TABELAS	VII
LISTA DE ABREVIATURAS.....	VIII
1 INTRODUÇÃO	1
1.1 MOTIVAÇÃO	2
1.2 ENQUADRAMENTO	3
1.3 OBJETIVOS.....	4
1.4 ESTRUTURA	5
2 ESTADO DA ARTE.....	6
2.1 SISTEMAS DE RECOMENDAÇÃO	7
2.1.1 Sistemas de recomendação colaborativa	8
2.1.2 Sistemas de recomendação baseados no conteúdo	10
2.1.3 Sistemas Híbridos	11
2.1.4 Sistemas de suporte à Recomendação	12
2.1.5 Sistemas de Recomendação sensíveis ao contexto	13
2.2 APLICAÇÕES MÓVEIS DE SUPORTE À DECISÃO	13
2.2.1 Yelp.....	14
2.2.2 Foodspotting	15
2.2.3 UrbanSpoon	16
2.2.4 Lifecooler Restaurantes	17
2.2.5 BestTables.....	17
2.2.6 Appetite Super Bock.....	18
2.3 DISPOSITIVOS MÓVEIS	19
2.3.1 Smartphone	19
2.3.2 Tablet PC	21
2.3.3 Sistemas Operativos Móveis.....	22
2.4 DESENVOLVIMENTO DE APLICAÇÕES	23
2.5 MERCADO DE SMARTPHONES	24
2.6 CONCLUSÕES.....	25
3 PROJETO ANDRÓSIO.....	26
3.1 INTRODUÇÃO	26
3.2 ÂMBITO	26
3.3 REQUISITOS	27
3.4 ARQUITETURA	27
3.5 ALGORITMO DE RECOMENDAÇÃO	28
3.6 VALIDAÇÃO DO ALGORITMO.....	32
3.6.1 Estrutura de dados de teste	33
3.6.2 Metodologia de teste.....	34

3.6.3 Métricas de avaliação da precisão	35
3.6.4 Resultados.....	35
3.7 SERVIDOR.....	36
3.8 COMUNICAÇÃO CLIENTE - SERVIDOR.....	37
3.9 APLICAÇÃO PARA DISPOSITIVOS MÓVEIS	38
3.10 APLICAÇÃO WEB DE ADMINISTRAÇÃO	40
3.11 TESTES DE ACEITAÇÃO	41
3.12 RESULTADOS	42
4 CONCLUSÕES E TRABALHO FUTURO	44
BIBLIOGRAFIA	45
ANEXOS	48
ANEXO 1 - ECRÃS DA APLICAÇÃO PARA DISPOSITIVOS MÓVEIS.....	48
ANEXO 2 - ECRÃS DA APLICAÇÃO DE WEB DE ADMINISTRAÇÃO	54
ANEXO 3 - FORMULÁRIO DE FEEDBACK DE ACEITAÇÃO - APLICAÇÃO ANDRÓSIO	56
ANEXO 4 - LISTA DAS PRINCIPAIS STORED PROCEDURES	58
ANEXO 5 - RESULTADOS EXPERIMENTAIS COM ALGORITMOS DE RECOMENDAÇÃO.....	59

Índice de Figuras

Figura 1 - Evolução da utilização de smartphones em Portugal	2
Figura 2 - Exemplo de ecrã da aplicação móvel Yelp	15
Figura 3 - Ecrãs da aplicação móvel Foodspotting.	15
Figura 4 - Ecrãs da aplicação móvel UrbanSpoon.	16
Figura 5 - Ecrã da aplicação móvel LifeCooler Restaurantes.	17
Figura 6 - Ecrãs da aplicação móvel BestTables.	18
Figura 7 - Ecrãs da aplicação móvel Appetite.	18
Figura 8 - Primeiro smartphone, IBM Simon.	20
Figura 9 - Smartphone da Apple, o iPhone.	20
Figura 10 - Primeiro smartphone Android, o T-Mobile G1.	20
Figura 11 - Vendas de pc's a azul e telemóveis a vermelho. Fonte: IDC (Novembro 2011)	21
Figura 12 - Primeiro tablet, o GridPad.	21
Figura 13 - <i>Tablet</i> da Apple lançado em 2010, o <i>iPad</i>	21
Figura 14 - Mercado de <i>smartphones</i> . Fonte: IDC(Fevereiro 2012).	24
Figura 15 - Mercado por fabricante de SO. Fonte: ComScore (Fevereiro 2012)	24
Figura 16 - Evolução da cota de mercado global por plataforma. Fonte: Gartner (2012)	25
Figura 17 - Arquitetura do sistema.	28
Figura 18 - Processo de recomendação	29
Figura 19 - Exemplo de matriz de interação	29
Figura 20 - Exemplo de matriz de coeficientes de similitude entre utilizadores.	30
Figura 21 - Tempo de processamento em minutos em função de k	31
Figura 22 - Tabelas principais da base de dados de teste.	34
Figura 23 - Tabelas principais da base de dados.	36
Figura 24 - Restaurantes mais recomendados ao utilizador	38
Figura 25 - Detalhe de restaurante e comentários associados.	39
Figura 26 - Configuração de parâmetros do sistema	40
Figura 27 - <i>Website</i> de distribuição da aplicação móvel.	41
Figura 28 - Utilizadores por género.	42
Figura 29 - Distribuição de utilizadores por faixa etária	42
Figura 30 - Distribuição da utilização do SO.	42
Figura 31 - Diagrama de extremos e quartis das respostas ao questionário	43
Figura 32 - Ecrã de <i>login</i> da aplicação	48
Figura 33 - Restaurantes mais recomendados ao utilizador	49
Figura 34 - Restaurantes próximos da localização do utilizador	50
Figura 35 - Ecrã dos 20 restaurantes mais populares.	50
Figura 36 - Pesquisa por nome.	51
Figura 37 - Ligação ao marcador telefónico do dispositivo.	51
Figura 38 - Sequência de ecrãs de ligação entre a aplicação e o navegador.	52
Figura 39 - Avaliação de 1 a 5 estrelas e comentários.	52
Figura 40 - Partilha da avaliação no <i>Facebook</i>	53
Figura 41 - Ecrã de gestão de utilizadores.	54
Figura 42 - Gestão de restaurantes	54
Figura 43 - Ecrã de detalhe de restaurante	55

Índice de Tabelas

Tabela 1 - Vantagens e desvantagens da filtragem colaborativa.....	9
Tabela 2 - Vantagens e desvantagens da filtragem por conteúdo	10
Tabela 3 - Comparação entre as funcionalidades das aplicações	14
Tabela 4 - Principais requisitos funcionais do sistema.....	27
Tabela 5 - Resultados experimentais de algoritmos de recomendação na base MovieLens 1M.....	59

Lista de Abreviaturas

API - Application Programming Interface.
CPU - Central Processing Unit.
EC2 - Elastic Compute Cloud.
GPS - Global Positioning System.
GPU - Graphics Processing Unit.
GSM - Global System for Mobile Communications.
HTTP - Hypertext Transfer Protocol.
MAE - Mean Absolute Error.
PDA - Personal Digital Assistant.
RMSE - Root Mean Square Error.
RAM - Random Access Memory.
SOAP - Simple Object Access Protocol.
SDK - Software Development Kit.
T-Sql - Transact Sql.
WSDL - Web Service Definition Language.
XML - Extensible Markup Language.

1 Introdução

A Internet expõe os indivíduos a um enorme leque de possibilidades, desde lojas com milhares de produtos, a documentos com informação de maior ou menor qualidade, a conversas online, etc. O crescimento exponencial do número de *sites* com informação disponível para consulta, bem como de lojas de comércio eletrônico, trouxe consigo um aumento enorme do volume de informação, tornando o processo de pesquisa e filtragem numa tarefa cada vez mais demorada e complexa. A impossibilidade de aumentar a capacidade de processamento do ser humano proporcionalmente ao aumento da informação a processar, provoca o problema da sobrecarga de informação.

Para responder à crescente necessidade de existência de mecanismos que tornassem a pesquisa de informação relevante mais fácil, surgiram nos anos 90 os primeiros sistemas de recomendação, que têm por base um conjunto de módulos de software e de técnicas, que produzem sugestões de itens do interesse do utilizador (Ricci, Rokach, Shapira, & Kantor, 2011).

Estes sistemas ajudam a solucionar o problema da sobrecarga de informação por filtrarem os dados, mostrando apenas os mais úteis ou mais interessantes para cada utilizador.

Este trabalho foca-se numa classe de técnicas utilizadas em sistemas de recomendação denominada de filtragem colaborativa. Estas técnicas procuram recomendar itens ao utilizador que outros utilizadores com preferências semelhantes gostaram no passado.

Os sistemas de recomendação associados a grandes entidades ligadas ao comércio na Internet como a Amazon¹ e a NetFlix², estão agora a ser acedidos cada vez mais através de dispositivos móveis à medida que estes vão tendo uma maior taxa de penetração no mercado.

¹ <http://www.amazon.com>

² <http://www.netflix.com>

³ <http://www.yelp.com>

⁴ <http://www.urbanspoon.com>

Em Portugal, a utilização de dispositivos móveis denominados *Smartphones* com capacidades de processamento semelhantes a computadores de secretária, aumentou em termos da sua taxa de penetração em 2011 para o dobro comparativamente com 2010, representado já 4,2% da população residente no território nacional (Figura 1) (Meios & Publicidade, 2012).




Figura 1 - Evolução da utilização de *smartphones* em Portugal

Os *Smartphones* estão tipicamente equipados com recetores de GPS e com uma ligação permanente à Internet, o que lhes confere tanto a possibilidade de obterem a sua localização geográfica com precisão, como aceder a serviços disponíveis na Internet.

Este trabalho procura implementar um algoritmo de recomendação de restaurantes, através da sua incorporação numa prova de conceito de uma aplicação para dispositivos móveis que tira partido da localização do utilizador.

1.1 Motivação

Para o território nacional, existe uma oferta muito limitada de aplicações para dispositivos móveis, que permita a partilha de críticas de restaurantes entre utilizadores conjuntamente com um sistema de recomendação que lhes facilite a pesquisa, através da sugestão de restaurantes.

Nos Estados Unidos existem aplicações de localização e avaliação de estabelecimentos comerciais como o Yelp³ e o UrbanSpoon⁴, sendo a segunda dedicada exclusivamente ao sector da restauração.

³ <http://www.yelp.com>

⁴ <http://www.urbanspoon.com>

Estas aplicações permitem a pesquisa e listagem de lojas por localização e tipo, fornecendo ao utilizador a possibilidade de avaliar as lojas que visita.

As avaliações podem ser partilhadas com a comunidade, contribuindo para o conhecimento coletivo.

Em termos de funcionamento, e por localização, o utilizador pode ver por exemplo a listagem de restaurantes próximos e respetivas classificações. Esta listagem fornece detalhes de cada restaurante, como críticas feitas pelos utilizadores, informação relativa aos produtos disponíveis, bem como a possibilidade de reservar mesas. Se for um utilizador registado, pode inserir uma crítica sobre um dado restaurante utilizando uma classificação de uma a cinco estrelas, bem como uma descrição da sua experiência.

Através da utilização de uma aplicação deste tipo, quem visite uma cidade que desconhece, beneficia do conhecimento coletivo quanto à localização dos restaurantes com a melhor classificação em termos de qualidade, sendo uma grande mais valia para o indivíduo. Para os restaurantes, é uma oportunidade de aumentarem as suas receitas, dada a maior visibilidade em relação a grandes cadeias de restaurantes (Luca, 2011).

1.2 Enquadramento

A utilização crescente de *smartphones* com acesso à Internet e à localização geográfica através de GPS, abre novas oportunidades de fornecimento de serviços baseados na localização do utilizador, com benefícios para este. Exemplos deste tipo de serviços incluem aplicações de requisição de táxis e localização de farmácias ou restaurantes próximos do utilizador.

Neste trabalho procura-se implementar uma prova de conceito de um sistema de recomendação de restaurantes, utilizando um modelo cliente-servidor, em que a componente cliente é uma aplicação para *smartphones*.

Recorre-se à localização geográfica do dispositivo para contextualizar os resultados das pesquisas, o que irá permitir ao utilizador encontrar os restaurantes perto da sua localização atual, mostrando-lhe os que receberam as melhores avaliações por parte da comunidade. Um sistema de recomendações personalizado dá a conhecer outros restaurantes alternativos, tendo em conta os gostos e preferências do utilizador.

1.3 Objetivos

Quando alguém se encontra numa cidade que desconhece, tem muita dificuldade na escolha de um restaurante, pelo desconhecimento quanto à sua localização, qualidade dos produtos, atendimento, etc. E mesmo quando encontra um restaurante, tem muita dificuldade em obter informações tidas como confiáveis e atualizadas sobre a sua qualidade.

A publicidade e as críticas feitas por especialistas, são tidas como sendo de menor confiança, quando comparadas com as de outros clientes (Choi & Ok, 2011). No sentido de responder a estes desafios, pretende-se desenvolver um sistema que seja capaz de recolher as avaliações que cada utilizador faz dos diversos restaurantes que visita, e utilizá-las para produzir recomendações personalizadas. Para que seja possível fazer recomendações, é necessário implementar um algoritmo de recomendação alimentado pelas avaliações que cada utilizador faz dos restaurantes.

Para dar suporte quer à partilha de avaliações de restaurantes entre utilizadores, quer à recomendação personalizada, deverá ser implementada uma aplicação para dispositivos móveis, que forneça aos utilizadores a capacidade de partilharem entre si a localização dos restaurantes mais bem avaliados pela comunidade, bem como fornecer-lhes recomendações que vão ao encontro das suas preferências.

1.4 Estrutura

A dissertação está organizada em quatro capítulos: Introdução; Estado da arte; Projeto Andrósio; Conclusões e trabalho futuro.

No capítulo um pretende-se dar a conhecer de forma sintética a motivação, enquadramento e principais objetivos deste projeto.

No capítulo dois faz-se uma revisão dos diversos aspetos relacionados com o tema desta dissertação. Começa-se por apresentar os vários tipos de sistemas de recomendação, depois passa-se para a evolução do acesso aos sistemas, as aplicações móveis relacionadas ao apoio à decisão, a evolução dos dispositivos móveis e os sistemas operativos mais utilizados. Apresentam-se depois as características do desenvolvimento de aplicações móveis e as características do mercado de dispositivos móveis. Por fim tiram-se algumas conclusões.

No capítulo três apresenta-se o projeto desenvolvido começando pelo âmbito e requisitos apurados, passando pela arquitetura desenvolvida e uma descrição dos vários componentes, nomeadamente o algoritmo de recomendação, a metodologia utilizada para o validar, bem como os resultados obtidos quanto à precisão das previsões geradas.

Depois descreve-se o servidor central, a base de dados e as comunicações cliente-servidor. Passa-se depois a descrever a aplicação para dispositivos móveis, a aplicação de administração e por último apresentam-se os testes de aceitação efetuados e os resultados obtidos.

No capítulo quatro apresentam-se as conclusões retiradas da elaboração da dissertação, bem como as várias possibilidades de melhoramento e desenvolvimento adicional em relação ao trabalho efetuado.

2 Estado da Arte

Introdução

O problema da sobrecarga de informação a que os utilizadores estão sujeitos, levou ao aparecimento de sistemas de recomendação que procuram minimizar o problema, procedendo à filtragem dos dados e mostrando apenas aqueles que são considerados mais úteis ou mais interessantes para cada utilizador.

Em termos gerais, os sistemas de recomendação são um conjunto de módulos de software e técnicas que criam um modelo das preferências ou da tarefa a desempenhar pelo utilizador, com o objetivo de facilitar o acesso à informação relevante através da filtragem seletiva da informação.

Embora em grande parte dos casos, o utilizador faça uma pesquisa para obter resultados de acordo com critérios específicos, muitos sistemas tentam prever de variadas formas as necessidades e preferências dos utilizadores, assistindo-os com recomendações geradas automaticamente (Chesñear, Maguitman, & Simari, 2006).

Com a evolução da informática, foram sendo desenvolvidos dispositivos portáteis cada vez mais pequenos e leves, que foram adquirindo um número cada vez maior de funcionalidades. Essa evolução chegou ao ponto de permitir que esse tipo de dispositivos seja utilizado no acesso a vários serviços na Internet. De entre este tipo de dispositivos, são os chamados *smartphones* que têm maior expressão no mercado. Os *smartphones* são micro computadores com sistema operativo, o que lhes confere a capacidade de executar aplicações desenvolvidas por terceiros. É através destes dispositivos que os utilizadores começam a aceder a portais *web* de turismo e guias de restauração tais como o Lifecooler⁵ ou o BestTables⁶. Neste contexto, surgiram no mercado aplicações móveis desenvolvidas especificamente para cada sistema operativo, capazes de fornecer ao utilizador uma parte considerável das funcionalidades dos portais *web*, assim como tirar partido dos diversos sensores que esses dispositivos contêm tais como a bússola digital e o recetor de GPS.

As aplicações desenvolvidas por terceiros, são otimizadas para serem utilizadas em ecrãs muito reduzidos, através da utilização de componentes gráficos nativos do sistema operativo.

⁵ <http://www.lifecooler.com>

⁶ <http://www.besttables.com>

Algumas aplicações já começam a apresentar algum tipo de recomendações no sentido de apenas apresentar ao utilizador informação considerada mais útil, poupando espaço vital de ecrã e proporcionando uma experiência de utilização muito superior à dos portais *web*.

Neste capítulo faz-se uma revisão dos sistemas de recomendação mais comuns, bem como dos diversos dispositivos móveis, passando pelos sistemas operativos que fornecem as funcionalidades necessárias ao acesso à Internet, passando pelas aplicações desenvolvidas por terceiros otimizadas para estes dispositivos no contexto da pesquisa e suporte à decisão. Faz-se uma análise do mercado atual de *smartphones* e dos sistemas operativos associados e tiram-se algumas conclusões, em relação às escolhas efetuadas para o desenvolvimento do projeto.

2.1 Sistemas de recomendação

O aumento enorme da informação disponível, tornou a tarefa de pesquisa de informação relevante cada vez mais demorada e complexa.

Para responder a este problema crescente, surgiram nos anos 90 diversos tipos de sistemas de recomendação com o objetivo de facilitar a obtenção de informação relevante. Em meados da década de 90, diversos investigadores iniciaram o estudo dos problemas da recomendação automática, relacionados com a forma de prever a avaliação de itens nunca antes vistos pelos utilizadores.

Um tipo de sistemas caracteriza-se por recomendar itens ao utilizador, que outros utilizadores com preferências semelhantes também gostaram. Este tipo de sistemas foca-se na similaridade entre utilizadores, selecionando para cada um, um conjunto de outros utilizadores com preferências similares. Estes utilizadores são denominados de vizinhos mais próximos e influenciam diretamente o valor das previsões geradas.

Outros tipos de sistemas recorrem apenas às avaliações fornecidas pelos próprios utilizadores bem como às características dos próprios itens. A previsão do valor das avaliações feitas pelos utilizadores, pode ser calculada recorrendo-se a diversas técnicas, de entre elas as de aprendizagem automática.

Feita a previsão das avaliações que o utilizador faria em relação a itens desconhecidos, o sistema pode então recomendar-lhe aqueles que apresentam o valor de utilidade⁷ mais elevado (Adomavicius & Tuzhilin, 2005).

Seguidamente apresentam-se alguns dos principais tipos de sistemas de recomendação utilizados atualmente.

2.1.1 Sistemas de recomendação colaborativa

Os sistemas de recomendação colaborativa procuram sugerir ao utilizador itens com base nas preferências de outros utilizadores com gostos semelhantes aos seus.

No contexto de lojas de comércio eletrónico, utilizam-se métricas discretas relacionadas com o historial de compras do utilizador, bem como avaliações explícitas feitas a produtos. Toda esta informação é processada no sentido de se efetuar uma previsão do interesse que o utilizador poderá ter em relação a itens desconhecidos.

Há duas classes principais de sistemas: Os baseados em memória e aqueles que se baseiam em modelos.

Nos sistemas baseados em memória, as avaliações que os utilizadores fazem dos itens são utilizadas diretamente na produção de recomendações, ao passo que nos sistemas baseados em modelos, as avaliações são utilizadas para o desenvolvimento de um modelo.

Os sistemas baseados em memória podem ainda ser focados no utilizador ou nos itens. Quando são focados no utilizador, preveem o seu interesse num dado item, relacionando-o com outros utilizadores com padrões de avaliação semelhantes aos seus, denominados de vizinhos. Quando são baseados nos itens, preveem o interesse do utilizador com base nas avaliações feitas por si no passado, relativamente a itens semelhantes (dois itens são considerados semelhantes quando são avaliados de forma semelhante por diversos utilizadores).

Nos sistemas baseados em modelos, utilizam-se algoritmos de aprendizagem automática no processo de construção do modelo de avaliações do utilizador. Estes algoritmos podem ser baseados em redes Bayesianas, técnicas de *clustering* ou através de uma aproximação baseada em regras. Pretende-se modelar as interações entre os utilizadores e os itens e proceder-se à construção do modelo. Depois de treinado é capaz de prever as avaliações que os utilizadores fariam na presença de novos itens (Ricci et al., 2011).

⁷ Neste contexto, a utilidade de um item refere-se ao quanto um utilizador gosta dele através das avaliações que faz, utilizando uma escala de uma a cinco estrelas.

Os sistemas de recomendação colaborativa apresentam vantagens e desvantagens tal como se pode ver na Tabela 1.

Vantagens	Desvantagens
Independência dos itens - A presença de itens sem qualquer informação quanto às suas características, não afeta a capacidade de produção de recomendações dado esta basear-se apenas nas avaliações dos utilizadores.	Novo item - Quando um novo item é registado, o sistema não tem forma de o recomendar aos utilizadores, até que este seja avaliado explicitamente.
Qualidade - Produzem recomendações baseadas na qualidade dos itens de acordo com a avaliação qualitativa feita por outros utilizadores, ao passo que outros sistemas apenas têm em conta as características, o que pode ser um mau indicador de qualidade.	Dispersão - Se houver um número pequeno de avaliações de utilizadores comparado com o volume de itens, então vamos ter uma cobertura fraca em termos do número de itens avaliados pelos utilizadores, limitando-se em muito o número de itens passíveis de serem recomendados pelo sistema.
Fator novidade - Têm a capacidade de sugerir novos itens ao utilizador com características nunca antes vistas, desde que outros utilizadores os tenham avaliado anteriormente.	Utilizador invulgar - Se um dado utilizador tiver gostos pouco comuns, então não irá ter um número significativo de utilizadores com gostos similares, o que vai limitar muito a qualidade das recomendações.

Tabela 1 - Vantagens e desvantagens da filtragem colaborativa

A dimensão e diversidade da população de utilizadores desempenha um papel crucial na quantidade e qualidade das recomendações geradas. Isto deve-se ao facto do grupo de utilizadores "Vizinhos próximos" de um determinado utilizador, ser fortemente influenciado pela dimensão e diversidade da população. Sempre que as avaliações negativas efetuadas pelos utilizadores sejam incapazes de alterar significativamente os elementos que compõem os seus "Vizinhos próximos", então nada impede que itens desinteressantes sejam novamente recomendados (Balabanović, 1997).

Um dos grandes pontos fortes dos sistemas de recomendação colaborativa é a sua capacidade de recomendar itens desconhecidos para o utilizador, cujas características podem sair fora das suas preferências habituais (Burke, 2002).

2.1.2 Sistemas de recomendação baseados no conteúdo

Estes sistemas, em vez de basearem as recomendações nas similaridades entre os utilizadores, baseiam-se nas similaridades entre as características dos itens, para os quais os utilizadores revelaram interesse. Recorrem a um conjunto de características discretas de cada item, bem como ao historial de compras do utilizador para lhe recomendarem outros itens de características similares.

Por exemplo, numa aplicação de recomendação de filmes, o sistema tenta reconhecer as especificidades dos filmes que o utilizador avaliou favoravelmente no passado, para depois poder recomendar-lhe outros filmes, que tenham características similares.

É guardado um perfil de utilizador com os seus gostos e preferências, sendo a informação recolhida através da análise das características contidas nos itens vistos e classificados anteriormente pelo utilizador. A recolha de informação relativa a cada novo item inserido no sistema é efetuada através da aplicação de técnicas de extração de informação, nomeadamente a análise de palavras-chave (Adomavicius & Tuzhilin, 2005). Os sistemas baseados no conteúdo apresentam algumas vantagens e desvantagens tal como se pode ver na tabela 2.

Vantagens	Desvantagens
Independente de outros utilizadores - Obtêm de cada utilizador, as avaliações de itens necessárias à construção do seu perfil, independentemente da atividade de outros utilizadores.	Limitações do conteúdo - Podem haver limitações no número e no tipo de características que podem ser associadas aos itens. Se não existir informação suficiente, estes sistemas tornam-se incapazes de produzir resultados satisfatórios.
Transparência - É possível obter as características dos itens que levaram o sistema a recomenda-los ao utilizador. Essas características podem ser consultadas e validadas.	Falta de novidade - Este sistema não é capaz de sugerir itens com características completamente novas ao utilizador. São sugeridos tipicamente itens cujas características já se assemelham muito ao perfil do utilizador.
Novos itens - O aparecimento de novos itens nunca antes avaliados por nenhum utilizador, não coloca qualquer problema neste tipo de sistemas, pois são as características inerentes aos itens que são críticas.	Novo utilizador - O sistema necessita de recolher um conjunto mínimo de avaliações do utilizador, antes de ser capaz de gerar recomendações em sintonia com as suas preferências. Quando o número de avaliações é escasso, não é possível gerar recomendações fiáveis.

Tabela 2 - Vantagens e desvantagens da filtragem por conteúdo

A escassez de recomendações por parte dos utilizadores em relação à quantidade de itens disponíveis é um problema comum a vários tipos de sistemas de recomendação. Dado que o ato de avaliar um item requer algum esforço por parte do utilizador, este tende a evitar fazê-lo. Surge portanto a necessidade de aliciar de alguma forma os utilizadores para que estes produzam avaliações em número suficiente.

Num sistema puramente baseado na filtragem do conteúdo, a única fonte de recomendações são aquelas fornecidas pelo próprio utilizador, pelo que, quanto menor o seu número, menor a performance do algoritmo que produz as recomendações.

A recomendação baseada no conteúdo apresenta algumas vantagens em relação aos sistemas de recomendação colaborativa, mas apresenta também alguns problemas a ultrapassar (Ricci et al, 2011).

2.1.3 Sistemas Híbridos

As abordagens híbridas combinam características de dois ou mais sistemas de recomendação no sentido de se melhorar a qualidade das recomendações. A combinação de características visa também mitigar alguns dos problemas associados a cada sistema individualmente (Burke, 2002).

Por exemplo, os métodos de filtragem colaborativa sofrem do problema de inserção de novos itens nunca antes avaliados por utilizadores, fazendo com que sejam incapazes de os recomendar. Já os sistemas baseados em filtragem do conteúdo não sofrem deste problema, dado basearem as recomendações nas características dos itens, mas sofrem do problema da falta de novidade.

Os sistemas podem ser combinados através da aplicação de várias técnicas:

- **Ponderação de Valores:** Cada item recebe uma pontuação de cada um dos sistemas de recomendação. O valor final atribuído a cada item resulta da ponderação dos valores gerados pelos sistemas envolvidos.
- **Combinação:** Uma elevada escassez de avaliações pode levar a que não seja possível obter valores de todos os sistemas de recomendação. Recorre-se então a técnicas de hibridização combinada, consistindo na obtenção de um conjunto de recomendações independentes para cada item, e depois na sua combinação.

- **Comutação:** Neste tipo de aproximação, primeiro aplica-se um sistema de recomendação e caso este não consiga produzir um valor de elevada confiança, troca-se de sistema. Outras variantes procuram seleccionar automaticamente o sistema de recomendação com base no tipo de utilizador.

A maioria dos sistemas híbridos utiliza primeiro o perfil do utilizador e o conteúdo das descrições dos itens, para obter o conjunto de utilizadores com interesses similares, e só depois aplica a filtragem colaborativa para efetuar previsões (Shih & Liu, 2005).

Em (Pazzani, 1999) são propostas duas formas de se combinarem sistemas, sendo a primeira designada por colaboração via conteúdo, em que se aplica a filtragem por conteúdo e só depois a filtragem colaborativa, e a segunda designada como método baseado no consenso, em que se combinam os resultados individuais dos algoritmos no sentido de se encontrarem consensos entre eles.

2.1.4 Sistemas de suporte à Recomendação

Estes sistemas caracterizam-se pelo facto do processo de recomendação não ser automático. Eles oferecem aos utilizadores a possibilidade de partilharem as recomendações diretamente entre si. Suportam tanto o utilizador no papel de pesquisador por itens recomendados, como o papel de utilizador que é produtor de recomendações, servindo como ferramenta de suporte à partilha de recomendações entre os dois tipos de papéis. O primeiro sistema de recomendações reconhecido como tal foi o Tapestry (Goldberg, Nichols, Oki, & Terry, 1992). Este sistema permitia aos seus utilizadores classificar como boas ou más as mensagens de correio electrónico que recebiam, possibilitando também a associação de comentários às mensagens. Podendo estas ser pesquisadas não só pelo seu conteúdo, como também pela sua classificação e comentários associados. Mais tarde esta abordagem foi desenvolvida em (Maltz & Ehrlich, 1995) no sentido em que o sistema foi construído para suportar explicitamente, tanto o modo de pesquisa como o de produção de recomendações. Podiam ser criadas recomendações associadas a documentos, podendo depois ser dirigidas a conjuntos específicos de utilizadores. Os sistemas de suporte à recomendação para serem eficazes necessitam de uma massa crítica de utilizadores dispostos a produzirem recomendações (Terveen & Hill, 2001).

2.1.5 Sistemas de Recomendação sensíveis ao contexto

Os sistemas de recomendação lidam tradicionalmente apenas com duas entidades, os utilizadores e os itens. Não têm em consideração por exemplo o contexto físico, temporal ou mesmo emocional em que a recomendação é feita.

Por exemplo nos dias da semana, o utilizador pode estar mais interessado em ver recomendações sobre restaurantes do tipo *fastfood*, enquanto que no fim de semana pode estar mais interessado em restaurantes com cozinha mais tradicional. Uma recomendação com elevado grau de precisão depende sempre da qualidade da informação contextual incluída no algoritmo de recomendação (Ricci et al, 2011). Mostra-se em (Oku et al, 2006) que a adição de dimensões de contexto tais como as condições meteorológicas, o tempo e a localização melhoram substancialmente a precisão do sistema de recomendação de restaurantes.

2.2 Aplicações móveis de suporte à decisão

O uso crescente de dispositivos móveis com capacidade de acesso a lojas de comércio eletrónico e a *sites* ligados à pesquisa de pontos de interesse, trouxe consigo desafios de utilização bem como novas oportunidades, relacionadas com a própria mobilidade dos dispositivos. No sentido de responder à necessidade de existência de aplicações otimizadas para as características dos dispositivos móveis, foram sendo criadas aplicações específicas para essas novas plataformas.

Apresenta-se em resumo vários exemplos de aplicações de acesso a sistemas de recomendação de vários tipos. Todas elas são aplicações projetadas para serem executadas em dispositivos móveis com ligação permanente à Internet e tiram partido da localização geográfica do utilizador.

Podemos observar na Tabela 3 algumas das características das aplicações disponíveis para dispositivos móveis predominantemente relacionadas com restaurantes.

	Baseado na Localização	Pesquisa proximidade	Críticas de restaurantes	Reservas	Recomendações personalizadas
2.2.1 - Yelp	Sim	Sim	Sim	Sim	Não
2.2.2- FoodSpotting	Sim	Sim	Sim	Sim	Sim
2.2.3- UrbanSpoon	Sim	Sim	Sim	Sim	Não
2.2.4- LifeCooler	Sim	Sim	Sim	Não	Não
2.2.5- BestTables	Sim	Sim	Sim	Sim	Não
2.2.6- Appetite	Sim	Sim	Sim	Não	Sim

Tabela 3 - Comparação entre as funcionalidades das aplicações

2.2.1 Yelp

O Yelp⁸ é um motor de busca de estabelecimentos comerciais, sendo a restauração a categoria com mais negócios. Em 2008 foi lançada a aplicação móvel de acesso ao sistema, o que originou um enorme aumento do número de utilizadores. Atualmente cerca de 40% das pesquisas provêm já da utilização da aplicação móvel.

Para além de apresentar os resultados das pesquisas tradicionais, o Yelp mostra também informação relacionada com cada negócio, nomeadamente críticas e avaliações associadas (Figura 2).

As críticas e avaliações são fornecidas direta e exclusivamente pela comunidade de utilizadores do Yelp. É utilizado um algoritmo polémico para filtrar as críticas e comentários suspeitos capazes de pôr em causa a seriedade global do sistema.

Esta filtragem não é perfeita, acabando por remover um número significativo de avaliações legítimas de restaurantes, o que provoca sentimentos de revolta por parte dos donos dos estabelecimentos comerciais.

Em termos da participação, os donos de negócios registam os seus estabelecimentos comerciais e os utilizadores avaliam e criticam os estabelecimentos, baseados nas experiências que tiveram. A avaliação é feita pelos utilizadores recorrendo a um esquema de classificação de 1 a 5 estrelas.

⁸ <http://www.yelp.com>




Figura 2 - Exemplo de ecrã da aplicação móvel Yelp

Com o aparecimento da aplicação móvel, os utilizadores passaram a contar também com uma referência à localização geográfica do dispositivo, como auxílio na obtenção de resultados mais úteis nas pesquisas.(Luca, 2011).

2.2.2 Foodspotting

O Foodspotting⁹ é um sistema lançado em Janeiro de 2010, que age como guia de restaurantes para utilizadores que procuram pratos específicos, próximos da sua localização atual (Figura 3). Este guia pode ser acedido tanto via *web* como através de uma aplicação para dispositivos móveis desenvolvida especificamente para este fim.

Os pratos são mostrados ao utilizador através de fotografias partilhadas por outros utilizadores, juntamente com a sua classificação e localização geográfica.



Figura 3 - Ecrãs da aplicação móvel Foodspotting.

⁹ <http://www.foodspotting.com>

Para além do papel de pesquisadores, os utilizadores podem ser *spotters* de pratos, podendo desta forma contribuir para a comunidade e ganhar pontos de reputação sempre que avistam um novo prato. Cada utilizador tem uma certa quantidade de pontos de reputação que podem ser usados para classificar pratos, incentivando-se dessa forma a qualidade da classificação.

Não são permitidas classificações negativas como política central, incentivando-se antes a não partilha de pratos que o utilizador não gostou.

Em Fevereiro de 2012 foi lançada uma nova versão da aplicação, tendo sido adicionado pela primeira vez um sistema de recomendações personalizadas. Agora é possível indicar na aplicação os gostos pessoais através de um menu de contexto em cada imagem de pratos, permitindo que apenas sejam recomendados aqueles mais do agrado do utilizador (Bonnington, 2012).

2.2.3 UrbanSpoon

O UrbanSpoon¹⁰ é um guia *online* especializado na indústria da restauração fundado em Outubro de 2006. Fornece informação detalhada sobre restaurantes, cafés e estabelecimentos similares para uma dada região.

A aplicação móvel com o mesmo nome foi lançada em 2008 com uma forma inovadora de recomendação, apresentando ao utilizador um jogo que simula uma *slot-machine* (Figura 4). Ao abanar o dispositivo móvel, ativa-se a *slot-machine*, que sorteia uma recomendação de restaurantes baseada numa mistura aleatória de 3 parâmetros, a cidade, tipo de cozinha e classe de preço.




Figura 4 - Ecrãs da aplicação móvel UrbanSpoon.

A aplicação permite também a pesquisa de restaurantes, leitura de críticas e avaliações submetidas por outros utilizadores e por especialistas. Muito recentemente foram adicionadas

¹⁰ <http://www.urbanspoon.com>

novas funcionalidades, nomeadamente a capacidade de reservas de mesas e o registo do historial de refeições denominado *Dineline*. O utilizador pode registar no seu *Dineline* informação como o montante gasto, comida servida no local e imagens recolhidas. A quantidade de informação guardada é controlada pelo utilizador, podendo ficar apenas registado o restaurante e uma avaliação simples de gostou ou não gosto.

2.2.4 Lifecooler Restaurantes

Esta aplicação é uma ferramenta que serve de extensão ao sistema online Lifecooler¹¹ que é um portal de turismo e lazer. Trata-se de uma aplicação exclusiva para dispositivos móveis da Apple e que permite a pesquisa de restaurantes de acordo com a sua proximidade ao utilizador, bem como filtrar os resultados por tipos de cozinha, preço e horário. A aplicação móvel fornece direções aos utilizadores criando um roteiro desde a sua localização atual até ao destino através de um mapa. Fornece também informação relevante sobre restaurantes recomendados por especialistas bem como os descontos em vigor (Figura 5).




Figura 5 - Ecrã da aplicação móvel LifeCooler Restaurantes.

2.2.5 BestTables

O BestTables¹² é um sistema de pesquisa e reserva de mesas em restaurantes lançado em exclusivo para Portugal em Abril de 2011 como site *web*, e em Fevereiro de 2012 como aplicação móvel em exclusivo para os dispositivos móveis da Apple. Este sistema faz a gestão de forma integrada e automática dos lugares disponíveis nos restaurantes aderentes (Figura 6). Permite a pesquisa de restaurantes em determinada zona do país e apresenta uma listagem detalhada dos resultados.

Os restaurantes são apresentados com informação detalhada, incluindo o menu completo e preços.

¹¹ <http://www.lifecooler.com>

¹² <http://www.besttables.com>

Disponibiliza aos utilizadores a capacidade de publicarem críticas na forma de comentários de opinião (Fernandes, 2012). As avaliações dos restaurantes são fornecidas através da ligação ao sistema TripAdvisor (TripAdvisor, 2012).




Figura 6 - Ecrãs da aplicação móvel BestTables.

2.2.6 Appetite Super Bock

Trata-se de um guia de restaurantes lançado exclusivamente para dispositivos móveis da Apple em Janeiro de 2011. Mais tarde foi feita uma conversão para Android, permitindo que um público mais alargado tivesse acesso à aplicação.

Utiliza as capacidades de localização por GPS dos dispositivos móveis para indicar a localização dos restaurantes relativamente à posição do dispositivo (Figura7), bem como o trajeto a efetuar. Permite que sejam aplicados diversos filtros nas pesquisas tais como o tipo de cozinha, nível de preço e região. Conta também com um sistema de votos muito simples, do tipo "gostei" ou "não gostei" e permite adicionar comentários e a partilha dos mesmos no *Facebook*.



Figura 7 - Ecrãs da aplicação móvel Appetite.

Esta aplicação está ligada a um sistema de recomendação que tem em conta as utilizações prévias e as preferências do utilizador bem como os dados do seu perfil que se resume ao escalão de idade, preferência de localização e sensibilidade ao preço (Appetite - Super Bock, 2012). O utilizador tem a possibilidade de criar uma lista de restaurantes favoritos bem como uma lista de pretendidos onde pode guardar os locais que pretende visitar ou contactar no futuro.

2.3 Dispositivos Móveis

Os dispositivos móveis, quer sejam telemóveis inteligentes, quer sejam *tablets*, todos têm a capacidade de executarem uma enorme variedade de aplicações. Atualmente estes dispositivos são considerados como extensões do computador de secretária. O termo dispositivos móveis é utilizado no contexto da presente dissertação para descrever um conjunto de dispositivos do tipo *handheld*, com sistema operativo, elevada capacidade de processamento e ligação à Internet.

A evolução da tecnologia implicou um aumento nas capacidades do hardware o que levou a uma incorporação de funcionalidades, antes dispersas por vários dispositivos.

Assistentes pessoais (PDA's), *paggers*, agendas eletrónicas e telefones móveis foram todos concentrados em dispositivos "inteligentes" capazes de executar aplicações que implementam as tarefas antes desempenhadas pelos vários dispositivos.

2.3.1 Smartphone

Os dispositivos móveis do tipo *smartphone*, além das funções típicas de um telemóvel tem capacidades avançadas comparáveis às de computadores de secretária, possuindo um CPU relativamente poderoso e um GPU para aceleração gráfica. Estes dispositivos têm tipicamente um ecrã tátil, capacidade de ligação à Internet através de WIFI ou GSM, bem como um recetor de GPS e outros sensores auxiliares.

Eles executam tipicamente um dos sistemas operativos mais populares: Android, Symbian, iOS, BlackBerry OS ou Windows Phone. Todos estes sistemas operativos têm a capacidade de executar aplicações complexas, que podem ser descarregadas da Internet e instaladas pelos próprios utilizadores sem que para isso sejam necessários quaisquer conhecimentos técnicos.

Os modelos mais antigos, bem como os atuais modelos de gama baixa têm ecrãs tipicamente pouco precisos, necessitando de dispositivos tipo "caneta" para uma correta operação. Já os modelos mais recentes de gama média e alta são equipados com ecrãs com capacidade para a

deteção de mais de um toque em simultâneo, sendo portanto capazes de detetar gestos como o de zoom utilizando vários dedos, dispensando o uso de apontadores.

Estes dispositivos têm também sensores tais como os acelerómetros que permitem que os dados no ecrã sejam mostrados de acordo com a orientação do dispositivo, bem como giroscópios que permitem que as aplicações utilizem o movimento do dispositivo como forma de navegação, o que é particularmente importante para os jogos.

O primeiro telemóvel considerado inteligente chamava-se Simon (ver Figura 8) e foi lançado pela IBM em exclusivo para o público Americano em 1992. Tinha um ecrã tátil, calendário, bloco de notas e *e-mail* (Hafeez, 2012).



Figura 8 - Primeiro smartphone, IBM Simon.

No início de 2007 a Apple lançou o *iPhone* (Figura 9), o *smartphone* que veio revolucionar o mercado, com um ecrã tátil multi-toque, *web browser* que oferecia uma experiência de navegação única e acesso à maior loja de música do mundo.

Pouco depois em Setembro de 2008 é lançado o primeiro *smartphone* com o sistema operativo Android da Google, o T-Mobile G1 (Figura 10) (Sterling, 2008).



Figura 9 - Smartphone da Apple, o iPhone.



Figura 10 - Primeiro smartphone Android, o T-Mobile G1.

Tal como se pode ver na Figura 11, de acordo com um novo estudo, as vendas de *smartphones* ultrapassaram no final de 2011 pela primeira vez na história, a venda de computadores pessoais (Rosoff, 2012).




Figura 11 - Vendas de pc's a azul e telemóveis a vermelho. Fonte: IDC (Novembro 2011)

2.3.2 Tablet PC

Um *tablet* é um dispositivo móvel portátil que recorre à utilização de um ecrã sensível ao toque como modo de interação principal.

Este tipo de dispositivos são pensados para terem uma portabilidade que lhes permita serem utilizados em locais onde não é prática a utilização de computadores portáteis ou de um computador de secretária.

A incorporação de uma bateria interna de grande capacidade e a otimização de todos os componentes no sentido da minimização do consumo energético permite-lhes terem autonomias superiores aos computadores portáteis.

O primeiro *tablet* foi comercializado em 1989 com o nome de *Gridpad* (Figura 12), muito antes da Apple ou Microsoft lançarem os seus próprios dispositivos (Holwerda, 2010). Esta gama de dispositivos teve pouco sucesso no mercado de consumo de massas até que a Apple lançou o *iPad* em 2010 (Figura 13).



Figura 12 - Primeiro tablet, o GridPad.



Figura 13 - Tablet da Apple lançado em 2010, o iPad.

2.3.3 Sistemas Operativos Móveis

Um sistema operativo móvel, tal como acontece com um sistema tradicional tem como objetivo a execução de aplicações e o controlo do hardware.

Na compra de qualquer dispositivo móvel, este vai ter pré instalado um sistema operativo escolhido pelo fabricante. O sistema operativo vai determinar também as aplicações que podem ser executadas no dispositivo. Em seguida descrevem-se os principais sistemas operativos pré-instalados nos dispositivos móveis atuais.

2.3.3.1 Android

É um sistema operativo de código aberto baseado num *kernel linux*, desenvolvido explicitamente para *smartphones* e *tablets*. A Google lidera o desenvolvimento do sistema e disponibiliza um SDK (Software Development Kit), que permite aos programadores desenvolverem aplicações nativas. A linguagem de programação utilizada é o Java e a plataforma de distribuição de software oficial é o Google Play.

Dada a natureza "aberta" do sistema operativo, permite-se a instalação de aplicações de fontes não oficiais, bem como de lojas de distribuição de aplicações não controladas pela Google.

2.3.3.2 iOS

É o sistema operativo proprietário da Apple desenvolvido exclusivamente para os dispositivos da marca. Atualmente o iOS é pré-instalado em algumas linhas de produtos, nomeadamente na gama iPhone, iPad e AppleTv.

Este sistema operativo é baseado numa versão especial do OS X da Apple para dispositivos móveis, desenvolvida para tirar partido das características específicas deste tipo de dispositivos. A Apple fornece o iOS SDK juntamente com a plataforma de desenvolvimento XCODE gratuitamente para o desenvolvimento de aplicações nativas.

2.3.3.3 BlackBerry OS

Trata-se de um sistema operativo móvel lançado pela empresa RIM em Janeiro de 1999 para o modelo BlackBerry 580.

Este sistema operativo contém suporte nativo para um conjunto de aplicações empresariais tais como o *e-mail*, calendário corporativo, tarefas e sincronização com o Microsoft Exchange

entre outros. A RIM disponibiliza uma API para que os programadores possam desenvolver programas nativos. A linguagem de programação utilizada é o Java.

2.3.3.4 Windows Phone 7

O Windows Phone 7 é um sistema operativo proprietário da Microsoft lançado em Novembro de 2010. Trata-se de uma nova versão do seu sistema operativo para dispositivos móveis conhecido anteriormente como Windows Mobile. Esta nova versão contou com um interface de utilizador completamente redesenhado, orientado para o mercado de consumo.

O sistema operativo conta com um conjunto de aplicações nativas pré-instaladas tais como o *browser web Internet Explorer* e o cliente de *e-mail Outlook*.

A Microsoft disponibiliza gratuitamente o Visual Studio 2010 Express For Windows Phone, que inclui o Windows Phone SDK para que os programadores possam desenvolver aplicações nativas para o sistema. Em termos de linguagem de programação pode optar-se entre C# e VB.NET. Em Fevereiro de 2011, a Microsoft assinou uma parceria com a Nokia, que permitiu o lançamento de vários modelos da fabricante com o sistema operativo Windows Phone 7. Em Maio do mesmo ano foi anunciada a adesão de outros parceiros como a Acer, Fujitsu e ZTE (Davies, 2011).

2.4 Desenvolvimento de Aplicações

Todos os sistemas operativos móveis mostrados anteriormente contam com um ambiente de desenvolvimento gratuito. O desenvolvimento de aplicações para estes sistemas operativos pode ser feita em várias linguagens de programação. De acordo com o sistema operativo, as principais linguagens de programação utilizadas são o Java para o Android e BlackBerry OS, o Objective-C no iOS e C# e VB no Windows Phone.

Para cada sistema operativo existe pelo menos uma loja de aplicações disponível, onde os programadores podem publicar as aplicações e os utilizadores podem descarregá-las.

2.5 Mercado de Smartphones

De acordo com o relatório da ComScore (ComScore, 2011), o sistema operativo da Google dominava o mercado Americano em Julho de 2011 com 41,8% de quota, seguido pela Apple com 27%, depois pela RIM com 21,7%, pela Microsoft com 5,7% e finalmente pela Symbian com apenas 1,9% do mercado, mesmo depois da Nokia ter abandonado a plataforma a favor do Windows Phone 7. Em termos de evolução entre Abril e Julho de 2011, só a Google e a Apple viram a sua quota de mercado subir ao passo que todas as outras desceram, sendo a RIM a mais penalizada com uma quebra de 4%. De acordo com um relatório da IDC (IDC, 2012), em termos globais, os fabricantes de *smartphones* com maior quota de mercado são a Samsung e a Apple com 22,8% e 23,5% respetivamente (Figura 14).




Figura 14 - Mercado de *smartphones*. Fonte: IDC(Fevereiro 2012)

Em termos de sistemas operativos móveis, podemos ver na Figura 15, que o Android da Google é o sistema operativo dominante no mercado com 47,3%, seguido de perto pelo iOS da Apple com 30%.




Figura 15 - Mercado por fabricante de SO. Fonte: ComScore (Fevereiro 2012)

Na Figura 16 mostra-se a evolução do mercado de smartphones em termos mundiais, assistindo-se a uma queda acentuada do sistema operativo Symbian desde o seu auge em 2009. Pelo contrário, a plataforma Android teve um crescimento enorme desde 2009 sendo o líder desde 2011.




Figura 16 - Evolução da cota de mercado global por plataforma. Fonte: Gartner (2012)

2.6 Conclusões

De entre as aplicações móveis ligadas à recomendação de restaurantes, apenas as aplicações FoodSpotting e Appetite fornecem algum tipo de recomendação automática, sendo que as restantes apenas se comportam como sistemas de suporte à recomendação. Dado o sucesso comercial da recomendação baseada na filtragem colaborativa (Sarwar, Karypis, Konstan, & Riedl, 2000) bem como a sua capacidade de utilizar apenas as avaliações dos utilizadores como fonte de informação, escolheu-se implementar a filtragem colaborativa como motor do sistema de recomendação da aplicação a desenvolver.

Tal como exposto anteriormente, o sistema operativo Android da Google é o sistema mais utilizado, representando uma quota de mercado de 47,3%, permitindo distribuir as aplicações por uma base de utilizadores muito mais alargada. A este facto acresce a grande facilidade de distribuição de aplicações *ad-hoc*, sem necessidade de aprovação oficial. Por estas razões decidiu-se desenvolver o protótipo da prova de conceito para o sistema operativo Android.

3 Projeto Andrósio

3.1 Introdução

Identificada a falta de oferta de aplicações móveis em Portugal, com capacidade de recomendação automática de restaurantes, foi elaborada uma prova de conceito de uma aplicação com essas características. Esta prova de conceito consiste numa implementação de um sistema de recomendação colaborativo de restaurantes.

O sistema interage com os utilizadores através de uma aplicação para dispositivos móveis, que tira partido das capacidades de localização baseada na tecnologia GPS.

Ao protótipo de aplicação móvel foi dado o nome de Andrósio, sendo a conjugação do nome do sistema operativo onde é executado (Android) e o nome Ambrósio. O nome Ambrósio faz alusão à personagem de um motorista ou mordomo que faz sugestões sobre os melhores restaurantes a frequentar, de acordo com a localização atual.

No sentido de proporcionar ao utilizador uma experiência de utilização o mais completa possível, procurou-se apresentar na aplicação móvel diversas possibilidades de pesquisa:

- Pesquisa por avaliação média da comunidade.
- Pesquisa por proximidade.
- Pesquisa por nome.

Apresenta-se também uma lista dos restaurantes recomendados automaticamente pelo sistema, ordenados por valor de recomendação.

Com esta informação diversificada, o utilizador pode efetuar uma escolha informada, tendo em conta a distância a que os restaurantes estão em relação à sua localização atual, bem como à classificação média dada por outros utilizadores e à recomendação feita pelo sistema.

3.2 Âmbito

Tratando-se de uma aplicação móvel que utiliza a localização geográfica do dispositivo, tornou-se importante restringir a área geográfica abrangida. Dados os constrangimentos em termos de tempo e infraestruturas disponíveis associadas ao desenvolvimento deste projeto de dissertação, optou-se por restringir a localização dos pontos de interesse apenas à área da grande Lisboa. Foram recolhidos dados de cerca de 2900 restaurantes de vários *websites* públicos.

3.3 Requisitos

Foi identificado um conjunto de necessidades dos utilizadores, entre elas a de pesquisar informações sobre restaurantes próximos, partilhar avaliações com outros utilizadores e visualizar restaurantes filtrados de forma personalizada, de acordo com as preferências de cada um, pelo que foram identificados os serviços necessários, sendo elaborada uma lista de requisitos funcionais (Tabela 4).

Autenticar os utilizadores dos dispositivos móveis.
Gerir utilizadores.
Gerir restaurantes.
Permitir a configuração de parâmetros do motor de recomendações.
Gerar recomendações de restaurantes personalizadas por utilizador.
Permitir a pesquisa de restaurantes por nome e proximidade.
Permitir a avaliação de restaurantes.
Mostrar informação detalhada sobre cada restaurante.
Permitir a interligação com um sistema de navegação.
Permitir a partilha de avaliações de restaurantes no Facebook.

Tabela 4 - Principais requisitos funcionais do sistema

3.4 Arquitetura

Este projeto implementa uma arquitetura típica cliente-servidor tal como se pode ver na Figura 17. Os utilizadores acedem ao sistema através de uma aplicação que reside no dispositivo móvel do utilizador. Esta aplicação liga-se ao servidor central através de uma ligação à Internet. A informação é centralizada no servidor para permitir a partilha de informação entre utilizadores e para a obtenção de recomendações personalizadas.

Os utilizadores com privilégios de administração, podem aceder ao *website* de administração alojado no servidor, para registarem novos utilizadores e restaurantes, bem como ajustar diversos parâmetros do sistema.




Figura 17 - Arquitetura do sistema

Para permitir que a aplicação móvel seja utilizada em qualquer local com ligação à Internet, tornou-se imperativo que o servidor fosse público e tivesse um endereço IP fixo. A solução encontrada foi a criação de uma máquina virtual na infraestrutura tipo *cloud* da Amazon chamada EC2¹³. A máquina virtual pertence à categoria *micro-instance* pelo que tem uma capacidade de processamento e memória RAM muito reduzida(613MiB¹⁴) sendo capaz de servir os pedidos de um número pequeno de dispositivos móveis. Se necessário, a capacidade da máquina virtual pode ser aumentada, acompanhando o crescimento do número de utilizadores.

3.5 Algoritmo de Recomendação

Para se produzir uma lista de restaurantes recomendados de forma personalizada para cada utilizador, é necessário implementar um algoritmo, que seja capaz de prever as avaliações que ele daria a restaurantes que desconhece.

O algoritmo de recomendação escolhido para o efeito foi o da filtragem colaborativa pelo facto de se basear apenas nos valores das avaliações feitas pelos utilizadores em relação aos itens(restaurantes) tal como apresentado na secção 2.1.1. Isto é muito importante pois a base de dados de restaurantes que foi constituída contém pouca informação sobre os restaurantes nomeadamente a designação, localização, morada e contactos.

¹³ <http://aws.amazon.com/ec2/>

¹⁴ Um Mebibyte corresponde a $2^{20} = 1048576$ bytes

O algoritmo de recomendação é um processo que pode ser separado em três fases: cálculo da semelhança entre utilizadores, previsão das avaliações para itens desconhecidos e finalmente a produção da lista de recomendações.

Em primeiro lugar calcula-se a semelhança entre cada utilizador e todos os outros. Depois selecciona-se um conjunto de "vizinhos" do utilizador em análise, com valores de semelhança mais elevados em relação a este.

Para o utilizador em análise são então produzidas previsões para as avaliações dos itens que lhe são desconhecidos. Com as previsões das avaliações, geram-se as recomendações dos restaurantes com melhor *score* (Figura 18). Seguidamente detalha-se cada uma das fases do processo de recomendação.




Figura 18 - Processo de recomendação

Fase 1: Cálculo da semelhança entre utilizadores

As avaliações que os utilizadores fazem dos restaurantes são representadas numa matriz de interação (Figura 19). Esta matriz contém os *ratings* dos utilizadores em linha e os restaurantes em coluna e cada célula representa o valor da avaliação (entre 1 e 5) que o utilizador "U" fez relativamente ao restaurante "R". Esta informação serve de base para todo o processo.

	R1	R2	R3	R4	R5	R6	R7
U1	1	1	4	1	3	1	1
U2	4	1	4	2	3	1	3
U3	5	1	4	2	3	1	4
U4	3	4	3	2	1	5	3
U5	5	2	4	2	3	1	4
U6	1	1	4	1	2	1	1
U7	3	4	5	2	3	4	5

Figura 19 - Exemplo de matriz de interação

A primeira fase consiste no cálculo da correlação linear entre cada utilizador e todos os outros, gerando-se uma matriz de correlação semelhante à da Figura 20. O valor de cada elemento da matriz é calculado através da aplicação da fórmula de correlação de Pearson (1) dado ter sido mostrado empiricamente que produz melhores resultados, quando relacionada com outros métodos nomeadamente o da similaridade vetorial (Breese, Heckerman, & Kadie, 1998).

$$w_{a,u} = \frac{\sum_{i \in I} (r_{a,i} - \bar{r}_a)(r_{u,i} - \bar{r}_u)}{\sqrt{\sum_{i \in I} (r_{a,i} - \bar{r}_a)^2 \sum_{i \in I} (r_{u,i} - \bar{r}_u)^2}} \quad (1)$$

Em (1) o valor de $w_{a,u}$ representa a correlação entre o utilizador em análise "a" e o utilizador comparado "u". O I representa o conjunto de restaurantes avaliados em comum por ambos os utilizadores, $r_{a,i}$ refere-se à avaliação que "a" fez do restaurante "i", $r_{u,i}$ refere-se à avaliação que "u" fez do restaurante "i". $\bar{r}_a$ e $\bar{r}_u$ representam respetivamente a média das avaliações que o utilizador "a" e o "u" fizeram dos restaurantes avaliados em comum.

Os valores de correlação obtidos variam entre -1 e 1, sendo que -1 representa uma correlação negativa perfeita e 1 representa uma correlação perfeita positiva das avaliações dos utilizadores. Calculou-se um coeficiente de similitude através da aplicação da fórmula de ajuste (2), em que $w_{a,u}$ representa o valor de correlação original e " v " o valor ajustado para o intervalo entre 0 e 1 em que 0 significa uma completa dissemelhança e 1 significa uma perfeita semelhança.

$$v = \frac{1 + w_{a,u}}{2} \quad (2)$$

	U 1	U 2	U 3	U 4	U 5	U 6	U 7
U 1	1	0,77	0,66	0,29	0,64	0,98	0,65
U 2	0,77	1	0,98	0,25	0,96	0,77	0,57
U 3	0,66	0,98	1	0,29	0,99	0,67	0,58
U 4	0,29	0,25	0,29	1	0,32	0,39	0,73
U 5	0,64	0,96	0,99	0,32	1	0,66	0,61
U 6	0,98	0,77	0,67	0,39	0,66	1	0,71
U 7	0,65	0,57	0,58	0,73	0,61	0,71	1

Figura 20 - Exemplo de matriz de coeficientes de similitude entre utilizadores

A primeira fase termina com a obtenção da matriz de correlação ajustada que vai servir de *input* para o processamento das previsões.

Fase 2: Cálculo da previsão para os itens desconhecidos

Na segunda fase processa-se a previsão da avaliação que determinado utilizador daria a determinado restaurante. Primeiro fixa-se um utilizador, denominado de utilizador ativo, depois para esse utilizador selecionam-se os k utilizadores mais correlacionados com ele, como sendo os seus vizinhos mais próximos. O valor de k^{15} é uma variável configurável no sistema tendo em atenção que quanto maior for o seu valor, maior será o tempo despendido no processamento das previsões, tal como se pode ver num exemplo de um outro sistema baseado na vizinhança (Koren, 2010) (Figura 21). Por ser um sistema que produz recomendações online, torna-se necessário processar os dados muito rapidamente por forma a produzir uma resposta em tempo útil para o utilizador. Obtido o conjunto de utilizadores mais próximos, aplica-se a fórmula (3) para se gerar o valor da previsão da avaliação para o utilizador ativo.




Figura 21 - Tempo de processamento em minutos em função de k

$$p_{a,i} = \bar{r}_a + \frac{\sum_{u \in K} (r_{u,i} - \bar{r}_u) \times w_{a,u}}{\sum_{u \in K} w_{a,u}} \quad (3)$$

O $p_{a,i}$ representa a previsão da avaliação do utilizador em análise "a" em relação ao restaurante "i", sendo $\bar{r}_a$ a média das suas avaliações. $r_{u,i}$ é a avaliação que o utilizador "u" fez do restaurante i e $\bar{r}_u$ a média das avaliações do utilizador u. $w_{a,u}$ representa a medida de

¹⁵ O valor de k mínimo inicial foi de 4, obtido através de testes empíricos.

similitude entre os dois utilizadores determinada na fase 1. K representa o conjunto dos vizinhos mais próximos em relação ao utilizador "a" que avaliaram o mesmo conjunto de restaurantes.

A equação (3) corrige a média das avaliações do utilizador em análise com a média ponderada (pela similitude entre cada vizinho e o utilizador em análise) dos desvios das avaliações dos vizinhos em relação às suas próprias médias.

Este processo é repetido para cada restaurante que se queira prever a avaliação do utilizador.

Fase 3: Produção da recomendação

Com base nas previsões gera-se uma lista de restaurantes que tenham obtido um valor de recomendação previsto igual ou superior a 3, considerando-se um critério qualitativo de classificação desfavorável para valores entre 1 e 2, neutral para 3 e de favorável entre 4 e 5. Esta lista de restaurantes será a lista que o motor de recomendação irá produzir como recomendação personalizada para o utilizador em análise.

3.6 Validação do algoritmo

O projeto implementa um sistema de recomendação colaborativa puro. Tal como foi mostrado na secção 2.1.1, os sistemas de recomendação colaborativa puros têm limitações, que podem ter um impacto muito negativo na qualidade das recomendações. Estas limitações são especialmente evidentes no arranque inicial, sendo que de entre elas se destacam duas:

- Incapacidade de gerar recomendações com qualidade até que o número de utilizadores e correspondentes avaliações atinjam uma massa crítica.
- Um utilizador com padrão de avaliações incomum, impossibilita a formação de uma vizinhança significativa.

A base de dados utilizada no desenvolvimento do sistema de recomendação de restaurantes foi preenchida com cerca de 2900 restaurantes localizados exclusivamente em Lisboa, mas o número de utilizadores é de menos de uma centena. Tal desproporção entre o número de utilizadores e restaurantes, tem como resultado uma matriz de avaliações esparsa.

Sabendo isto espera-se que o arranque do sistema seja particularmente penalizador para a qualidade das recomendações (muitas vezes nem é possível recomendar dada a falta de dados).

Perante esta situação decidiu-se validar a implementação do algoritmo, recorrendo-se a testes num conjunto de dados *standard*, utilizado por diversos autores como (Gong, 2010) e (Sarwar, Karypis, Konstan, & Reidl, 2001) no estudo de algoritmos de recomendação.

O conjunto de dados escolhido tem o nome de MovieLens-1M e é composto por 6 mil utilizadores que produziram cerca de 1 milhão de avaliações relativas à qualidade de cerca de 4 mil filmes.

Este conjunto de dados é propriedade de um laboratório de investigação da universidade do estado do Minnesota nos Estados Unidos denominado GroupLens¹⁶. Os dados contidos no conjunto MovieLens-1M são extraídos da atividade de aproximadamente 6 mil utilizadores registados no ano 2000 no *website* MovieLens (www.movielens.org).

3.6.1 Estrutura de dados de teste

O conjunto de dados público conhecido como MovieLens-1M é composto por 3 ficheiros de texto com os valores dos campos separados de forma pouco convencional utilizando a dupla de caracteres "::".

Este facto obrigou a que fosse desenvolvido um programa para ler cada um dos ficheiros, converter os dados e inserir na base de dados toda a informação.

Na Figura 22 mostram-se as principais tabelas que compõem a base de dados de teste do algoritmo. A tabela ML_Ratings e ML_Ratings_Prev representam 80% e 20% respetivamente das avaliações efetuadas. A tabela ML_Ratings_Prev contém um campo adicional (RatingPrev) que é preenchido pelo algoritmo de recomendação com a previsão da avaliação. Dessa forma o valor da previsão pode ser comparado facilmente com o valor real representado pelo campo (Rating) da mesma tabela. A tabela ML_Users contém os dados dos utilizadores responsáveis pelas avaliações e a tabela MatrizProxUtilizadores_ML contém os valores de semelhança entre todos os utilizadores e que é utilizada pelo algoritmo de recomendação.

¹⁶ <http://www.grouplens.org/>

ML_Ratings	ML_Ratings_Prev	ML_Users	MatrizProxUtilizadores_ML
USERID MOVIEID RATING TIMESTAMP	USERID MOVIEID RATING TIMESTAMP RATINGPREV	UserId Gender Age Occupation Zip	ID_REL ID_UTILIZADORE_A_FK ID_UTILIZADOR_COMP_FK PROXIMIDADE

Figura 22 - Tabelas principais da base de dados de teste.

Dado o elevado número de avaliações de filmes, foi necessário adicionar tabelas auxiliares com o objetivo de aumentar a velocidade de processamento das previsões de avaliações.

3.6.2 Metodologia de teste

O método utilizado para implementar os testes de precisão¹⁷ do algoritmo tem o nome de *holdout*. Este método consiste na divisão do conjunto de dados original em dois conjuntos extraídos aleatoriamente, um com 80% dos *ratings* originais dados pelos utilizadores e outro com os restantes 20%. O conjunto maior correspondente a 80% dos dados é utilizado para a construção da matriz de semelhança entre utilizadores, ao passo que o conjunto dos 20% dos *ratings* é escondido do algoritmo de recomendação para ser subsequentemente utilizado nos testes à precisão das previsões (Cremonesi & Turrin, 2010). O valor da avaliação prevista pelo sistema é então comparado com o valor real que é conhecido.

Em termos dos parâmetros utilizados nos testes, foi selecionado um valor mínimo de avaliações em comum de 10 itens para cálculo do valor de semelhança entre utilizadores. Valores inferiores tornavam o processo de criação da matriz de semelhanças extremamente lento pelo aumento do número de utilizadores a comparar em relação ao selecionado. O valor de *k* (número de vizinhos mais próximos) utilizado para o cálculo das previsões foi de 50 por ser um valor que produz bons resultados (Gong, 2010) para o conjunto de dados Movielens. Valores de *k* superiores a 50 não produzem uma redução do valor do MAE suficiente para compensar o aumento enorme no tempo de processamento.

¹⁷ Neste contexto refere-se à capacidade do algoritmo em fazer previsões iguais às avaliações efetuadas pelos utilizadores.

3.6.3 Métricas de avaliação da precisão

Foram utilizadas duas métricas de avaliação do erro cometido nas previsões de avaliações dos utilizadores: O erro médio absoluto e a raiz quadrada do erro médio quadrático. Ambas as métricas são muito populares na avaliação da precisão de um motor de recomendação, sendo que quanto menor for o valor de cada uma, mais precisas são as previsões geradas pelo motor.

$$\text{MAE} = \frac{1}{n} \sum_{j=1}^n |y_j - \hat{y}_j| \quad (4)$$

O MAE (4) é o erro médio absoluto e fornece o desvio da previsão fornecida pelo motor de recomendação, em relação ao valor verdadeiro indicado pelo utilizador. Na equação (4), n representa o número de avaliações envolvido, sendo y_j o valor real da avaliação fornecida pelo utilizador e $\hat{y}_j$ a previsão da avaliação fornecida pelo sistema.

Trata-se da média aritmética dos valores absolutos dos erros de previsão cometidos individualmente item a item. Esta métrica dá-nos uma estimativa geral do desempenho do algoritmo.

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{j=1}^n (y_j - \hat{y}_j)^2} \quad (5)$$

O RMSE (5) é a raiz quadrada do erro quadrático médio e fornece uma estimativa global de precisão das previsões efetuadas pelo motor de recomendações no grupo de teste. Em (5), n representa o número de avaliações envolvido, sendo y_j o valor real da avaliação fornecida pelo utilizador e $\hat{y}_j$ a previsão da avaliação fornecida pelo sistema.

Tal como podemos ver em (5), as diferenças entre os valores esperados e os previstos são elevadas ao quadrado, o que penaliza fortemente os erros de previsão de maior valor.

3.6.4 Resultados

O erro médio absoluto (MAE) das previsões das avaliações feitas pelo sistema em relação ao grupo de teste foi de 0.72. Este valor está em linha com os valores obtidos em publicações como (Amatriain, Lathia, & Pujol, 2009) e (Lee, Kim, & Park, 2007) para algoritmos de recomendação colaborativa.

A raiz quadrada do erro quadrático médio (RMSE) das previsões de avaliações que o sistema fez para o grupo de teste foi de 0.905. Este valor também está em linha com os resultados obtidos em (Candillier, Meyer, & Fessant, 2008) e (Candillier, Meyer, & Boullé, 2007). No anexo 5 apresenta-se uma tabela onde se podem ver os resultados obtidos por vários algoritmos de sistemas de recomendação, aplicados ao mesmo conjunto de dados (MovieLens), sendo que os resultados obtidos neste trabalho são comparáveis.

Isto permite-nos concluir que o algoritmo de recomendação foi validado com sucesso quanto à precisão das previsões que produz.

3.7 Servidor

O servidor tem duas funções principais, sendo a primeira a de servir os pedidos das aplicações executadas pelos dispositivos móveis, e a segunda a de alojar o *website* de administração do sistema.

Para servir os pedidos dos dispositivos móveis, o servidor possui um *web-service*¹⁸ que disponibiliza um conjunto de funções, as quais podem ser invocadas pelas aplicações móveis clientes, expondo dessa forma as funcionalidades necessárias à interação entre elas e a base de dados. O sistema de gestão de base de dados utilizado foi o Microsoft Sql Server 2008™. O modelo de dados utilizado é o apresentado na (Figura 23).




Figura 23 - Tabelas principais da base de dados.

¹⁸ Forma estandardizada de uma aplicação invocar funções de outra, recorrendo a diversas tecnologias padrão como o XML, SOAP e WSDL.

A tabela **Utilizadores** guarda a informação necessária para a autenticação e validação do estado de cada utilizador. A informação adicional sobre as características de cada utilizador é guardada na tabela **PerfilUtilizadores**, dando ao sistema a capacidade de distinguir o tipo de utilizador (normal ou administrador) bem como informação pessoal que possa ser útil para uso futuro. As avaliações que cada ponto de interesse (neste caso restaurantes) é guardada na tabela **AvaliaçõesPdis**. A tabela **PontosDeInteresse** contem toda a informação relativa aos restaurantes.

Finalmente a tabela **MatrixProxUtilizadores** guarda o valor da "proximidade" que cada utilizador está em relação a todos os outros. Esta informação é de extrema importância na produção de recomendações personalizadas.

A base de dados contem um conjunto de micro programas escritos na linguagem t-sql denominados de *stored procedures*, responsáveis por implementar as principais funcionalidade do sistema ao nível do servidor. Por exemplo, para que um utilizador possa ver a lista de restaurantes recomendados, é chamada a *stored procedure* **ObtemPDIsRec** a qual por sua vez chama a *stored procedure* **PreveUserPDIAval** para obter as previsões das avaliações em relação ao utilizador selecionado.

O *web-service* liga-se à base de dados e executa diretamente estas *stored procedures* em resposta a pedidos dos utilizadores da aplicação para dispositivos móveis.

Esta aproximação permite uma maior independência e flexibilidade em relação às aplicações que se ligam à base de dados, sendo possível alterar o comportamento do sistema sem a necessidade de alteração das aplicações móveis, *web site* de administração ou mesmo do *web-service*. No Anexo 4 apresenta-se uma lista com a descrição da função das principais *stored procedures*.

3.8 Comunicação Cliente - Servidor

A comunicação entre a aplicação cliente executada nos dispositivos móveis e o servidor, utiliza o protocolo SOAP¹⁹ que é um protocolo baseado no XML e que permite a comunicação entre aplicações sobre HTTP. Sendo o HTTP um protocolo standard utilizado na comunicação entre browsers *web* e servidores para a visualização de *websites*, permite a comunicação através de *firewalls* ao passo que protocolos não standard não o conseguem.

¹⁹ <http://www.w3.org/tr/2000/note-soap-20000508/>

3.9 Aplicação para Dispositivos Móveis

O utilizador interage com o sistema de recomendação de restaurantes através de uma aplicação para dispositivos móveis desenvolvida para ser executada exclusivamente no sistema operativo Android. A aplicação tem o nome de Andrósio e disponibiliza um conjunto de ecrãs que expõem as principais funcionalidades do sistema.

Seguidamente apresentam-se alguns dos ecrãs da aplicação onde se mostram os restaurantes recomendados automaticamente pelo sistema, bem como o detalhe obtido quando se seleciona um dos restaurantes da lista. No Anexo 1 apresentam-se os principais ecrãs da aplicação.

Ecrã de recomendação de restaurantes

Na Figura 24 mostra-se o ecrã que apresenta a lista de restaurantes mais recomendados para o utilizador que está a utilizar a aplicação. A lista apresenta os restaurantes por ordem decrescente de recomendação (representada por uma barra central colorida), bem como a distância de cada restaurante em relação ao dispositivo (lado esquerdo) e o número médio de estrelas dado pelos restantes utilizadores (direita). De entre todas as previsões de avaliações produzidas pelo motor de recomendação, apenas são mostradas as de valor maior ou igual a 3.



Figura 24 - Restaurantes mais recomendados ao utilizador

Ecrã de detalhe de restaurante

Quando o utilizador pressiona um item de uma lista de resultados em qualquer dos ecrãs principais da aplicação, obtém um novo ecrã com o detalhe da informação relevante, bem como a possibilidade de ver os comentários que os vários utilizadores fizeram quando avaliaram o restaurante (Figura 25).



Figura 25 - Detalhe de restaurante e comentários associados.

3.10 Aplicação *web* de administração

Os utilizadores com privilégio de administração têm à sua disposição uma aplicação *web* que permite gerir os utilizadores, restaurantes e configuração de parâmetros do sistema de recomendação. No ecrã da Figura 26 apresentam-se os diversos atributos relacionados com o sistema de recomendação, que podem ser alterados neste ecrã, afetando diretamente o motor de recomendações e os resultados das pesquisas efetuadas através da aplicação móvel.

The screenshot shows the 'Configuração dos Parâmetros Principais' (Main Parameters Configuration) page in the ANDROSIO web application. The page has a header with the ANDROSIO logo and navigation links (Início, Minha Info, Sair). Below the logo are three tabs: 'Restaurantes', 'Utilizadores', and 'Configuração'. The 'Configuração' tab is active, displaying a list of parameters for configuration:

Parameter Name	Value	Description
NR VIZINHOS PROX	10	Nº de vizinhos mais próximos
MIN PDI COM	2	Mínimo de avaliações em comum entre utilizadores para a formação de recomendações
MIN REG AVALS	4	Mínimo de avaliações em comum entre utilizadores para a formação de recomendações
RECOM APENAS DESC	☐	Apenas recomendar ao utilizador restaurantes que ele ainda não avaliou
MAX RESULT REC	20	Número máximo de restaurantes recomendados mostrados no dispositivo móvel
MAX RESULT PROX	20	Número máximo de restaurantes próximos mostrados no dispositivo móvel
MAX RESULT PESQ	20	Número máximo de restaurantes mostrados no dispositivo móvel

At the bottom of the configuration area, there are two buttons: 'Cancelar ou' and 'Atualizar'.

Figura 26 - Configuração de parâmetros do sistema

O parâmetro (NR VIZINHOS PROX) refere-se ao número de vizinhos mais próximos de cada utilizador que é tido em conta na produção de previsões. O (MIN PDI COM) representa o número mínimo de restaurantes que dois utilizadores têm de ter avaliado em comum para que faça sentido calcular a correlação entre utilizadores. O (MIN REG AVALS) é o número mínimo de avaliações requeridas para que o registo de um novo utilizador seja efetuado com sucesso. Finalmente os parâmetros (MAX RESULT) referem-se ao número máximo de resultados enviados para os dispositivos móveis em cada um dos tipos de pesquisa. No Anexo 2 apresentam-se os restantes ecrãs da aplicação *web* de administração.

3.1.1 Testes de Aceitação

No sentido de validar as funcionalidades da aplicação móvel junto dos utilizadores, foram efetuados testes de aceitação para as principais funcionalidades.

A distribuição da aplicação móvel pelos utilizadores foi feita através de um *website* criado para o efeito em www.androsio.pt. Neste *website* os utilizadores podem fazer download da aplicação diretamente para os seus dispositivos móveis e proceder à sua posterior instalação (Figura 27).




Figura 27 - *Website* de distribuição da aplicação móvel.

Neste *website* está também disponível um *link* para o formulário com perguntas sobre o grau de satisfação que cada utilizador teve em relação às principais funcionalidades da aplicação móvel e ao sistema em geral.

O formulário (Anexo 3) foi criado e é gerido pelo Google Docs, o que permite uma recolha de dados muito conveniente para os utilizadores, bem como uma grande facilidade de exportação dos resultados para MS Office Excel™ para análise posterior. A recolha de dados é feita de forma anónima e a estrutura do formulário foi pensada de forma a recolher tanto a opinião do utilizador quanto às principais funcionalidades, como obter uma avaliação comparativa entre esta aplicação e outras semelhantes existentes no mercado.

3.12 Resultados

A aplicação móvel foi testada por um total de 21 utilizadores, dos quais 5 eram do género feminino e 16 do masculino (Figura 28). Em termos de faixa etária, grande parte dos utilizadores está situado entre os 18 e os 44 anos (Figura 29).




Figura 28 - Utilizadores por género




Figura 29 - Distribuição de utilizadores por faixa etária

Tal como esperado, a dispersão de versões do sistema operativo Android utilizadas é grande. De salientar que 9 utilizadores responderam que não sabem a versão que utilizam (Figura 30).




Figura 30 - Distribuição da utilização do SO.

Foram feitas 10 perguntas aos utilizadores sobre a sua satisfação em relação às principais funcionalidades da aplicação móvel e sistema de recomendações, as quais foram respondidas utilizando uma escala de pontuação de 1 a 5, sendo que 1 significa muito pouco satisfeito e 5 muito satisfeito.

Na Figura 31 podemos ver um gráfico com a distribuição das classificações dos utilizadores para cada uma das 10 perguntas.




Figura 31 - Diagrama de extremos e quartis das respostas ao questionário

Os resultados recolhidos nos formulários levam-nos a concluir que as principais funcionalidades foram todas validadas pelos utilizadores de forma positiva, apresentando uma mediana de avaliações de 4 para todas as perguntas, exceto na pergunta 7 com um valor de 3,5 e na 10 foi de 3.

Na pergunta 7 pedia-se ao utilizador para avaliar a sua experiência na avaliação de restaurantes. Na pergunta 10 desafiava-se o utilizador a comparar a satisfação da utilização da aplicação relativamente à sua satisfação com outras aplicações semelhantes comerciais

Para além dos dados recolhidos nos formulários, foram também recolhidos comentários textuais com propostas de melhorias de vários aspetos que serão tidos em conta em futuros melhoramentos.

4 Conclusões e Trabalho Futuro

Este trabalho teve como objetivo principal o desenvolvimento de um sistema capaz de recolher as avaliações que cada utilizador faz dos diversos restaurantes que visita e utilizá-las para produzir recomendações personalizadas. Para isso foi necessário o desenvolvimento e implementação de um algoritmo de recomendação alimentado em exclusivo pelas avaliações dos utilizadores, bem como o desenvolvimento de uma aplicação para dispositivos móveis de acesso à plataforma. Isto permite ao utilizador visualizar recomendações geradas pelo sistema, fazer pesquisas e partilhar comentários com a restante comunidade.

O objetivo foi atingido com sucesso tendo como base os resultados dos testes efetuados na base dados MovieLens validando o algoritmo de recomendação, e nos testes de aceitação da aplicação móvel junto dos utilizadores.

Em termos de trabalho futuro, tal como foi exposto no capítulo 2, sabe-se que os sistemas de recomendação colaborativa puros têm diversas fraquezas que afetam negativamente a qualidade das recomendações. Os sistemas híbridos combinam dois ou mais sistemas de recomendação, justamente para mitigar as fraquezas individuais de cada um. Dito isto, seria muito vantajoso para a qualidade das recomendações se fosse implementado um sistema de recomendação paralelo baseado nas características dos restaurantes (filtragem com base no conteúdo). A combinação desse sistema com o atual iria permitir que a qualidade das recomendações aumentasse consideravelmente.

A grande maioria das interações entre os utilizadores e a aplicação móvel implica uma ligação ativa à Internet, e à troca de informação entre o dispositivo móvel e o servidor do sistema. Quando a ligação à Internet é de má qualidade ou intermitente, o utilizador tem uma experiência de utilização muito pouco satisfatória. Uma forma de mitigar esse problema passa por passar grande parte da base de dados com a informação referente a todos os pontos de interesse para o próprio dispositivo móvel. Esta transferência da informação iria reduzir substancialmente o tráfego de informação necessário para suportar as funcionalidades da aplicação. Embora a transferência dos dados de todos os restaurantes para os próprios dispositivos implique a implementação de mecanismos de atualização dessa informação nos dispositivos, a diminuição das necessidades de comunicação compensam esse aumento de complexidade.

Bibliografia

- Adomavicius, G., & Tuzhilin, A. (2005). 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. doi:10.1109/TKDE.2005.99
- Amatriain, X., Lathia, N., & Pujol, J. (2009). The wisdom of the few: a collaborative filtering approach based on expert opinions from the web. *Proceedings of the 32nd ...*, 532–539. Retrieved from <http://dl.acm.org/citation.cfm?id=1572033>
- Appetite - Super Bock. (2012). Retrieved October 12, 2012, from www.appgeneration.com/geoinfo/appetite
- Balabanović, M. (1997). Fab : content-based , collaborative recommendation. *Communications of the ACM*, 66(March), 1–7. Retrieved from <http://dl.acm.org/citation.cfm?id=245124>
- Bonnington, C. (2012). Foodspotting App Adds Dish Recommendations to the Menu. Retrieved July 1, 2012, from <http://www.wired.com/gadgetlab/2012/02/foodspotting-app-rec-updates/>
- Breese, J., Heckerman, D., & Kadie, C. (1998). Empirical analysis of predictive algorithms for collaborative filtering. *Proceedings of the Fourteenth ...*. Retrieved from <http://research.microsoft.com/en-us/um/people/heckerman/bhk98uai.pdf>
- Burke, R. (2002). Hybrid recommender systems: Survey and experiments. *User modeling and user-adapted interaction*, 1–29. Retrieved from <http://www.springerlink.com/index/N881136032U8K111.pdf>
- Candillier, L., Meyer, F., & Boullé, M. (2007). Comparing state-of-the-art collaborative filtering systems. *Machine Learning and Data Mining in ...*, 548–562. Retrieved from <http://www.springerlink.com/index/20G0586RPM55GNX7.pdf>
- Candillier, L., Meyer, F., & Fessant, F. (2008). Designing specific weighted similarity measures to improve collaborative filtering systems. ... in *Data Mining. Medical Applications, E- ...*, 242–255. Retrieved from <http://www.springerlink.com/index/Q61H5875180J2820.pdf>
- Chesñevar, C. I., Maguitman, A. G., & Simari, G. R. (2006). Argument-based critics and recommenders: A qualitative perspective on user support systems. *Data & Knowledge Engineering*, 59(2), 293–319. doi:10.1016/j.datak.2005.09.005
- Choi, J., & Ok, C. (2011). The Effect of Online Restaurant Reviews on Diners' Visit Intention: A Comparative Analysis of Expert vs. Peer Reviews. *The 16 th Annual Graduate Education and Graduate Students Research Conference in Hospitality and Tourism, 1*. Retrieved from http://scholarworks.umass.edu/gradconf_hospitality/2011/Poster/39/
- ComScore. (2011). Mobile Subscriber Market Share. Retrieved April 8, 2012, from http://www.comscore.com/Press_Events/Press_Releases/2011/8/comScore_Reports_July_2011_U.S._Mobile_Subscriber_Market_Share
- Cremonesi, P., & Turrin, R. (2010). An evaluation methodology for collaborative recommender systems, (March). Retrieved from http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=4688072

- Davies, C. (2011). Windows Phone “Mango” official; Acer, Fujitsu and ZTE onboard. Retrieved from <http://www.slashgear.com/windows-phone-mango-official-acer-fujitsu-and-zte-onboard-24153926/>
- Fernandes, J. (2012). Aplicação Portuguesa para reservar mesas em restaurantes lidera App Store. Retrieved September 1, 2012, from http://tek.sapo.pt/noticias/internet/aplicacao_portuguesa_para_reservar_mesa_em_re_1219919.html
- Goldberg, D., Nichols, D., Oki, B., & Terry, D. (1992). Using collaborative filtering to weave an information tapestry. *Communications of the ACM*, (12). Retrieved from <http://dl.acm.org/citation.cfm?id=138867>
- Gong, S. (2010). A Collaborative Filtering Recommendation Algorithm Based on User Clustering and Item Clustering. *Journal of Software*, 5(7), 745–752. Retrieved from <http://www.academpublisher.com/ojs/index.php/js/article/view/2840>
- Hafeez. (2012). Smartphones - Advance features and history. Retrieved October 2, 2012, from <http://www.techulator.com/resources/6688-Smartphones-Advance-features-history.aspx>
- Holwerda, T. (2010). A Short History of the Tablet Computer. Retrieved April 2, 2012, from http://www.osnews.com/story/22739/A_Short_History_of_the_Tablet_Computer/page2/
- IDC. (2012). IDC Worldwide Mobile Phone Tracker. Retrieved April 8, 2012, from <http://www.idc.com/getdoc.jsp?containerId=prUS23299912>
- Koren, Y. (2010). Factor in the neighbors: Scalable and accurate collaborative filtering. *ACM Transactions on Knowledge Discovery from Data* Retrieved from <http://dl.acm.org/citation.cfm?id=1644874>
- Lee, H. J., Kim, J. W., & Park, S. J. (2007). Understanding collaborative filtering parameters for personalized recommendations in e-commerce. *Electronic Commerce Research*, 7(3-4), 293–314. doi:10.1007/s10660-007-9004-7
- Luca, M. (2011). Reviews, reputation, and revenue: The case of Yelp. com. *Com (September 16, 2011). Harvard Business School* Retrieved from http://papers.ssrn.com/sol3/papers.cfm?abstract_id=1928601
- Maltz, D., & Ehrlich, K. (1995). Pointing the way: Active collaborative filtering. *Proceedings of the SIGCHI conference on Human ...*, (May). Retrieved from <http://dl.acm.org/citation.cfm?id=223930>
- Meios & Publicidade. (2012). Taxa de penetração de smartphones em Portugal duplica num ano. Retrieved July 3, 2012, from <http://www.meiosepublicidade.pt/2012/03/01/taxa-de-penetracao-de-smartphones-em-portugal-duplica-num-ano/>
- Oku, K., & Nakajima, S. (2006). Context-aware SVM for context-dependent information recommendation. ... *Data Management, 2006* ..., 5–8. Retrieved from http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=1630645
- Pazzani, M. (1999). A framework for collaborative, content-based and demographic filtering. *Artificial Intelligence Review*, 1–16. Retrieved from <http://www.springerlink.com/index/T61V33QX45465531.pdf>

- Ricci, F., Rokach, L., Shapira, B., & Kantor, P. B. (2011). *Recommender Systems Handbook*. (F. Ricci, L. Rokach, B. Shapira, & P. B. Kantor, Eds.) *Media*. Boston, MA: Springer US. Retrieved from <http://www.springerlink.com/index/10.1007/978-0-387-85820-3>
- Rosoff, M. (2012). For The First Time Ever, Smartphones Outsold PCs Last Quarter. Retrieved April 3, 2012, from http://www.businessinsider.com/for-the-first-time-ever-smartphones-are-outselling-pcs-2012-2?utm_source=twitterfeed&utm_medium=twitter
- Sarwar, B., Karypis, G., Konstan, J., & Reidl, J. (2001). Item-based collaborative filtering recommendation algorithms. *Proceedings of the 10th international conference on World Wide Web* (pp. 285–295). ACM. Retrieved from <http://dl.acm.org/citation.cfm?id=372071>
- Sarwar, B., Karypis, G., Konstan, J., & Riedl, J. (2000). Analysis of recommendation algorithms for e-commerce. *Proceedings of the 2nd ACM conference on Electronic commerce - EC '00*, 158–167. Retrieved from <http://portal.acm.org/citation.cfm?doid=352871.352887>
- Shih, Y., & Liu, D. (2005). Hybrid recommendation approaches: collaborative filtering via valuable content information. ... *Sciences, 2005. HICSS'05. Proceedings of ...*, 00(C), 1–7. Retrieved from http://ieeexplore.ieee.org/xpls/abs_all.jsp?arnumber=1385682
- Sterling, G. (2008). First Android Phone: “T-Mobile G1 With Google”. Retrieved April 8, 2012, from <http://searchengineland.com/first-android-phone-t-mobile-g1-with-google-14796>
- Terveen, L., & Hill, W. (2001). Beyond Recommender Systems : Helping People Help Each Other Recommendation : Examples and Concepts, (1), 1–21.
- TripAdvisor. (2012). Retrieved July 1, 2012, from www.tripadvisor.com

Anexos

Anexo 1 - Ecrãs da aplicação para dispositivos móveis

A aplicação para dispositivos móveis é responsável por fornecer ao utilizador o interface de interação com o sistema de recomendação e partilha de avaliações de restaurantes. Ela é composta por um conjunto de ecrãs navegáveis entre si, arrastando a imagem para a direita ou para a esquerda. Seguidamente apresentam-se os ecrãs principais da aplicação, que fornecem o acesso às principais funcionalidades do sistema.

Ecrã de autenticação

Quando a aplicação é executada, é apresentado ao utilizador o ecrã de *login* (Figura 32) onde se pode escolher entre inserir o nome de utilizador e respetiva password, ou registar-se como novo utilizador pressionando o botão "Registar-se".




Figura 32 - Ecrã de *login* da aplicação

Ecrã de recomendação de restaurantes

Na Figura 33 mostra-se o ecrã que apresenta a lista de restaurantes mais recomendados para o utilizador que está a utilizar a aplicação. A lista apresenta os restaurantes por ordem decrescente de recomendação (representada por uma barra central colorida), bem como a distância de cada restaurante em relação ao dispositivo (lado esquerdo) e o número médio de estrelas dado pelos restantes utilizadores (direita). De entre todas as previsões de avaliações produzidas pelo motor de recomendação, apenas são mostradas as de valor maior ou igual a 3.



Figura 33 - Restaurantes mais recomendados ao utilizador

Ecrã de restaurantes por proximidade

Neste ecrã o utilizador vê a lista dos restaurantes que estão mais próximos da sua localização atual, tendo a possibilidade de escolha entre dois tipos de vistas (Figura 34). A vista em forma de lista, com informação como o nome, distância relativa ao utilizador e rating médio de cada restaurante. Alternativamente pode ver os resultados obtidos num mapa centrado na localização atual do utilizador. No mapa, os restaurantes aparecem representados por um marcador na localização correspondente.




Figura 34 - Restaurantes próximos da localização do utilizador

Pressionando um dos marcadores faz aparecer um balão com informação sobre o restaurante correspondente. Pressionando o balão mostra um novo ecrã com detalhe sobre o restaurante.

Ecrã dos restaurantes mais populares

O sistema guarda a média das avaliações efetuadas pelos utilizadores para cada restaurante. Tal como se pode ver na Figura 35, o ecrã mostra ao utilizador a lista dos restaurantes com a média de avaliações mais alta, representado por uma classificação de 1 a 5 estrelas. A lista é mostrada por ordem decrescente de valor de média de avaliações.



Figura 35 - Ecrã dos 20 restaurantes mais populares.

Ecrã de pesquisa de restaurantes

Este ecrã permite que os utilizadores efetuem pesquisas de restaurantes por nome, obtendo todos os que contenham os caracteres inseridos como parte do seu nome (Figura 36). Para minimizar os tempos de resposta e quantidade de dados transmitidos, os resultados da pesquisa foram restringidos a um máximo 30.




Figura 36 - Pesquisa por nome.

Redireccionamento para Marcador do telemóvel

No ecrã de detalhe de um restaurante, a ação de pressionar o botão "ligar", invoca o marcador telefónico passando-lhe o número de contacto. O utilizador depois escolhe se procede com a chamada ou não (Figura 37).




Figura 37 - Ligação ao marcador telefónico do dispositivo.

Redirecionamento para software de navegação

A partir do ecrã de detalhe de um restaurante, pressionando o botão "Navegar", provoca o aparecimento de um menu com a lista de aplicações instaladas no dispositivo com capacidade de navegar até ao restaurante. Na Figura 38 mostra-se a sequência de ecrãs desde pressionar o botão, passando pelo menu de escolha da aplicação a executar para navegar até ao restaurante, e finalmente o ecrã do navegador seleccionado.




Figura 38 - Sequência de ecrãs de ligação entre a aplicação e o navegador.

Avaliação de restaurante

No ecrã de detalhe de um restaurante, se o utilizador pressionar o botão "Avaliar", irá surgir uma caixa de diálogo (Figura 39) dando-lhe a possibilidade de fazer uma avaliação de 1 a 5 estrelas bem como adicionar opcionalmente um comentário.




Figura 39 - Avaliação de 1 a 5 estrelas e comentários.

Ligação ao *Facebook*

Após o utilizador avaliar um restaurante, surge uma caixa de diálogo perguntando se deseja partilhar a sua avaliação no *Facebook*. Caso o utilizador concorde, é invocada a API do *Facebook* e enviados os dados referentes ao restaurante bem como o valor da avaliação feita (Figura 40).




Figura 40 - Partilha da avaliação no *Facebook*.

Anexo 2 - Ecrãs da aplicação de web de administração

Na Figura 41 mostra-se o ecrã de gestão de utilizadores onde se listam os utilizadores mediante determinado critério de pesquisa. Podem adicionar-se novos utilizadores e editar as características de cada um, através do *link* para a página de edição de perfil de utilizadores que está presente em cada linha da tabela de utilizadores.




Figura 41 - Ecrã de gestão de utilizadores

Na Figura 42 mostra-se o ecrã de gestão de restaurantes onde é possível lista-los mediante determinado critério de pesquisa. Permite adicionar novos restaurantes e visualizar o detalhe de cada um, através do *link* para a página de visualização de detalhes que está presente em cada linha dos resultados de pesquisa.




Figura 42 - Gestão de restaurantes

Na Figura 43 mostra-se o detalhe da informação relativa a determinado restaurante onde se podem ver todas as avaliações e comentários feitos pelos utilizadores. Os atributos do restaurante podem ser editados através de um *link* para a página de edição.

The screenshot shows a web application interface for 'ANDROSIO'. The top navigation bar includes 'Restaurantes', 'Utilizadores', and 'Configuração'. The main heading is '101-Snack-Bar Restaurante e Gelataria Lda' with an 'Editar Restaurante' link. Below this is a table of restaurant details:

DESIGNAÇÃO	101-Snack-Bar Restaurante e Gelataria Lda	Avaliação Média ★★★★☆
CONTACTO	218496836	
DESCRIÇÃO		
ARRUAMENTO	Avenida Almirante Gago Coutinho 101C, Lisboa	
CÓDIGO POSTAL	1700 - 029	
DESIG POSTAL	LISBOA	

Below the details is a table of reviews. An 'Export to Excel' button is on the left. The review table has columns: Utilizador, AVALIAÇÃO, COMENTÁRIO, and DATA DA AVALIAÇÃO. It shows 8 reviews from various users, with the most recent from 15 Oct (7 days ago).

Utilizador	AVALIAÇÃO	COMENTÁRIO	DATA DA AVALIAÇÃO
Paulo Admin	★★★★☆	Come-se!	15 Oct (7 days ago)
Maria Jacinta	★★★★☆	Razoável para o preço.	23 Aug
Manuel Alves	★★★★☆	Excelente, adorei!	23 Aug
Jaqueline Pinto	★★★★☆	Comida fria e sem sabor.	23 Aug
Vivancio Pontes	★★★★☆	Já comi pior	23 Aug
João das Neves	★★★★☆	Do melhor que já comi em Lisboa	23 Aug
Manel Vasco	★★★★☆	Boa Comida e bom atendimento.	23 Aug
Paulo Admin	★★★★☆	Baratas por todo o lado!	2000-01-01

Figura 43 - Ecrã de detalhe de restaurante

Anexo 3 - Formulário de feedback de aceitação - Aplicação Andrósio

Por favor responda às seguintes perguntas para fins estatísticos:

Qual o seu género? *

☒ Masculino ☐ Feminino

Qual a faixa etária a que pertence? *

☒ 0 a 17 anos ☐ 18 a 24 anos ☐ 25 a 34 anos ☐ 35 a 44 anos ☐ 45 a 54 anos ☐ 55 a 64 anos ☐ 65+

Que versão do Android utilizou? *

☐ 2.1 ☐ 2.2.x ☐ 2.3.x ☐ 3.x ☐ 4.0.x ☒ 4.1.x ☐ Não sei

Por favor preencha o formulário, avaliando a aplicação móvel quanto às diversas funcionalidades.

P1 -Como classifica a sua experiência de registo como novo utilizador?

1 2 3 4 5
Muito má ☐ ☐ ☐ ☐ ☐ Muito boa

P2 -Como classifica a facilidade de utilização e navegação na aplicação?

1 2 3 4 5
Muito difícil ☐ ☐ ☐ ☐ ☐ Muito fácil

P3 -Qual o grau de satisfação nos resultados obtidos para restaurantes próximos?

1 2 3 4 5
Baixo ☐ ☐ ☐ ☐ ☐ Alto

P4 -Qual o grau de satisfação nos resultados obtidos para restaurantes mais populares?

1 2 3 4 5
Baixo ☐ ☐ ☐ ☐ ☐ Alto

P5 -Qual o grau de satisfação nos resultados obtidos na pesquisa de restaurantes por nome?

1 2 3 4 5
Baixo ☐ ☐ ☐ ☐ ☐ Alto

P6 -Qual o grau de satisfação com as recomendações apresentadas?

	1	2	3	4	5	
Baixo	☐	☐	☐	☐	☐	Alto

P7 -Como classifica a experiência de avaliação/critica de um restaurante?

	1	2	3	4	5	
Muito Má	☐	☐	☐	☐	☐	Muito Boa

P8 -Como classifica a Integração com o Facebook na partilha de críticas de restaurantes?

	1	2	3	4	5	
Muito Má	☐	☐	☐	☐	☐	Muito Boa

P9 -Como classifica a Integração com um navegador (Ndrive / Google Navigation) ?

	1	2	3	4	5	
Muito Má	☐	☐	☐	☐	☐	Muito Boa

P10 -Caso conheça aplicações semelhantes como o BestTables, Appetite ou FoodSpotting, comparativamente como classifica esta?

	1	2	3	4	5	
Muito Má	☐	☐	☐	☐	☐	Muito Boa

Anexo 4 - Lista das principais *stored procedures*

CalcMatProxUtilizadores - Calcula a correlação entre o utilizador e todos os outros.

InserirPDI - Permite inserir um novo restaurante com um conjunto de informação associada.

InserirPDIAval - Insere uma nova avaliação de restaurante incluindo um comentário.

ObtemPDI - Obtém da base de dados os detalhes referentes a determinado restaurante.

ObtemPDIAvals - Obtém da base de dados, os comentários sobre determinado restaurante.

ObtemPDIsPChave - Gera uma lista de restaurantes com determinada palavra na descrição.

ObtemPDIsProximos - Gera uma lista de restaurantes próximos do utilizador.

ObtemTopEvalPois - Gera a lista de restaurantes com média de avaliações mais elevada.

ObtemPDIsRec - Gera a lista de restaurantes recomendados para determinado utilizador.

Regista_utilizador - Processa o registo de um novo utilizador.

ActualizaConfigSys - Permite atualizar os parâmetros do motor de recomendações.

Anexo 5 - Resultados experimentais com algoritmos de recomendação

Na tabela 5 apresentam-se os resultados experimentais da aplicação de diversas variantes de algoritmos de recomendação ao conjunto de dados MovieLens. Estas experiências foram efectuadas recorrendo-se à livreria MyMediaLite²⁰ pertencente à Universidade de Hildesheim²¹.

Method	recommender-options	RMSE	MAE
GlobalAverage		1.117	0.934
UserAverage		1.036	0.827
ItemAverage		0.983	0.783
SlopeOne		0.902	0.712
UserItemBaseline	reg_u=25 reg_i=10, num_iter=10	0.908	0.719
ItemKNNPearson	k=80 shrinkage=10 reg_u=25 reg_i=10	0.871	0.683
FactorWiseMatrixFactorization	num_factors=11 shrinkage=115	0.860	0.673
MatrixFactorization	num_factors=10 num_iter=75 reg=0.05 learn_rate=0.005	0.857	0.675
BiasedMatrixFactorization	num_factors=6 bias_reg=0.25 reg_u=0.4 reg_i=1.2 frequency_regularization=true learn_rate=0.03 num_iter=80 bold_driver=true	0.854	0.674
BiasedMatrixFactorization	num_factors=20 bias_reg=0.25 reg_u=0.4 reg_i=1.2 frequency_regularization=true learn_rate=0.03 num_iter=80 bold_driver=true	0.852	0.672
BiasedMatrixFactorization	num_factors=40 bias_reg=0.001 regularization=0.060 learn_rate=0.07 num_iter=110 bold_driver=true	0.855	0.676
BiasedMatrixFactorization	num_factors=60 bias_reg=0.001 regularization=0.060 learn_rate=0.07 num_iter=100 bold_driver=true	0.854	0.676
BiasedMatrixFactorization	num_factors=80 bias_reg=0.001 regularization=0.060 learn_rate=0.07 num_iter=100 bold_driver=true	0.854	0.676
BiasedMatrixFactorization	num_factors=120 bias_reg=0.001 regularization=0.055 learn_rate=0.07 num_iter=100 bold_driver=true	0.854	0.676
SVDPlusPlus	num_factors=10 num_iter=80 reg=0.05 learn_rate=0.005	0.852	0.668
SVDPlusPlus	num_factors=20 num_iter=80 reg=0.05 learn_rate=0.005	0.851	0.668

Tabela 5 - Resultados experimentais de algoritmos de recomendação na base MovieLens 1M

²⁰ <http://www.ismll.uni-hildesheim.de/mymedialite/examples/datasets.html>

²¹ <http://www.ismll.uni-hildesheim.de/>