



Universidade Aberta

Abordagem Multiagente em Sistemas de Recomendação Web

Joaquim Augusto Queirós Frazão Neto

Dissertação para obtenção do Grau de Mestre em

Tecnologias e Sistemas Informáticos Web

Orientador: Doutor António Jorge do Nascimento Morais

Janeiro de 2015

Resumo

O crescimento exponencial da informação disponível na Web torna difícil para os utilizadores a tarefa de obter a informação que pretendem e quando dela necessitam. Para ultrapassar o problema, os *sítios Web* têm vindo a incorporar sistemas de recomendação que, baseados no histórico de acessos, têm como objetivo maximizar a satisfação dos utilizadores, disponibilizando-lhes recomendações de alta qualidade.

A complexidade do problema e a natureza distribuída da Web justificam abordagens baseadas na tecnologia dos agentes inteligentes autónomos e sistemas multiagente, permitindo combinar múltiplos algoritmos de recomendação, aumentando assim as hipóteses das recomendações sugeridas serem efetivamente do interesse do utilizador. É este o tipo de abordagem explorada pelo sistema de recomendação multiagente AMAAFWA (*A Multi-Agent Approach for Web Adaptation*) (Morais, 2013). Os testes realizados em modo *offline* mostraram que essa abordagem multiagente, baseada em agentes implementando diferentes algoritmos, apresenta um desempenho superior ao dos algoritmos considerados individualmente.

O objetivo desta dissertação é adaptar e testar o sistema AMAAFWA em tempo real, com o objetivo de validar os resultados obtidos em modo *offline*, pelo que se procedeu à sua adaptação para funcionamento *online*, integrando-o num sítio Web. O sistema AMAAFWA baseia-se numa classificação implícita dos itens e os algoritmos de recomendação são baseados em memória e incrementais. Foi também criada e testada uma versão do sistema que considera uma classificação explícita dos itens por parte dos utilizadores, com o propósito de comparar o desempenho de ambos os tipos de classificação.

Demonstra-se na presente dissertação que o sistema de recomendação multiagente AMAAFWA, em funcionamento *online*, apresenta um desempenho superior ao dos algoritmos considerados individualmente, sendo ainda capaz de melhorar a satisfação do utilizador e contribuir para o aumento do sucesso do sítio Web em que se insere. Relativamente à comparação dos tipos de classificação implícita e explícita dos itens, os resultados mostram desempenhos similares.

Palavras-chave: Sistemas de recomendação Web, Sistemas multiagente, Regras associativas, Filtragem colaborativa, JADE.

Abstract

The exponential growth of information available on the Web makes it difficult for users to get the information they want and when they need it. To overcome the problem, the Web sites are using recommender systems in order to provide high-quality recommendations to the users and, in that way, improve user satisfaction.

The complexity of the problem and the distributed nature of Web justify the use of the autonomous intelligent agents and multi-agent systems technology approaches, which allows the combination of multiple recommendation algorithms in order to increase the chances of the suggested recommendations to be actually of interest to the users. The multi-agent recommender system AMAAFWA (*A Multi-Agent Approach for Web Adaptation*) (Morais, 2013) explores this approach. The results of the tests performed offline showed that this multi-agent approach, based on agents implementing different algorithms, has a higher performance when compared to individual algorithms.

The goal of this dissertation is to adapt and test the AMAAFWA system in real-time operation, in order to validate the results obtained in offline mode. So, we adapted the system for online operation and integrate it on a website. The AMAAFWA system is based on implicit classification of items and the recommendation algorithms are memory and item-based and incremental. It was also built and tested a version of the system that considers explicit classification of items by users, with the aim of comparing the performance of both types of classification.

It is shown in this dissertation that the multi-agent recommender system AMAAFWA, in online and real-time operation, has a higher performance when compared to individual algorithms, being able to improve user satisfaction and contribute to the increasing success of the website. Concerning the comparison between implicit and explicit classification, the results show a similar performance for both.

Keywords: Web Recommender Systems, Multi-agent Systems, Association Rules, Collaborative Filtering, JADE

Às minhas quatro princesas, que todos os dias me fazem feliz,
a minha mulher Isabel e as minhas filhas Rita, Joana e Bia.

Agradecimentos

Sendo um trabalho na maioria das vezes solitário, só foi possível com o apoio e colaboração de muitos. Assim, não poderia deixar de tornar público o meu particular agradecimento a quem, ao longo do último ano, de uma forma ou de outra, contribuiu decisivamente para tornar possível a realização desta dissertação, a saber:

- Ao meu orientador, Professor Doutor António Jorge do Nascimento Morais, pelo apoio, pelos conselhos e sugestões, sem os quais não teria sido possível concluir este trabalho com sucesso.
- À Universidade Aberta, nas pessoas do coordenador e do vice-coordenador do Curso de Mestrado em Tecnologias e Sistemas Informáticos Web, Professor Doutor Paulo Shirley e Professor Doutor Vítor Rocio, respetivamente, por me terem dado a oportunidade e o privilégio de frequentar este Mestrado, que muito contribuiu para o enriquecimento da minha formação académica e científica.
- Ao Laboratório Nacional de Engenharia Civil (LNEC), na pessoa do Investigador Principal Carlos António de Oliveira Costa, pelo apoio e disponibilização de infraestruturas essenciais para a conclusão desta dissertação.
- Aos meus colegas da Divisão de Infraestruturas Informáticas do Centro de Instrumentação Científica do LNEC pelo apoio, em particular, ao Dr. Rui Monteiro, sempre disponível para me ouvir e garantir que nada faltasse.
- A todos os professores do Curso de Mestrado em Tecnologias e Sistemas Informáticos Web, que sempre foram capazes de me estimular na busca do conhecimento.
- A todos aqueles, anónimos, que colaboraram na realização dos testes, porque sem eles teria sido impossível concluir esta dissertação.

Por último, mas não menos importante, à minha família pelo apoio e por sempre me incentivarem, aceitando algumas privações sempre de sorrisos nos lábios.

Índice

Resumo.....	i
Abstract	iii
Agradecimentos.....	vii
Índice de Tabelas.....	xiii
Índice de Figuras	xv
1. Introdução.....	1
1.1 Objetivos e formulação do problema a investigar.....	2
1.1.1 Metodologia adotada	3
1.2 Contribuições	4
1.3 Infraestruturas e meios.....	6
1.4 Estrutura do documento	7
2. Sistemas Multiagente e Sistemas de Recomendação Web.....	9
2.1 Agentes Inteligentes e Sistemas Multiagente.....	9
2.1.1 Definição de agentes	9
2.1.2 Caraterísticas dos agentes.....	10
2.1.3 Agentes e Objetos.....	12
2.1.4 Agentes e Sistemas Periciais (<i>Expert Systems</i>)	12
2.1.5 Principais tipos de agentes.....	13
2.1.6 Sistemas Multiagente	15
2.2 Sistemas de Recomendação Web.....	15
2.2.1 Informação implícita versus informação explícita	16
2.2.2 Tipos de abordagem	17
2.2.2.1. Abordagens baseadas em conteúdo	17
2.2.2.1.1 Limitações.....	18
2.2.2.2. Abordagens colaborativas	19
2.2.2.2.1. Limitações	20

2.2.2.2.2.	Recomendação baseada em utilizadores e baseada em itens	22
2.2.2.2.3.	Escalabilidade e qualidade das recomendações.....	23
2.2.2.2.4.	Algoritmos baseados em memória e baseados em modelos	24
2.2.2.3.	Abordagens híbridas	25
3.	Sistema de Recomendação Web AMAAFWA.....	27
3.1	Formulação teórica do sistema de recomendação.....	29
3.1.1	Formalização de um sítio Web	29
3.1.2	Formalização do sistema de recomendação.....	32
3.1.3	Avaliação do sistema de recomendação	33
3.2	Arquitetura do sistema multiagente	35
3.2.1	Caraterização dos agentes.....	36
3.2.1.1	Agente servidor (server agent)	36
3.2.1.2	Agente cliente (client agent).....	37
3.2.1.3	Agente de recomendação (recommender agent).....	37
3.2.2	Detalhes de implementação.....	38
3.3	Agentes de recomendação.....	39
3.3.1	Agente baseado em regras de associação	39
3.3.2	Agente baseado em filtragem colaborativa	41
3.3.3	Agente baseado nas n páginas mais visitadas.....	42
3.4	Recomendações a apresentar ao utilizador	42
3.5	Desempenho <i>offline</i> do sistema	43
3.6	Adaptação do Sistema de Recomendação Web AMAAFWA para utilização <i>online</i>	46
3.6.1	Detalhe de implementação	47
3.6.2	Funcionamento do sistema	48
3.6.3	Adaptação do sistema para funcionamento com classificação explícita dos itens	48
4.	Testes e resultados.....	51
4.1	Descrição dos testes realizados	51
4.2	Análise dos Resultados	54

4.2.1	Experiência de Navegação dos Utilizadores e Objetivos do Sítio Web	54
4.2.2	Análise do desempenho do sistema de recomendação multiagente	63
4.2.3	Classificação Implícita versus Classificação Explicita dos Itens	67
5.	Conclusões e Trabalho Futuro.....	73
5.1	Respostas às questões de investigação formuladas.....	74
5.2	Trabalho futuro	77
6.	Referências Bibliográficas	79

Índice de Tabelas

Tabela 2-1 – Investigação em sistemas de recomendação (estado da arte).....	26
Tabela 3-1 – Caraterização dos conjuntos de dados dos testes offline.....	44
Tabela 3-2 – Resultados dos testes <i>offline</i>	45
Tabela 4-1 - Caraterização dos conjuntos de dados de ambos os testes.....	54
Tabela 4-2 – Percentagem de visualização de fotos.....	55
Tabela 4-3 – Percentagem de recomendações seguidas.....	55
Tabela 4-4 – Conjuntos de dados (dados originais vs dados filtrados).....	57
Tabela 4-5 – Resultados (dados originais vs dados filtrados).....	57
Tabela 4-6 - Percentagem de recomendações seguidas (dados originais e dados filtrados).....	58
Tabela 4-7 – Conjunto de dados da 1ª fase (dados filtrados).....	60
Tabela 4-8- Caraterização dos resultados observados.....	61
Tabela 4-9 – Tabela de frequências relativa e cumulativa.....	62
Tabela 4-10 – Páginas de foto visitadas (com e sem a recomendações ativas).....	64
Tabela 4-11 - Resultados por agente de recomendação.....	65
Tabela 4-12- Resultados para 1ª fase – apenas não são considerados os fins de sessão.....	66
Tabela 4-13 - Resultados para 1ª fase – apenas são considerados itens elegíveis para recomendação .	66
Tabela 4-14 – Caraterização dos conjuntos de dados de ambos os testes.....	68
Tabela 4-15 - Percentagem de visualização de fotos e recomendações: classificação implícita e explícita.....	68
Tabela 4-16 – Comparação de resultados: classificação implícita e explícita.....	69
Tabela 4-17 – Peso dos agentes de recomendação nas recomendações apresentadas.....	71
Tabela 4-18 – Resultados considerando todos os registos, exceto os fins de sessão.....	71
Tabela 4-19 – Resultados considerando apenas os itens elegíveis para recomendação.....	72

Índice de Figuras

Figura 3-1 – Arquitetura global da solução de recomendação Web AMAAFWA.....	28
Figura 3-2 – Página Web com o conjunto de recomendações apresentadas ao utilizador	29
Figura 3-3 – Arquitetura do sistema multiagente	35
Figura 3-4 – Arquitetura do sistema de recomendação	38
Figura 3-5 – Arquitetura do sistema de recomendação – módulos a adaptar	46
Figura 3-6 – Arquitetura global do sistema de recomendação (adaptação para utilização <i>online</i>)	47
Figura 4-1 – Página de foto do sítio Web: 1º teste (recomendações inativas)	52
Figura 4-2 - Página de foto do sítio Web: 1º teste (recomendações ativas)	53
Figura 4-3 - Página de foto do sítio Web: 3º teste (recomendações ativas e botão “ <i>Gosto</i> ”).....	53
Figura 4-4 - Gráfico de dispersão (nº de visitas/página) baseado em dados originais	56
Figura 4-5 - Gráfico de dispersão (nº de visitas/página) baseado em dados filtrados	58
Figura 4-6 - Gráfico de dispersão (RECS_ON VS RECS_OFF) baseado em dados filtrados	59
Figura 4-7 -Tempo de resposta do sistema de recomendação: histograma de frequência relativa.....	62
Figura 4-8-Tempo de resposta do sistema de recomendação: histograma de frequência cumulativa...	63
Figura 4-9 – Gráfico de dispersão (nº visitas/página): classificação implícita e explícita	70
Figura 4-10 – Gráfico de Dispersão (Classificação Implícita VS Explícita).....	70

1. Introdução

O crescimento exponencial da informação disponível na Web torna difícil para o utilizador a tarefa de obter a informação que pretende e quando dela necessita. Mesmo o recurso a motores de busca, ainda que capazes de proporcionar uma seleção de informação, colocam à disposição dos utilizadores um tão grande leque de ligações supostamente relevantes, que a utilidade do resultado da pesquisa tende a diminuir, fazendo-se sentir a necessidade de algo que torne essa seleção de informação mais precisa e consentânea com os interesses dos utilizadores.

Os sistemas de recomendação Web são uma solução que permite reduzir a sobrecarga de informação colocada à disposição dos utilizadores, fornecendo-lhes recomendações de alta qualidade, através duma seleção de conteúdos baseada na relevância dessa informação para esses utilizadores.

Os sistemas de recomendação Web estão cada vez mais presentes nos sítios Web. A recomendação de um conjunto de páginas Web de potencial interesse para o visitante de um sítio Web, tendo como base o registo histórico de acessos, visa melhorar a experiência do utilizador, dotando-o de ferramentas de pesquisa facilitadoras e eficazes.

Os sistemas multiagente (Wooldridge, 2009), dadas as suas características e flexibilidade, permitem combinar múltiplos algoritmos de recomendação, aumentando as hipóteses de as recomendações sugeridas serem efetivamente do interesse dos utilizadores. De facto, como referem Morais, et al. (2014), têm já sido aplicadas abordagens multiagente na automatização da Web (Ardissono et al., 2005), em face das já referidas flexibilidade e características deste tipo de sistemas. Ainda de acordo com Morais, et al. (2014), os sistemas multiagente são também usados na recuperação e atualização automática de sítios Web (Albayrak, et al., 2005) e Wei, et al. (2005) propôs a implementação de um sistema de recomendação usando uma abordagem multiagente.

1.1 Objetivos e formulação do problema a investigar

No âmbito do trabalho de dissertação pretendeu-se investigar em que medida a tecnologia dos agentes inteligentes autónomos e sistemas multiagente pode ser usada para melhorar o desempenho de sistemas de recomendação Web.

O trabalho de investigação teve por base o sistema de recomendação multiagente AMAAFWA, desenvolvido por A. Jorge Morais no âmbito da sua tese de doutoramento (Morais, 2013).

Pretende-se investigar se o referido sistema de recomendação, constituído por um sistema multiagente, com agentes de recomendação baseados em diferentes algoritmos de recomendação, apresenta um melhor desempenho que um sistema de recomendação baseado num único algoritmo de recomendação, bem como avaliar se esse sistema é capaz de proporcionar, na prática, uma solução que não só permita colocar à disposição dos utilizadores a informação que estes procuram e desejam, em tempo real e de forma satisfatória, como também seja capaz de potenciar os objetivos a que o sítio Web se propõe.

O problema a investigar pode assim ser formulado através das três questões seguintes:

- Poderá o sistema de recomendação multiagente AMAAFWA (Morais, et al., 2012), com agentes baseados em diferentes algoritmos de recomendação, apresentar um melhor desempenho que um sistema de recomendação baseado num único algoritmo de recomendação?
- Poderá esse sistema de recomendação multiagente ser capaz de disponibilizar ao utilizador a informação que este procura, em tempo real e de forma satisfatória?

- Poderá o sistema de recomendação multiagente ser capaz de potenciar os objetivos do sítio Web em que se insere?

Também objeto de investigação é a comparação do desempenho do sistema de recomendação multiagente AMAAFWA baseado numa classificação implícita dos itens como originalmente desenvolvido por Morais (2013), com um sistema baseado numa classificação explícita como a implementada no âmbito da presente dissertação.

1.1.1 Metodologia adotada

Em face do problema formulado, podemos classificar o trabalho desenvolvido como enquadrável num projeto de investigação do tipo investigação aplicada.

De facto, a investigação aplicada refere-se ao estudo e pesquisa científica que procura resolver problemas de ordem prática, isto é, procura encontrar soluções para os problemas do dia-a-dia, sejam, por exemplo, relacionados com o tratamento ou cura de doenças, com o melhoramento da produção de culturas agrícolas ou o desenvolvimento de tecnologias inovadoras.

Entre essas tecnologias inovadoras que se podem enquadrar em investigação aplicada, podemos considerar as tecnologias Web, pois também estas procuram encontrar respostas para problemas de ordem prática, seja nas organizações, seja na sociedade em geral.

De facto, como refere Marcos (2012), a investigação em ciência e tecnologia Web foca o seu estudo na “adoção e utilização das tecnologias da informação nas organizações e na sociedade em geral, com foco nas que estão subjacentes à Web e suas aplicações”, isto é, envolve em geral o estudo dos efeitos da aplicação prática da tecnologia. Podemos considerar que, em geral, a investigação em ciência e tecnologia Web é do tipo investigação aplicada, isto é “aborda cenários de uso reais de adoção/aplicação da tecnologia Web”(Marcos, 2012).

Pelo que, como já se referiu, podemos dizer que estamos perante um projeto de investigação do tipo investigação aplicada, cujo propósito é estudar a adoção e utilização da tecnologia dos agentes inteligentes autónomos e sistemas multiagente na resolução de um problema ordem prática das organizações, que, no caso do projeto a desenvolver, está relacionado com o objetivo de fornecer aos utilizadores dos seus sítios Web a informação que estes procuram, em tempo útil, de forma fácil e satisfatória.

Para Coutinho, et al. (2008, pp. 362,363), o que melhor caracteriza e identifica a Investigação-Ação “é o facto de se tratar de uma metodologia de pesquisa, essencialmente prática e aplicada, que se rege pela necessidade de resolver problemas reais”.

Uma das características da Investigação-Ação é o facto de envolver uma espiral de ciclos, como descrito por Kurt Lewin (planeamento, ação, observação e reflexão), nos quais as descobertas iniciais geram possibilidades de mudança, “que são então implementadas e avaliadas como introdução do ciclo seguinte. Temos assim um permanente entrelaçar entre teoria e prática” (Coutinho, et al., 2008, p. 362). Esta espiral de ciclos realça a característica de autoavaliação da Investigação-Ação, pois “as modificações são continuamente avaliadas, numa perspetiva de adaptabilidade e de produção de novos conhecimentos” (Coutinho, et al., 2008, p. 362).

Assim, considerando Marcos (2012) que a investigação em ciência e tecnologia Web é “essencialmente baseada em investigação aplicada, i.e. aborda cenários de uso reais de adoção/aplicação da tecnologia Web” e ainda que a investigação em ciência e tecnologia Web “integra geralmente a implementação de um protótipo”, justifica-se a necessidade dos ciclos de investigação-ação, relacionados com a implementação e uso do protótipo.

Apesar de no caso presente, não estar em causa a necessidade de construção de um protótipo de raiz, pois o projeto desenvolvido teve por base o sistema de recomendação AMAAFWA (Morais, et al., 2012), as adaptações implementadas no referido sistema de modo a que pudesse ser testado *online*, num sítio Web real, configuram, também, uma situação de prototipagem, pelo que considerámos que a metodologia Investigação-Ação se adequava ao projeto de investigação que se pretendia desenvolver.

1.2 Contribuições

Com o presente trabalho de investigação pretendeu-se contribuir para o aprofundamento do estudo do sistema de recomendação multiagente AMAAFWA, desenvolvido por A. Jorge Morais no âmbito da sua tese de doutoramento (Morais, 2013). As principais contribuições consistiram no seguinte:

- Adaptação do sistema de recomendação para funcionamento em tempo real de modo a testar o seu desempenho em funcionamento *online*, comparar os resultados com os obtidos por Morais (2013) e responder às questões de investigação formuladas e apresentadas no ponto 1.1).

- Adaptação do sistema de recomendação para funcionamento baseado numa classificação explícita dos itens por parte dos utilizadores, de modo a comparar o seu desempenho com o sistema baseado numa classificação implícita dos itens como originalmente desenvolvido por Morais (2013).

Todos os trabalhos de adaptação e alteração do sistema de recomendação AMAAFWA acima referidos foram de nossa autoria e consistiram no seguinte:

- Alteração e adaptação do sítio Web 1000 Palavras (www.1000palavras.pt), de modo a acolher o sistema de recomendação AMAAFWA. Nos trabalhos desenvolvidos recorreu-se a diversas tecnologias Web, designadamente *PHP*, *HTML*, *CSS*, *JavaScript*, *AJAX* e *Java Servlet*, tendo os mesmos consistido no seguinte:
 - Alteração do *design* gráfico do sítio Web, dotando-o de uma área para apresentação das recomendações sugeridas pelo sistema de recomendação.
 - Alteração da estrutura da base de dados para registo da informação necessária de suporte aos pedidos a enviar ao sistema de recomendação.
 - Desenvolvimento de uma interface de comunicação entre o *browser* do utilizador e o sistema de recomendação, assente na tecnologia *AJAX* e numa *HTTP servlet*, que incorpora um *gateway* para a plataforma *JADE*.
- Alteração e adaptação do sistema de recomendação AMAAFWA para funcionamento em tempo real e integração com o sítio Web 1000 Palavras (www.1000palavras.pt). As alterações consistiram no desenvolvimento de código em Java e na utilização da plataforma *JADE*, destacando-se o seguinte:
 - Alteração do sistema para funcionamento com o sistema de gestão de base de dados *MySQL*, sistema usado pelo sítio Web 1000 Palavras (www.1000palavras.pt).
 - Criação e desenvolvimento de um agente, *gateway agent*, para assegurar a comunicação entre o sistema de recomendação e o sítio Web.
 - Alterações nos diferentes tipos de agente que constituem o sistema de recomendação, de forma a assegurar a comunicação com o sítio Web.
- Alteração e adaptação do sistema de recomendação para funcionamento baseado numa classificação explícita dos itens por parte dos utilizadores. Os trabalhos desenvolvidos neste âmbito consistiram em alterações no sítio Web e no próprio sistema de recomendação. No sítio Web foi disponibilizado um botão de “*Gosto*” para os utilizadores classificarem as fotos e no sistema de recomendação foram realizadas

as alterações que passaram a permitir diferenciar um “*Gosto*” de um simples visualizar de uma foto.

Considera-se que os trabalhos desenvolvidos e os testes efetuados no âmbito da presente dissertação contribuíram para o aprofundamento do estudo do sistema de recomendação multiagente AMAAFWA. Os resultados obtidos pelo sistema de recomendação em tempo real vieram reforçar as conclusões obtidas por Morais (2013), de que o sistema de recomendação é capaz de apresentar um melhor desempenho que um sistema de recomendação baseado num único algoritmo de recomendação, permitindo também inferir que o sistema de recomendação pode contribuir para a satisfação do utilizador e permite potenciar os objetivos do sítio Web que acolhe.

De referir também os contributos dados para as seguintes publicações:

- Jorge Morais, Joaquim Neto, Eugénio Oliveira & Alípio Mário Jorge, “*Sistema de Recomendação Web Usando Agentes*”, Revista de Ciências da Computação, nº8, 2013.
- Neto, J., & Morais, A. Jorge (2014). Multi-Agent Web Recommendations. *Distributed Computing and Artificial Intelligence, 11th International Conference ; Advances in Intelligent Systems and Computing Volume 290* (pp. 235-242). Salamanca: Springer International Publishing

Sendo de realçar que o artigo “Multi-Agent Web Recommendations”, foi apresentado pelo mestrando na conferência “DCAI – 11th International Symposium on Distributed Computing and Artificial Intelligence”, Salamanca, 4th-6th June, 2014.

1.3 Infraestruturas e meios

O projeto foi desenvolvido através de meios computacionais próprios e recorrendo a meios disponibilizados pelo Laboratório Nacional de Engenharia Civil, organismo onde o mestrando desempenha a sua atividade profissional, para alojamento do sítio Web usado para os testes *online*.

Para realização dos testes *online* foi desenvolvido o sítio Web 1000 Palavras (www.1000palavras.pt). Trata-se de um sítio Web de fotografia, que inclui 344 fotografias, distribuídas por 8 galerias.

1.4 Estrutura do documento

Após este capítulo introdutório, apresentam-se no capítulo 2 os conceitos chave relacionados com a tecnologia dos agentes inteligentes autónomos, sistemas multiagente e sistemas de recomendação Web.

No capítulo 3 descreve-se com detalhe o sistema de recomendação multiagente AMAAFWA. Começa-se por formalizar um sistema de recomendação do ponto de vista teórico, apresenta-se a abordagem multiagente seguida por Morais (2013), descrevem-se os diferentes algoritmos de recomendação em que se baseou o sistema, apresentam-se de forma sucinta os resultados e conclusões obtidos por Morais (2013) e descrevem-se os trabalhos de adaptação do sistema multiagente para funcionamento *online* integrado no sítio Web 1000 Palavras (www.1000palavras.pt).

No capítulo 4 descrevem-se os testes efetuados, apresentam-se e analisam-se os resultados obtidos.

Para finalizar, no capítulo 5 apresentam-se as conclusões e faz-se referência a alguns trabalhos de interesse a desenvolver futuramente.

2. Sistemas Multiagente e Sistemas de Recomendação Web

Os sistemas de recomendação Web estão cada vez mais presentes nos sítios Web. A recomendação de um conjunto de páginas Web de potencial interesse para o visitante de um sítio Web, tendo como base o registo histórico de acessos, visa melhorar a experiência do utilizador, dotando-o de ferramentas de pesquisa facilitadoras e eficazes.

Considerando a complexidade do problema e a natureza distribuída da Web, justifica-se uma abordagem baseada num sistema multiagente para a adaptação da Web.

A tecnologia dos agentes autónomos e sistemas multiagente é uma área de investigação que tem vindo a sofrer um grande desenvolvimento ao longo da última década e, dadas as suas características, permite combinar múltiplos algoritmos de recomendação, aumentando as hipóteses de as recomendações sugeridas serem efetivamente do interesse do utilizador.

2.1 Agentes Inteligentes e Sistemas Multiagente

2.1.1 Definição de agentes

Não existe uma definição consensual para o conceito de agente (Wooldridge, 2009). Segundo Franklin e Graesser (1996), diferentes autores definem agente consoante o uso que cada um faz do termo agente, sendo relevante referenciar algumas dessas definições.

Para Russell e Norvig (1995), “Um agente é qualquer coisa que possa ser vista como capaz de perceber, através de sensores, o ambiente onde se encontra e agir sobre esse ambiente através de atuadores”.

Gilbert, et al. (1995) definem agentes inteligentes como “entidades de *software* que desempenham um conjunto de operações, em nome de um utilizador ou outro programa, com um certo grau de independência e autonomia e que, ao fazê-lo, empregam algum conhecimento ou representação dos desejos ou objetivos do utilizador”.

Já Maes (1991, p. 108) define agentes autónomos como “sistemas computacionais que, habitando em ambientes dinâmicos e complexos, são capazes de perceber e agir de forma autónoma nesse ambiente, sendo assim capazes de realizar um conjunto de tarefas ou objetivos para os quais foram projetados”.

Os próprios Franklin e Graesser (1996, p. 4) apresentam a seguinte definição: “Um agente autónomo é um sistema que, situado num dado ambiente, é capaz de perceber esse ambiente e agir sobre ele de acordo com os seus propósitos, de tal modo que os efeitos dessas ações no ambiente são por ele percecionados no futuro”.

Finalmente, Wooldridge (2009, p. 21) socorre-se de Wooldridge e Jennings (1995) e define agente como sendo “um sistema computacional situado num dado ambiente e que é capaz de agir de forma autónoma nesse ambiente com o propósito de cumprir os objetivos que lhe foram delegados”.

Para Jennings (1999), desta última definição resulta que os agentes:

- i. são entidades capazes de resolver problemas com limites e interfaces bem definidos;
- ii. recebem como entrada o estado do ambiente em que se situam através de sensores, agindo nesse mesmo ambiente através de atuadores;
- iii. são desenhados para cumprir um propósito específico e têm objetivos determinados a atingir;
- iv. têm controlo sobre o seu comportamento e exibem um comportamento flexível na prossecução dos seus objetivos;
- v. têm de ser reativos e pró-ativos.

2.1.2 Caraterísticas dos agentes

Comum a todas as definições anteriormente enunciadas está o conceito de autonomia. No entanto, conforme também refere Wooldridge (2009), o próprio termo autonomia pode ter

significados diferentes para pessoas diferentes. Sendo a autonomia uma característica fundamental de um agente, importa clarificar em que medida podemos entender o conceito aplicado a um agente, enquanto sistema computacional. Pegando na definição de agente de Wooldridge M. (2009), podemos entender autonomia como a capacidade de o agente agir de forma a cumprir os objetivos que lhe foram delegados.

Além da autonomia, Wooldridge e Jennings (1995) referem também as seguintes propriedades que os agentes têm de possuir para que possam dar cumprimento aos objetivos que lhe foram delegados:

- Reatividade - capacidade de entender o ambiente e responder de forma adequada e em tempo às alterações que detetam.
- Pró-atividade – capacidade de tomar iniciativa;
- Habilidade social – capacidade de interagir com outros agentes e, possivelmente, com humanos.

Consideram-se agentes inteligentes, aqueles que possuam as capacidades referidas, as quais são mais exigentes do que à primeira vista podem parecer (Wooldridge M. , 2009).

No caso da reatividade está subjacente que o ambiente é dinâmico e não estático, devendo o agente responder em tempo útil às alterações que deteta no ambiente em que se insere.

Quanto à pro-atividade, esta refere-se à capacidade de o agente ir mais além do que apenas ter uma postura puramente reativa. O que se pretende é que o agente seja capaz de reconhecer oportunidades e tomar iniciativas, sem que tenha de ser estimulado por um evento.

Relativamente à habilidade social, não se trata apenas da capacidade de os agentes comunicarem entre si, mas sim à capacidade dos agentes em cooperar, coordenar e negociar no sentido de darem cumprimento aos objetivos que lhes foram delegados.

Àquelas propriedades, Wooldridge e Jennings (1995) acrescentam mais quatro características:

- Mobilidade – capacidade de um agente para se mover na rede.
- Veracidade – o agente não comunica informação que sabe ser falsa.
- Benevolência – agentes não têm objetivos conflitantes e tentam sempre fazer o que se lhes pede.
- Racionalidade – o agente agirá para atingir os seus objetivos, nunca agindo de forma a impedir que os mesmos sejam alcançados.

2.1.3 Agentes e Objetos

Em que diferem os conceitos de agente e objeto? O que traz de novo conceito de agente? Obter respostas claras para estas questões tem sido um desafio para os que se dedicam ao estudo dos agentes inteligentes.

Recordando a definição do conceito de objetos, estes são entidades computacionais que encapsulam um estado e são capazes de executar ações ou métodos sobre esse estado e que comunicam entre si através da troca mensagens. Constatam-se semelhanças claras com o conceito de agente que temos vindo a expor. No entanto, são também claras as diferenças, sendo as mais importantes as seguintes (Wooldridge, 2009):

- i. Os agentes possuem uma maior capacidade de autonomia que os objetos, sendo capazes de tomar decisões por sua iniciativa, o que não acontece com os objetos;
- ii. Ao contrário dos objetos, os agentes são capazes de ter um comportamento flexível, sabem ser reativos, pró-ativos e sociais;
- iii. Num sistema multiagente os agentes possuem pelo menos um fluxo de controlo próprio e distinto dos restantes agentes.

Os dois *slogans* seguintes, que transcrevemos sem tradução, resumem a diferença entre agentes e objetos:

“Objects do it for free; agents do it for money!” (Jennings, Sycara, & Wooldridge, 1998)

“Objects do it for free; agents do it because they want to” (Wooldridge M. , 2009, p. 29)

Apesar das diferenças entre agentes e objetos, importa notar que a similitude entre os dois conceitos faz com que, do ponto de vista de programação de *software*, o modelo orientado a objetos seja também adequado à implementação de agentes. Segundo Shoham (1993), referido por Reis (2003, p. 25), “os agentes podem ser vistos como um novo paradigma de programação: a Programação Orientada por Agentes”.

2.1.4 Agentes e Sistemas Periciais (*Expert Systems*)

Sistemas periciais são sistemas capazes de resolver problemas complexos através de raciocínio baseado em conhecimento. Esta definição envolve também semelhanças com o conceito de agente. Quanto às diferenças, Wooldridge (2009) refere que, ao contrário dos agentes, os sistemas periciais:

- i. não estão conectados ao ambiente, atuando através de um intermediário;
- ii. não são capazes de comportamento flexível (reatividade e pró-atividade);
- iii. não possuem habilidade social no sentido da cooperação, coordenação e negociação.

2.1.5 Principais tipos de agentes

Definido e percebido o conceito de agente, importa agora estudar como se podem construir agentes que gozem das propriedades de autonomia, reatividade, pró-atividade e habilidade social. Esta área de estudo é denominada arquitetura de agentes e foi definida por Maes (1991) como uma metodologia específica, suportada em técnicas e algoritmos, para construir agentes autónomos. Essa metodologia descreve como um agente pode ser decomposto num conjunto de módulos e como estes devem ser implementados de forma a interagir entre si. São esses módulos que, interagindo entre si, permitem que o agente cumpra os objetivos para que é desenhado.

Na sua tese de doutoramento, Reis (2003) faz referência a dois tipos de classificações para as arquiteturas de agentes: uma defendida por Russel e Norvig (1995), que divide os agentes em quatro classes: Agentes Reflexos Simples, Agentes com Representação do Estado do Mundo, Agentes Baseados em Objetivos e Agentes Baseados em Utilidade; a outra, apresentada por Wooldridge e Jennings (1995), considera três grandes categorias: Arquiteturas Deliberativas, Arquiteturas Reativas e Arquiteturas Híbridas. Nas arquiteturas deliberativas os agentes comportam-se de acordo com os modelos simbólicos que possuem dos seus ambientes. Nas arquiteturas reativas os agentes reagem ao ambiente, não utilizando qualquer tipo de raciocínio assente em modelos simbólicos. Nas arquiteturas híbridas os agentes combinam as capacidades deliberativa e reativa.

Os tipos de agentes classificam-se em função do tipo de arquitetura usada na sua conceção e construção. Wooldridge (2009) apresenta quatro tipos de agentes: Agentes de raciocínio dedutivo ("*Deductive Reasoning Agentes*"), Agentes de raciocínio prático ("*Practical Reasoning Agents*"), Agentes reativos ("*Reactive Agents*") e Agentes híbridos ("*Hybrid Agents*").

Os Agentes de raciocínio dedutivo enquadram-se na classe das arquiteturas deliberativas e comportam-se de acordo com a representação simbólica que possuem do seu ambiente, tomando decisões, designadamente que ações empreender, através de um raciocínio lógico dedutivo.

Os Agentes de raciocínio prático sustentam a sua tomada de decisão num raciocínio direcionado para ações. Um agente deste tipo desempenha a sua função em duas etapas: fase deliberativa e fase de raciocínio de meios e fins. Na primeira o agente tem de decidir o que fazer, tem de deliberar sobre que intenção tem de alcançar. Na segunda o agente tem de decidir como fazer, tem de decidir como atingir um fim desejado usando os meios de que dispõe.

Os agentes reativos baseiam-se numa arquitetura reativa e tomam as suas decisões reagindo ao ambiente, decidindo em tempo real com base na informação que obtêm através dos sensores, isto é, a informação obtida pelos sensores é diretamente usada no processo de tomada de decisão, não existindo qualquer tipo de raciocínio simbólico. A mais conhecida das arquiteturas reativas (Wooldridge, 2009) é a Arquitetura de Subordinação (“*Subsumption Architecture*”) desenvolvida por Rodney Brooks, a qual assenta em duas características fundamentais:

- i. A tomada de decisão do agente faz-se através de um conjunto de comportamentos direcionados para a realização de tarefas, as quais não se baseiam em raciocínios ou representações simbólicas, antes decorrem da tomada de conhecimento do ambiente através dos sensores.
- ii. Vários comportamentos podem ser desencadeados em simultâneo, pelo que terá de existir um método para escolher a ação ótima num dado momento. Brooks(1991) propôs o que designou por hierarquia de subordinação, em que as ações são organizadas por níveis, sendo que as ações dos níveis inferiores têm maior prioridade de execução.

Os agentes híbridos, como o próprio nome sugere, são capazes de comportamentos reativos e pró-ativos, e surgem por se concluir que nem os agentes puramente reativos nem os puramente deliberativos são a melhor solução para a construção de agentes. Os primeiros apresentam dificuldades relacionadas com o facto de agirem em função da informação que o sensor lhe dá no momento, sendo incapazes de executar ações que tenham subjacente um plano de longo prazo. Os segundos assentam em raciocínios simbólicos muito complexos, sendo por vezes incapazes de responder atempadamente a estímulos do exterior. A solução para colmatar essas dificuldades, é construir um agente que incorpore na sua arquitetura os dois tipos de comportamento, através de dois subsistemas: um subsistema deliberativo, que contém informação simbólica sobre o ambiente no seu todo, desenvolvendo planos e tomando

decisões através de um raciocínio lógico dedutivo e um subsistema reativo, que é capaz de tomar decisões reagindo ao ambiente e sem necessidade de raciocínios complexos.

2.1.6 Sistemas Multiagente

Um sistema multiagente pode ser definido como um sistema constituído por vários agentes capazes de trabalhar em conjunto, de forma cooperativa ou competitiva, interagindo entre si com o propósito de alcançar objetivos difíceis de atingir por um agente individual ou por um sistema monolítico (Morais, 2013).

Sendo parte de um sistema multiagente, os agentes podem cooperar ou competir entre si. Quando interagem entre si de forma cooperativa, fazem-no de forma direta ou através do ambiente com o propósito de alcançar objetivos comuns. No entanto, agentes inseridos num sistema multiagente podem também ter os seus próprios objetivos, pelo que terão de negociar de modo a alcançar os objetivos a que se propõe o sistema.

2.2 Sistemas de Recomendação Web

Já se referiu que o crescimento exponencial da informação disponível na Web torna difícil para o utilizador a tarefa de obter a informação que pretende e quando dela necessita. Para ajudar os utilizadores nessa difícil tarefa, os sítios Web têm vindo a incorporar ferramentas que permitem a sua adaptação com o propósito de proporcionar aos utilizadores um conjunto de informação mais precisa e consentânea com os seus interesses. Os sistemas de recomendação Web são uma das soluções cada vez mais usadas com esse propósito.

Para Wei, et al. (2005) uma recomendação pode ser vista como uma referência para um item (uma página web por exemplo) que é direcionada para o utilizador que procura a informação. Para os mesmos autores, um sistema de recomendação típico agrega e direciona as recomendações aos destinatários apropriados, referindo também que o valor principal de um sistema de recomendação reside na agregação de informação e na sua capacidade de proporcionar recomendações adequadas aos interesses das pessoas que as procuram.

Em comparação com um sistema de pesquisa tradicional ou de filtragem simples, os sistemas de recomendação requerem menos experiência de utilização e menos esforço por parte do utilizador para especificar e restringir os seus interesses ao consultar e operar o sistema (Resnick & Varian, 1997). Para Wei, et al. (2005) isso acontece porque os sistemas de recomendação são capazes de proporcionar recomendações de qualidade aos utilizadores, em

virtude de tais recomendações serem baseadas nas suas preferências passadas ou nas preferências de outros utilizadores com interesses similares.

Os sistemas de recomendação têm dois propósitos: (i) podem ser usados para estimular utilizadores a fazer algo, a tomar uma decisão, como por exemplo a aquisição de um determinado bem ou (ii) podem também ser usados para aliviar a sobrecarga de informação nos utilizadores, disponibilizando a estes, os itens que mais se coadunam com os seus interesses.

Os sistemas de recomendação Web fornecem uma solução que permite não só reduzir essa sobrecarga de informação colocada à disposição dos utilizadores, como também estimular a tomada de decisões, fornecendo-lhes recomendações de alta qualidade, através duma seleção de conteúdos baseada na relevância dessa informação para os utilizadores.

2.2.1 Informação implícita versus informação explícita

Um sistema de recomendação típico assenta num modelo construído a partir de dados relacionados com o comportamento passado dos utilizadores. Esses dados podem ser obtidos de forma implícita, por exemplo, visita a uma página Web ou tempo de permanência numa página, ou de forma explícita, em que o sistema pede ao utilizador informação relevante para a geração de recomendações. Neste último caso, o utilizador explicita as suas preferências para um dado item, seja através de uma classificação binária do tipo gosto/não gosto, ou através de uma escala de preferências (de 1 a 5, por exemplo).

Apesar de um modelo baseado em informação explícita ser aparentemente mais fiável, tem o inconveniente de exigir do utilizador uma predisposição para colaborar. Por outro lado, apesar de um modelo assente em informação implícita apenas nos revelar comportamentos do utilizador, nada dizendo acerca do que o utilizador pensa sobre um determinado item, não deixa, mesmo assim, de ser um modelo muito utilizado em sistemas de recomendação. Schafer, et al.(2006) referem mesmo que, em alguns domínios, dando o caso da música como exemplo, modelos baseados em informação implícita podem conduzir a resultados mais precisos que os obtidos com modelos baseados em informação explícita.

2.2.2 Tipos de abordagem

De um modo geral, os sistemas de recomendação classificam-se segundo o modo como são geradas as recomendações, identificando-se os três tipos de abordagem seguintes (Balabanovic & Shoham, 1997):

- Abordagens baseadas em conteúdo, em que são recomendados os itens com conteúdos similares àqueles que o utilizador mostrou preferência no passado.
- Abordagens colaborativas, nas quais são recomendados itens que utilizadores com preferências similares às do utilizador ativo gostaram no passado.
- Abordagens híbridas, que combinam técnicas usadas em ambos os tipos de abordagem anteriormente referidas, com o propósito de ultrapassar alguns potenciais problemas das mesmas.

A principal diferença entre sistemas de recomendação baseados em conteúdo e em filtragem colaborativa é que, nestes últimos, apenas são usadas as classificações atribuídas pelos utilizadores aos itens para produzir as recomendações, enquanto nos sistemas baseados em conteúdo, o conjunto de recomendações produzido assenta nos atributos característicos dos itens. Nos pontos seguintes caracterizam-se cada um destes tipos de abordagem.

2.2.2.1. *Abordagens baseadas em conteúdo*

Este tipo de abordagem tem as suas raízes no domínio da recuperação de informação (*information retrieval*) (Balabanovic & Shoham, 1997). Os mesmos autores definem como um puro sistema de recomendação baseado em conteúdo, aquele em que as recomendações produzidas e apresentadas a um dado utilizador se baseiam exclusivamente no perfil construído, através da análise dos itens que o utilizador avaliou no passado. Jannach, et al. (2011) definem recomendação baseada em conteúdo como aquela em que são recomendados a um utilizador os itens que melhor se enquadram nas suas preferências.

A recomendação baseada em conteúdo apresenta duas vantagens relativamente às abordagens que ignoram o conteúdo (Jannach, et al., 2011): (i) não necessita de uma base alargada de utilizadores para obter recomendações com precisão e (ii) novos itens podem ser recomendados logo que conhecidos os seus atributos.

As abordagens baseadas em conteúdo assentam numa lista de características dos itens. Por exemplo, se considerarmos uma livraria *online*, os livros poderão estar catalogados segundo o título, o preço, o género ou o autor, pelo que o utilizador expressará as suas preferências com

base naqueles atributos. O sistema de recomendação usa esses atributos e as preferências dos utilizadores para produzir as recomendações.

2.2.2.1.1 *Limitações*

As abordagens baseadas exclusivamente em conteúdo têm as suas limitações. Balabanovic e Shoham (1997) e Jannach, et al. (2011) dão particular ênfase a três aspetos que podem limitar o desempenho deste tipo de abordagens.

A primeira das limitações refere-se ao facto de em geral só ser possível fornecer uma análise de conteúdo muito superficial, referindo como exemplo o caso em que os itens a recomendar são páginas Web, caso em que não basta uma análise textual do conteúdo para aferir da qualidade da página, pois dessa análise não se tem em conta aspetos como a estética, a usabilidade, tempos de resposta ou até mesmo se as hiperligações (*hyperlinks*) existentes na página estão corretas.

Uma outra limitação apontada pelos mesmos autores é o que designam por superespecialização (*overspecialization*), isto é, neste tipo de abordagens poderá existir uma tendência para os sistemas de recomendação proporem “mais do mesmo”, levando o sistema a fazer recomendações óbvias e demasiado similares àquelas que utilizador já conhece. Um exemplo típico apontado por Jannach, et al. (2011) é o de um sistema de recomendação de notícias que propõe um artigo de um jornal que aborda uma notícia que é já do conhecimento do utilizador. Ainda segundo os mesmos autores, um dos objetivos será introduzir alguma serendipidade, isto é, a faculdade de descobrir coisas agradáveis por acaso, na lista de recomendação, incluindo itens não esperados de modo a disponibilizar ao utilizador itens em que ele possa estar interessado.

Uma terceira limitação também apontada por Balabanovic e Shoham (1997) e Jannach, et al. (2011), refere-se às dificuldades relacionadas com a inércia dos utilizadores em manifestar a sua opinião de forma explícita, pelo que se deve minimizar o tempo gasto pelo utilizador na classificação de um item. Esta minimização do tempo gasto pelo utilizador colide, no entanto, com a necessidade de um maior número de atributos para assegurar melhores resultados, uma vez que em abordagens baseadas exclusivamente em conteúdo são apenas as opiniões dos utilizadores que influenciam as recomendações. Como referem Rashid, et al. (2002), exigir demasiado esforço ao utilizador pode levar a que alguns deles desistam, mas não questionar os utilizadores com o número adequado de questões levará à produção de recomendações de baixa qualidade.

2.2.2.2. *Abordagens colaborativas*

A ideia básica subjacente a este tipo de sistemas é a de que se os utilizadores partilharam os mesmos interesses no passado, então também terão interesses similares no futuro (Jannach, et al., 2011). Este tipo de abordagem explora a informação acerca do comportamento ou das opiniões passadas dos utilizadores de uma determinada comunidade, no sentido de prever em que itens um determinado utilizador estará interessado.

Dado que a seleção de itens de interesse para o utilizador envolve a filtragem dos itens mais adequados de entre um conjunto mais alargado, e porque, implicitamente, os utilizadores colaboram entre si para produzir essa lista de itens mais adequados, este tipo de abordagem é também conhecida por filtragem colaborativa (Jannach, et al., 2011). O sistema *Tapestry* (Goldberg, et al., 1992) foi um dos primeiros sistemas de recomendação, e foi concebido e construído para suportar filtragem colaborativa, definindo os autores o conceito de filtragem colaborativa em função do facto de se estar perante pessoas que, ao classificarem os itens a que acedem, colaboram entre si na produção de uma lista de itens adequadas a cada uma delas.

As abordagens colaborativas puras não necessitam de conhecer, nem exploram, as características dos itens e têm como entrada uma matriz com as classificações dos itens atribuídas pelos utilizadores (Jannach, et al., 2011), tendo como propósito produzir dois tipos de saída:

- Uma previsão numérica, indicativa do grau de apreciação do utilizador por um dado item.
- Uma lista de n itens recomendados.

Segundo Herlocker, et al. (1999), a filtragem colaborativa oferece três vantagens adicionais relativamente à filtragem baseada em conteúdo:

- i. Permite a filtragem de itens cujo conteúdo não é de fácil análise através de processos automatizados. Os utilizadores são capazes de manifestar as suas preferências quanto à relevância ou qualidade, mesmo acerca de itens de difícil análise por parte de computadores.
- ii. Permite a filtragem de itens em função da qualidade e gosto. Com a filtragem colaborativa o utilizador pode emitir a sua opinião sobre atributos e características que estão além do que é possível obter apenas com base no conteúdo do item.

- iii. Permite serendipidade nas recomendações. Os sistemas baseados em filtragem colaborativa têm a faculdade recomendar aos utilizadores itens valorizados pelos utilizadores, mas cujo conteúdo ele não está à espera.

Apesar dos sistemas baseados em filtragem colaborativa serem capazes de proporcionar aos utilizadores recomendações que vão ao encontro dos seus interesses e preferências, não são as mais adequadas quando os utilizadores procuram um conteúdo específico de informação, sugerindo Herlocker, et al. (1999) uma combinação com abordagens baseadas em conteúdo.

2.2.2.2.1. *Limitações*

Os sistemas baseados em filtragem colaborativa também têm as suas limitações, Papagelis, et al. (2005), Jannach, et al (2011) e Guo (2012), dão particular ênfase a dois tipos de problemas que podem limitar o desempenho deste tipo de sistemas: problemas com dados esparsos (*Data sparsity problem*), e problemas com o arranque do sistema (*Cold-start problem*).

As limitações relacionadas com dados esparsos decorrem do facto de em geral os utilizadores apenas manifestarem a sua preferência para um número limitado de itens, levando a que os dados sobre os quais o sistema se baseia possam ser insuficientes e originar recomendações de menor qualidade.

Os problemas com o arranque do sistema referem-se às dificuldades do sistema lidar com novos utilizadores ou novos itens. Para que o sistema possa apresentar recomendações úteis a um utilizador, este tem de avaliar um número suficiente de itens, de modo a que o sistema entenda as suas preferências, o que não acontece para novos utilizadores. O sistema só está apto a recomendar um item após este ter sido avaliado positivamente por um número substancial de utilizadores, o que não acontece com os novos itens.

Para ultrapassar os problemas que se colocam com novos utilizadores ou novos itens, usam-se habitualmente sistemas de recomendação baseados em abordagens híbridas (Adomavicius & Tuzhilin, 2005), que combinam técnicas baseadas em conteúdo com as baseadas em filtragem colaborativa. Os mesmos autores referem a existência de abordagens alternativas, designadamente as apresentadas por Rashid, et al. (2002) e Yu, et al. (2004).

Rashid, et al. (2002) apresentam um conjunto de estratégias para lidar com o problema da apresentação de recomendações nos casos de novos utilizadores ou novos itens. Uma das estratégias propostas tem por base a seleção aleatória de itens, através da qual são apresentados aos utilizadores uma seleção aleatória de itens de entre os que têm uma

probabilidade uniforme. Outra estratégia sugerida por Rashid, et al. (2002) passa pela recomendação dos itens mais populares aos utilizadores. O recurso a abordagens baseadas na entropia¹ dos itens, calculada com base na frequência relativa de cada uma das possíveis classificações atribuíveis (numa escala de 1 a 5), é outra das estratégias propostas pelos mesmos autores. Rashid, et al. (2002) fazem também referência a estratégias personalizadas baseadas nos itens, em que até que o utilizador emita uma opinião sobre pelo menos um item, lhe são apresentados itens usando outra estratégia como, por exemplo, seleção aleatória, sendo-lhe depois recomendados itens similares.

Já Yu, et al. (2004), apresentam uma solução que designam por filtragem colaborativa probabilística baseada em memória (*probabilistic memory-based collaborative filtering – PMCF*), em que é usada a entropia da similaridade de opiniões (*entropy of like-mindedness*) como base para uma aprendizagem ativa dos perfis dos utilizadores, que proporciona uma solução para o problema do novo utilizador, sendo de referir que, da primeira vez, são apresentados ao novo utilizador os itens mais populares.

Quanto aos problemas resultantes dos dados esparsos, Papagelis, et al. (2005) referem que as abordagens mais populares propostas incluem a redução da dimensionalidade da matriz utilizador-item, a aplicação de técnicas de recuperação associativa aplicadas ao grafo bipartido de itens e utilizadores, a utilização da similaridade entre itens em vez da similaridade entre utilizadores, e uma abordagem híbrida, baseada em filtragem colaborativa potenciada com conteúdo. Adomavicius e Tuzhilin (2005) apresentam uma solução que usa dados do perfil do utilizador para calcular a similaridade entre utilizadores, isto é, considera-se que dois utilizadores são similares, não só apenas se classificaram os mesmos itens de forma similar, mas também se pertencem ao mesmo segmento demográfico. Pazzani (1999) chama a este tipo de abordagem filtragem demográfica e na solução que apresenta usa dados como o género, a idade, o código postal, as habilitações literárias e a profissão para caracterizar os segmentos demográficos dos utilizadores. Outra abordagem é a proposta por Huang, et al. (2004), que também explora a similaridade entre utilizadores, aplicando uma ferramenta de recuperação associativa e algoritmos de propagação de ativação (*spreading activation algorithms*) para explorar associações transitivas entre os consumidores, com base no *feedback* e transações passadas. Tais associações transitivas são uma valiosa fonte de informação para ajudar a inferir as preferências e interesses dos utilizadores. Autores como Papagelis, et al. (2005) e Guo (2012) usam inferências de confiança (*trust inferences*) para

¹Entropia em teoria de informação é uma medida da incerteza associada a uma variável aleatória.

inferir associações entre utilizadores que não seriam possíveis através da filtragem colaborativa clássica. Exemplificando: considere-se que os utilizadores U1 e U2 opinaram sobre os itens I1 e I2 e que o utilizador U3 opinou sobre I2. A filtragem colaborativa clássica associa U1 com U2 e U2 com U3, devido aos itens I1 e I2, no entanto, não é detetada associação entre U1 e U3. Com a abordagem proposta é inferida uma associação entre U1 e U3 por intermédio de U2.

2.2.2.2.2. *Recomendação baseada em utilizadores e baseada em itens*

Podem distinguir-se dois tipos de abordagens colaborativas consoante a recomendação tenha por base os utilizadores ou os itens.

No caso da recomendação baseada em utilizadores (*user-based recommendation*), o que está em causa é a semelhança entre utilizadores, isto é, a um dado utilizador são recomendados itens preferidos por utilizadores com preferências similares às suas. Num sítio Web serão recomendadas páginas preferidas por utilizadores com preferências similares às do utilizador ativo, isto é, “utilizadores com gostos similares aos do utilizador ativo também gostaram destas páginas que se recomendam”. Para calcular a similaridade entre dois utilizadores a e b pode usar-se o *Coefficiente de correlação de Pearson*, dado pela expressão:

$$sim(a, b) = \frac{\sum_{p \in P} (r_{a,p} - \bar{r}_a)(r_{b,p} - \bar{r}_b)}{\sqrt{\sum_{p \in P} (r_{a,p} - \bar{r}_a)^2} \sqrt{\sum_{p \in P} (r_{b,p} - \bar{r}_b)^2}} \quad (1)$$

Apesar de existirem outras métricas para determinar a similaridade entres utilizadores, o *Coefficiente de correlação de Pearson* é o que apresenta melhores resultados (Jannach, et al., 2011).

No caso da recomendação baseada em itens (*item-based recommendation*), são recomendados itens que, relativamente ao item ativo, tenham obtido preferências similares por parte dos utilizadores. Exemplificando, para o caso de um sítio Web, serão recomendadas páginas que tenham merecido preferências similares à página corrente por parte dos utilizadores, ou seja “quem gostou desta página também gostou destas que se recomendam”. A medida mais comumente usada para calcular a similaridade entre dois itens a e b é a *Similaridade de Cosseno* (*cosine similarity*) (Jannach, et al., 2011), que é dada pela expressão:

$$sim(\vec{a}, \vec{b}) = \frac{\vec{a} \cdot \vec{b}}{|\vec{a}| * |\vec{b}|} \quad (2)$$

Uma forma de tornar aplicáveis em sítios Web de comércio eletrónico de grande dimensão os algoritmos de recomendação baseados em itens, sem sacrificar a precisão das recomendações, é ter por base um pré-processamento de dados. A ideia é construir em avanço, *offline*, a matriz de similaridade dos itens que descreva a similaridade entre cada par de itens para todo o catálogo. Em tempo real é calculada uma previsão para o produto p e utilizador u , através da determinação dos itens que são mais similares. O número de vizinhos a ter em consideração é limitado ao número de itens para os quais o utilizador atribuiu uma classificação.

A Amazon.com usa uma técnica que denomina de filtragem colaborativa item-item (*item-to-item collaborative filtering*) que em vez de comparar o utilizador com clientes similares, compara cada item, com itens similares, combinando-os numa lista de recomendações a apresentar a utilizador. Para determinar os itens mais similares a um dado item, o sistema constrói uma tabela de itens similares que costumam ser comprados em conjunto. Essa tabela de itens similares é construída *offline*, de modo a assegurar a escalabilidade e desempenho da solução (Linden, et al., 2003).

2.2.2.2.3. *Escalabilidade e qualidade das recomendações*

Apesar do sucesso da aplicação de técnicas e algoritmos de filtragem colaborativa em sistemas de recomendação, Sarwar, et al. (2001) alertam para a necessidade de superar dois desafios que ainda se colocam aos sistemas de recomendação baseados em filtragem colaborativa: melhorar a escalabilidade dos algoritmos e melhorar a qualidade das recomendações apresentadas aos utilizadores.

Relativamente ao primeiro desses desafios, decorre do facto de o crescimento exponencial da Web, em termos de volume de informação disponível nos sítio Web e em número de visitantes, exigir dos algoritmos desempenhos para os quais não estão preparados, pois, como os mesmos referem, tais algoritmos terão de operar sobre dezenas de milhões, em vez de dezenas de milhares, de potenciais utilizadores, tornando-os mais lentos. Quanto ao segundo desafio, prende-se com o desejo óbvio de os utilizadores exigirem recomendações em que possam confiar para os ajudar a obter a informação que procuram, recusando-se a usar sistemas de recomendação que não lhes ofereçam recomendações confiáveis (Sarwar, et al., 2001).

Porque melhorar a escalabilidade dos algoritmos e melhorar a qualidade das recomendações podem parecer, como referem Sarwar, et al. (2001), desafios contraditórios, pois quanto menor o tempo de processamento, mais escalável é o algoritmo e menor será a qualidade das recomendações geradas, é importante olhar para os dois desafios em conjunto de modo a obterem-se soluções práticas e úteis.

Para os autores, o ponto de estrangulamento dos algoritmos de filtragem colaborativa baseados em utilizadores existe quando se está perante uma pesquisa de potenciais utilizadores similares numa base alargada de utilizadores. No seu trabalho, concluem que uma solução baseada em algoritmos de filtragem colaborativa baseada em itens não só permite desbloquear esse ponto de estrangulamento como é capaz de responder de forma positiva aos dois desafios atrás mencionados. Nos testes efetuados, a solução baseada em itens produziu recomendações de melhor qualidade que as baseadas nos utilizadores, e o facto o número de itens ser relativamente estático, quando comparado com o número de utilizadores, permite que os sistemas baseados em itens sejam mais escaláveis que os baseados em utilizadores, mantendo, ainda assim, elevado desempenho.

Uma outra solução para lidar com o problema da escalabilidade em sistemas de recomendação baseados em utilizadores é a que propõem Papagelis, et al. (2005), que apresentam um modelo incremental que atualiza de forma incremental a matriz de similaridade dos utilizadores.

2.2.2.2.4. *Algoritmos baseados em memória e baseados em modelos*

De acordo com Breese, et al. (1998) e Jannach, et al. (2011) as técnicas e algoritmos usados em abordagens colaborativas são frequentemente classificados em:

- Algoritmos baseados em memória (*memory-based*), que produzem as recomendações baseando-se na base de dados com as classificações atribuídas pelos utilizadores. Na literatura, este tipo de algoritmos também são referenciados como baseados em heurísticas (*heuristic based*) (Adomavicius & Tuzhilin, 2005);
- Algoritmos baseados em modelos (*model-based*), que usam os dados das classificações atribuídas pelos utilizadores para construir um modelo, que é depois usado para produzir as recomendações.

Como refere Morais (2013) os algoritmos baseados em memória podem ser baseados em utilizadores ou em itens, consoante se trate de determinar a semelhança entre utilizadores ou entre itens.

2.2.2.3. *Abordagens híbridas*

Como se depreende da caracterização das abordagens colaborativas e baseadas em conteúdo, em cada uma delas é possível encontrar vantagens e desvantagens, dependendo do tipo de problema. Assim, poderá fazer sentido combinar diferentes técnicas como forma de obter resultados mais precisos. Existem diferentes formas de combinar técnicas colaborativas e baseadas em conteúdo num sistema de recomendação baseado numa abordagem híbrida. Adomavicius e Tuzhilin (2005) classificam essas diferentes formas do seguinte modo:

- i. implementar separadamente os algoritmos colaborativos e baseados em conteúdo, e combinar as recomendações geradas por ambos;
- ii. incorporar algumas características e técnicas das soluções baseadas em conteúdo em abordagens colaborativas;
- iii. incorporar algumas características e técnicas das soluções colaborativas em abordagens baseadas em conteúdo;
- iv. construir um modelo unificado que incorpore características e técnicas de ambos os tipos de abordagem.

Resumindo o exposto neste capítulo, os sistemas de recomendação podem classificar-se, de acordo com a abordagem de recomendação adotada, em sistemas baseados em conteúdo, colaborativos ou híbridos. Podendo também ser classificados em sistemas baseados em memória (ou heurísticas) ou em modelos, quanto às técnicas e algoritmos usados (Adomavicius & Tuzhilin, 2005).

Com base naqueles dois tipos de classificação, Adomavicius e Tuzhilin (2005) construíram a matriz apresentada na Tabela 2-1, a qual apresenta o estado da arte, à data, no que à investigação em sistemas de recomendação dizia respeito.

Tipo de Abordagem de recomendação	Técnica de recomendação	
	Baseada em memória (heurística)	Baseada em modelo
Baseada em conteúdo	<p>Técnicas comumente usadas:</p> <ul style="list-style-type: none"> • TF-IDF (<i>information retrieval</i>) • <i>Clustering</i> <p>Exemplos de investigação representativos:</p> <ul style="list-style-type: none"> • Lang 1995 • Balabanovic & Sloham 1997 • Pazzani & Billsus 1997 	<p>Técnicas comumente usadas:</p> <ul style="list-style-type: none"> • Classificadores Bayseanos • <i>Clustering</i> • Árvores de decisão • Redes neuronais artificiais <p>Exemplos de investigação representativos:</p> <ul style="list-style-type: none"> • Pazzani & Billsus 1997 • Mooney et al. 1998 • Mooney & Roy 1999 • Billsus & Pazzani 1999, 2000 • Zhang et al. 2002
Colaborativa	<p>Técnicas comumente usadas:</p> <ul style="list-style-type: none"> • Vizinho mais próximo (Correlação de cosseno) • <i>Clustering</i> • Teoria dos grafos <p>Exemplos de investigação representativos:</p> <ul style="list-style-type: none"> • Resnick et al. • Hill et al. 1998 • Shardanand & Maes 1995 • Breese et al. 1998 • Nakamura & Abe 1998 • Aggarwal et al 1999 • Delgado & Ishii 1999 • Pennock & Horwitz 1999 • Sarwar et al. 2001 	<p>Técnicas comumente usadas:</p> <ul style="list-style-type: none"> • Classificadores Bayseanos • <i>Clustering</i> • Redes neuronais artificiais • Regressão linear • Modelos probabilísticos <p>Exemplos de investigação representativos:</p> <ul style="list-style-type: none"> • Billsus & Pazzani 1998 • Breese et al. 1998 • Ungar & Foster 1998 • Chien & George 1999 • Getoor & Sahami 1999 • Pennock & Horwitz 1999 • Goldberg et al. 2001 • Kumar et al. 2001 • Pavlov & Pennock 2002 • Shani et al. 2002 • Yu et al. 2002, 2004 • Hofman 2003, 2004 • Marlin 2003 • Si & Jin 2003
Híbrida	<p>Combinar técnicas baseadas em conteúdo usando:</p> <ul style="list-style-type: none"> • Combinação linear de classificações previstas • Esquemas de votação variados • Incorporação de um componente como parte da heurística de outro. <p>Exemplos de investigação representativos:</p> <ul style="list-style-type: none"> • Balabanovic & Sloham 1997 • Claypool et al. 1999 • Good et al. 1999 • Pazzani 1999 • Billsus & Pazzani 2000 • Tran & Cohen 2000 • Melville et al. 2002 	<p>Combinar técnicas baseadas em conteúdo através da:</p> <ul style="list-style-type: none"> • Incorporação de um componente como parte da heurística de outro. • Construção de um modelo unificado <p>Exemplos de investigação representativos:</p> <ul style="list-style-type: none"> • Basu et al. 1998 • Condliff et al. 1999 • Soboroff & Nicholas 1999 • Popescul et al. 2001 • Schein et al. 2002

Tabela 2-1 – Investigação em sistemas de recomendação (estado da arte)

3. Sistema de Recomendação Web AMAAFWA

O sistema de recomendação Web AMAAFWA (Morais, 2013; Moraes, et al., 2012) é um sistema de recomendação multiagente (*Multi-Agent Recommender System*), em que agentes inteligentes autónomos, implementando diferentes técnicas e algoritmos de recomendação, competem entre si para proporcionar as melhores recomendações aos visitantes de um sítio Web.

Na Figura 3-1 apresenta-se a arquitetura global da solução de recomendação Web assente no sistema de recomendação multiagente AMAAFWA (Morais, 2009; Moraes, et al., 2012; Moraes, 2013).

Como já se referiu, os sistemas de recomendação Web são uma das soluções usadas para adaptação da Web, tendo como objetivo proporcionar aos utilizadores um conjunto de informação mais precisa e consentânea com os seus interesses. Já vimos também que, de acordo com Wei, et al. (2005), uma recomendação pode ser vista como uma referência para um item (uma página web por exemplo) que é direcionada para o utilizador que procura a informação.

Assim, socorrendo-nos da Figura 3-1, descreve-se de seguida a solução de recomendação concebida por Moraes no âmbito da sua tese de doutoramento (Moraes, 2013).

Ao aceder a qualquer página do sítio Web onde o sistema de recomendação se insere é gerado, de forma automática, um pedido ao sistema de recomendação. Esse pedido, que designamos por pedido de recomendação, é gerado pelo *browser* do utilizador e tem por base

três parâmetros: a identificação do utilizador, a página do sítio Web que está a ser acedida e a data e hora a que ocorre o acesso. O pedido de recomendação é enviado ao sistema de recomendação que internamente o distribui pelos diferentes agentes de recomendação. No caso em estudo são três os agentes de recomendação: um agente que produz recomendações baseadas em regras associativas; outro agente que produz as suas recomendações baseadas em filtragem colaborativa e um terceiro agente que recomenda as páginas mais populares do sítio Web. Cada um desses agentes de recomendação produz o seu conjunto de recomendações, determinando o sistema de recomendação qual o melhor desses conjuntos, enviando-o de seguida ao utilizador.

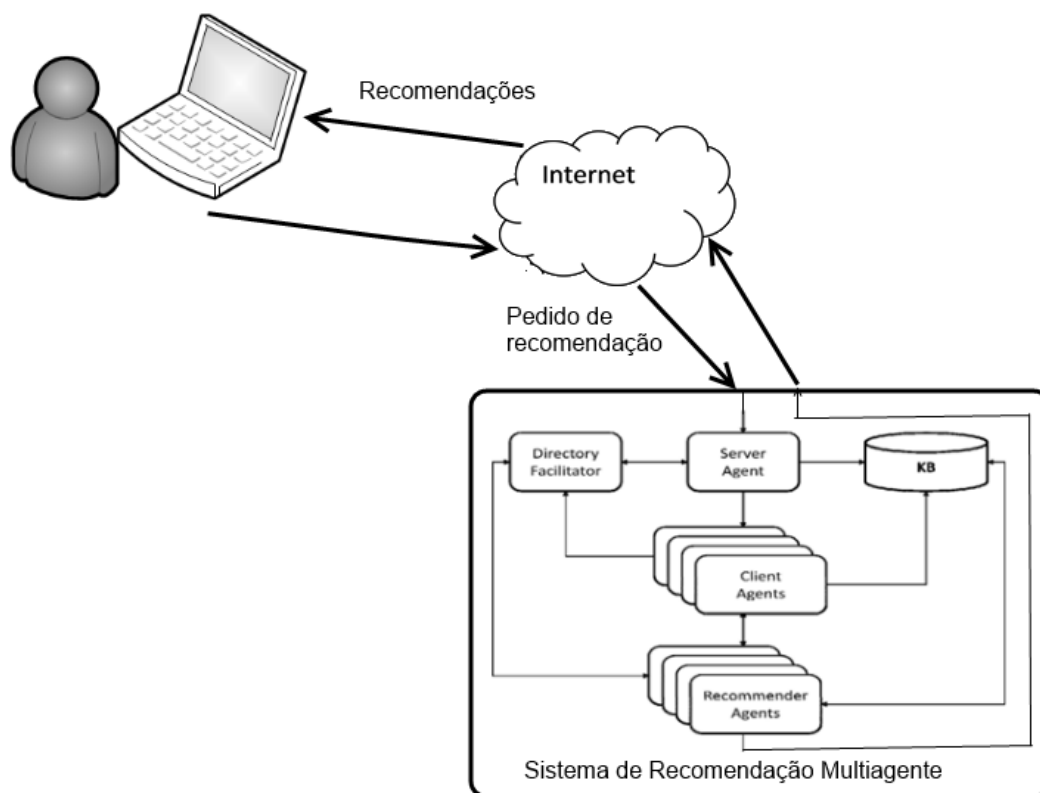


Figura 3-1 – Arquitetura global da solução de recomendação Web AMAAFWA

O conjunto de recomendações é apresentado ao utilizador em área da página Web especificamente definida para o efeito, conforme se apresenta na Figura 3-2.

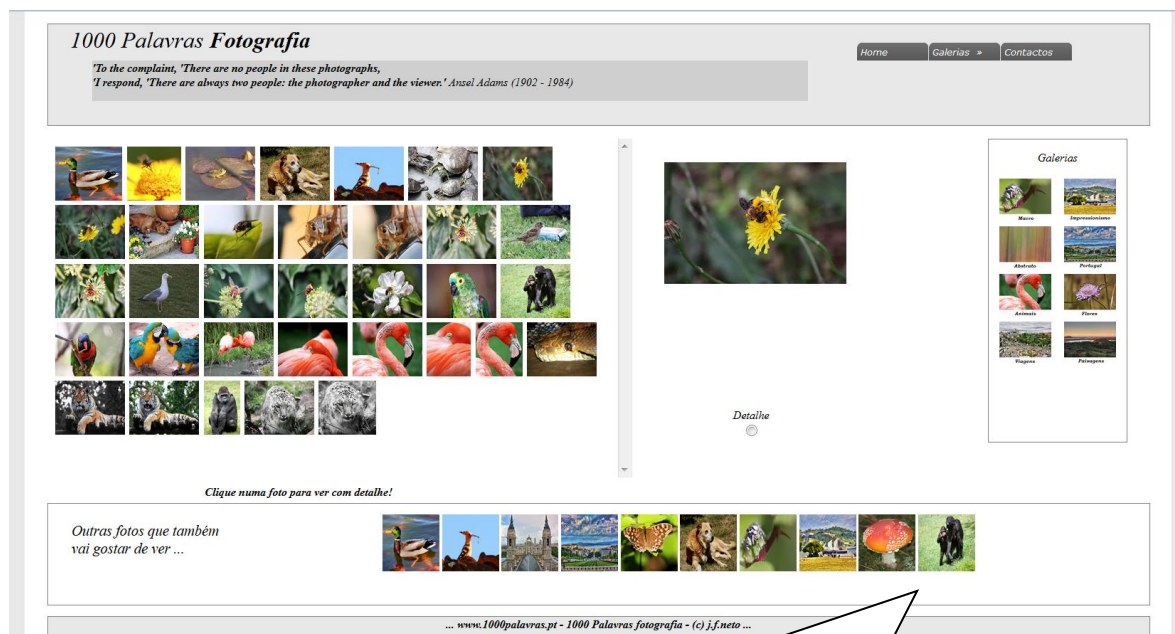


Figura 3-2 – Página Web com o conjunto de recomendações apresentadas ao utilizador

Nas secções seguintes descreve-se a solução e o sistema de recomendação AMAAFWA de forma detalhada.

3.1 Formulação teórica do sistema de recomendação

Nesta secção começamos por apresentar o conceito de sítio Web, tendo em vista a sua integração com o sistema de recomendação Web. De seguida far-se-á a formalização teórica do sistema de recomendação, concluindo-se com a introdução das métricas de avaliação de desempenho usadas neste tipo de sistemas.

3.1.1 Formalização de um sítio Web

Segundo Morais (2013), um sítio Web pode ser representado da seguinte forma:

$$WS = \langle WP, H \rangle \quad (3)$$

Onde WS é o sítio Web, WP é o conjunto de páginas Web desse sítio Web e H é o conjunto de hiperligações existentes em WP, podendo H ser expresso na forma:

$$H = \{(p, q) | p, q \in WP\} \quad (4)$$

Onde p e q são páginas Web.

No âmbito do trabalho em estudo, p e q são páginas Web locais do sítio Web WP, pelo que apenas se consideram o conjunto de hiperligações locais.

Sempre que é requisitado o acesso a uma página de um sítio Web, a correspondente informação de acesso é registada em ficheiros de log do servidor Web ou numa base de dados. Para o sistema de recomendação, a informação relevante é a que se refere a qual página Web acedida, quem acedeu e quando foi feito o acesso. Esses parâmetros, visitante, página Web acedida e data e hora do acesso, formam o que se pode definir por pedido do utilizador e pode representar-se na forma:

$$request = (uid, pid, reqtime) \quad (5)$$

Onde uid identifica o utilizador, pid é a página Web e $reqtime$ se refere à data e à hora do pedido.

Ao invés de obter aqueles dados procurando-os nos *logs* do servidor Web, onde é registada muito mais informação do que apenas esses três parâmetros, é preferível guardar essa informação numa base de dados específica, de modo a que apenas seja necessário lidar com esses três parâmetros.

Assim, para efeitos do sistema de recomendação, cada acesso de um utilizador/visitante a uma página do sítio Web, originará um pedido com os referidos parâmetros. No entanto, esta informação apenas disponibiliza um conjunto de pedidos isolados, pelo que é de todo o interesse agrupar os pedidos por sessões.

Considera-se sessão, a atividade desenvolvida por um utilizador durante o acesso a um sítio Web para satisfazer as suas necessidades, seja para procurar informação útil, para procurar um determinado assunto ou apenas para descobrir que tipo de assuntos o sítio Web aborda

(Morais, 2013). Para Cooley, et al. (1999) sessão é o conjunto de todas as páginas Web acessadas por um utilizador durante uma visita a um sítio Web.

Se o início da sessão é fácil de determinar, pois ocorre aquando do início da visita ao sítio Web, já o fim da sessão é mais difícil de identificar, pois um utilizador pode permanecer, por variadas razões, com uma página ativa por longos períodos de tempo. Para o sistema de recomendação AMAAFWA, Morais (2013), seguindo Cooley, et al. (1999), considera que o fim de sessão ocorre quando o utilizador não faz nenhum pedido ao sítio Web por um período de 30 minutos.

Segundo Morais (2013), os dados de acesso referidos ($uid, pid, reqtime$) podem ser vistos de dois modos diferentes.

Por um lado, pode considerar-se o conjunto de acessos a páginas durante uma sessão, como um percurso feito pelo utilizador durante a sua visita ao sítio Web, podendo formalizar-se da seguinte forma:

$$S_i = [p_{i1}, p_{i2}, \dots, p_{i|S_i|}] \quad (6)$$

Onde S_i é uma sessão i , p_{ij} é a j -ésima página visitada durante a sessão i , e $|S_i|$ é o número de pedidos durante a sessão.

Por outro lado, à parte a ordem dos elementos, uma sessão pode ser tratada como uma função binária (Morais, 2013) s_i , tal que:

$$s_i : WP \rightarrow \{0,1\} \quad (7)$$

Onde s_i é a função binária associada à sessão i , WP é o conjunto de páginas Web e a função tomará o valor 1 se uma página for visitada e 0 caso contrário. Pelo que uma sessão S_i , sendo o conjunto de páginas visitadas, pode ser representada na forma (Morais, 2013):

$$S_i = \{p \in WP \mid s_i(p) = 1\} \quad (8)$$

Assim, com a definição de sessão aqui apresentada podemos estender a expressão (5) da seguinte forma (Morais, 2013):

$$Req = (reqid, sessionid, subsid, uid, pid, reqtime) \quad (9)$$

Onde *reqid* é o número de identificação do pedido, *sessionid* é o número de identificação da sessão, *subsid* é o número de ordem do pedido dentro da sessão e *uid, pid, reqtime* têm o mesmo significado que o já anteriormente referido.

3.1.2 Formalização do sistema de recomendação

Um sistema de recomendação pode ser formalizado como uma função que, a um pedido *Req*, mapeia um conjunto de recomendações ordenadas, podendo representar-se na forma (Morais, 2013):

$$Rec_M : Req \rightarrow WP^n \quad (10)$$

Onde Rec_M é uma função baseada no modelo M que, para cada pedido *Req*, origina um conjunto de n páginas Web.

No sistema de recomendação AMAAFWA as recomendações são disponibilizadas por um modelo incremental baseado em itens, classificados pelos utilizadores através de uma classificação binária (Miranda & Jorge, 2008).

Já se fez referência que a escalabilidade é uma das limitações dos sistemas de recomendação baseados em filtragem colaborativa que assentam em abordagens baseadas em utilizadores. Para ultrapassar essa limitação pode recorrer-se, como também referimos, a soluções de filtragem colaborativa baseadas em itens (Sarwar, et al., 2001) ou baseadas em modelos de filtragem colaborativa incrementais (Papagelis, et al., 2005).

Pegando nas soluções apresentadas por Sarwar, et al. (2001) e Papagelis, et al. (2005), Miranda e Jorge (2008) apresentam uma abordagem baseada num modelo incremental aplicado a uma solução de filtragem colaborativa baseada em itens. Segundo os autores, a solução proposta beneficia não só das vantagens computacionais associadas às soluções baseadas em itens, mas também dos benefícios do modelo incremental, pelo facto da matriz de similaridade de itens ser atualizada no final de cada sessão, assegurando-se que no momento de produção de recomendações a matriz tem refletida todos os dados das sessões passadas, o que não acontece numa solução tradicional não incremental.

No seu trabalho, Miranda e Jorge (2008) consideram que as classificações binárias para os itens são obtidas de forma implícita. No sistema de recomendação AMAAFWA (Morais, 2013) também é usada classificação binária dos itens obtida de forma implícita, em resultado do comportamento do utilizador, pelo que, de acordo com a função formalizada na expressão (7), esta tomará o valor 1 ou 0 consoante determinada página Web for ou não visitada.

Como refere Moraes (2013), um modelo incremental é gerado a partir de um conjunto de dados que é atualizado no final de cada sessão e não através de um conjunto de dados fixo. Num modelo incremental, o conjunto de dados usado para gerar o conjunto de recomendações inclui todas as sessões já terminadas, isto é, quando, durante uma sessão S_i , um utilizador faz um pedido de acesso a uma página Web, as recomendações geradas são baseadas na informação resultante de cada sessão terminada, pelo que, como poderão coexistir várias sessões simultaneamente, o número de sessões em que se baseiam as recomendações pode variar para uma mesma sessão de um utilizador.

Como refere Moraes (2013), o objetivo fundamental de um sistema de recomendação é maximizar a satisfação do utilizador, providenciando recomendações que lhe sejam úteis. De cada vez que o sistema de recomendação gera um conjunto de recomendações, uma das situações seguintes poderá ocorrer (Morais, 2013):

- a. Nenhuma página é seguida, porque a sessão expirou.
- b. O conjunto de recomendações gerado é vazio.
- c. É seguida uma página que não faz parte do conjunto de recomendações.
- d. Uma das páginas recomendadas foi seguida.

Para a análise da performance do sistema de recomendação não vamos considerar os casos em que nenhuma página é seguida pelo facto de a sessão ter expirado, pois, tendo o utilizador abandonado o sítio Web, não é possível determinar se uma das recomendações seria ou não útil.

3.1.3 Avaliação do sistema de recomendação

Para avaliar o desempenho do sistema de recomendação, consideram-se as medidas *precision* e *recall*, propostas por Cleverdon e Kean (1968), as quais, desde então, se mantêm as mais populares métricas para avaliação de sistemas de recuperação de dados (Herlocker, et al.2004). Essas métricas têm também sido usadas na avaliação de sistemas de recomendação,

podendo, no caso do sistema de recomendação AMAAFWA, ser definidas do seguinte modo (Morais, 2013):

- *Recall* – é o rácio entre o número de páginas recomendadas que foram seguidas e o número total de páginas visitadas e é obtido pela expressão:

$$Recall = \frac{\#d}{\#b+\#c+\#d} \quad (11)$$

- *Precision* - é o rácio entre número de páginas recomendadas que foram seguidas e o número total de páginas recomendadas:

$$Precision = \frac{1}{N} x \frac{\#d}{\#b+\#c+\#d} = \frac{1}{N} x Recall \quad (12)$$

Onde N é o número de recomendações geradas pelo sistema a cada pedido e $\#b$, $\#c$ e $\#d$ representam as situações atrás descritas, a saber:

- $\#b$ é o número de vezes que o sistema de recomendação gerou um conjunto de recomendações vazio;
- $\#c$ é o número de vezes que é seguida uma página que não faz parte do conjunto de recomendações;
- $\#d$ é o número de vezes que uma das páginas recomendadas foi seguida.

Vamos considerar também a medida *F1-score*, que combina as medidas *recall* e *precision*, no que se pode interpretar como uma média ponderada daquelas duas medidas, através da expressão:

$$F1 = \frac{2 x Precision x Recall}{Precision+Recall} \quad (13)$$

No caso do sistema de recomendação em estudo, como

$$Precision = \frac{1}{N} x Recall \quad (14)$$

Então:

$$F1 = \frac{2 x Recall}{N+1} \quad (15)$$

3.2 Arquitetura do sistema multiagente

Nesta secção descreve-se detalhadamente o sistema de recomendação multiagente Web AMAAFWA.

O sistema multiagente foi concebido tendo em consideração as duas diretivas seguintes (Morais, 2013):

- Os agentes devem responder rapidamente a qualquer pedido de outro agente e preparar-se imediatamente para responder ao pedido seguinte.
- Tarefas mais demoradas, como a atualização do modelo, não devem interferir com o desempenho do sistema.

Aquelas duas diretivas assentam no pressuposto de que o sistema multiagente deve responder de forma rápida a um pedido de recomendações.

Na Figura 3-3 apresenta-se a arquitetura do sistema de recomendação multiagente AMAAFWA (Morais, 2009; Morais, et al., 2012; Morais, 2013).

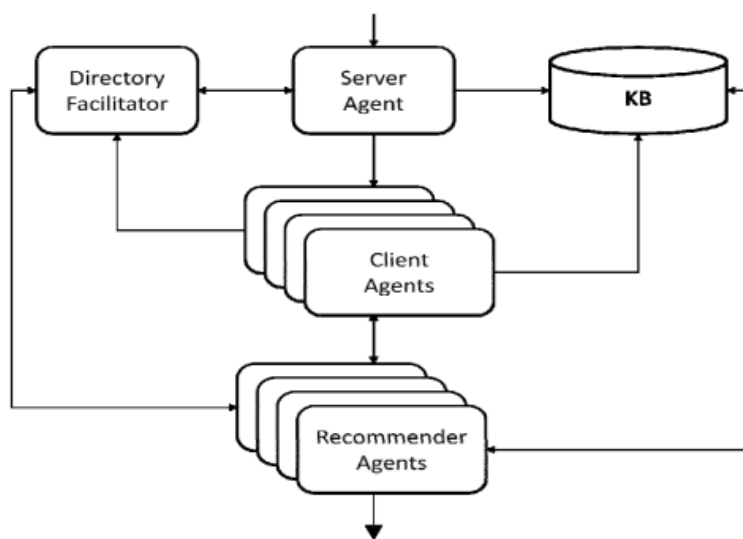


Figura 3-3 – Arquitetura do sistema multiagente

3.2.1 Caraterização dos agentes

O sistema é constituído por três tipos de agentes: agente servidor (*server agent*), agentes clientes (*client agents*) e agentes de recomendação (*recommender agents*), interagindo entre si como se apresenta na Figura 3-3.

Além dos três tipos de agente, apresentam-se também na Figura 3-3 o *Directory Facilitator* (DF) e a *Knowledge Base* (KB).

O *Directory Facilitator* é um agente implementado pela plataforma *JADE* (<http://jade.tilab.com/>) conforme especificado pela *FIPA* (<http://www.fipa.org/>) e pode comparar-se a um serviço de páginas amarelas. Os agentes que desejam anunciar os seus serviços têm de se registar no DF. Os agentes que procuram serviços questionam o DF sobre agentes que os providenciem. No caso do sistema de recomendação em estudo, o uso do DF é muito importante por duas razões (Morais, 2013):

- Ao fazerem e cancelarem o seu registo no DF, os agentes clientes conseguem separar as sessões para um mesmo utilizador, facilitando o agente servidor na tarefa de determinar se, para o utilizador a que corresponde o pedido que lhe chega, é necessário criar ou não um novo agente cliente.
- O registo dos agentes de recomendação no DF permite que, a todo o tempo, um agente possa ser destruído ou criado um novo. Deste modo, o sistema multiagente de recomendação pode alterar os algoritmos de recomendação de forma dinâmica, sem necessidade de ser reinicializado.

A *Knowledge Base* é onde são registados todos os dados necessários ao funcionamento do sistema. Moraes (2013) chama-lhe *Knowledge Base* em vez de *Database* porque os dados podem também estar em memória ou em outro qualquer suporte.

3.2.1.1 Agente servidor (server agent)

O agente servidor tem o papel de agente de controlo do sistema, recebe mensagens (pedidos) dos clientes (utilizadores), criando ou contactando os agentes clientes através de passagem de mensagens.

Como consequência do facto de, num dado instante, um utilizador carregar uma página do sítio Web em que o sistema de recomendação se insere, o agente servidor recebe uma mensagem do sítio Web. Recuperando o que já se referiu aquando da formalização de um

sítio Web, essa mensagem, composta pelo identificador do utilizador, pelo identificador da página Web e pelas data e hora em que o utilizador acede à página, tem forma:

(uid,pid,reqtime)

Sempre que recebe um pedido, o agente servidor verifica se já existe o agente cliente que representa aquele utilizador através de pesquisa no DF. Existindo, encaminha-lhe a mensagem recebida, caso contrário cria o agente cliente e passa-lhe a mensagem.

3.2.1.2 Agente cliente (*client agent*)

O agente cliente representa o utilizador no sistema multiagente. A cada utilizador é atribuído um agente cliente, que existe enquanto durar a sessão do utilizador. Quando é criado, o agente cliente regista-se no DF. As principais funções do agente cliente são (Morais, 2013):

- Receber pedidos do agente servidor e reencaminhá-los para os agentes de recomendação.
- Gerir os leilões.
- Determinar o fim de sessão.
- Atualizar a matriz de similaridade dos itens no final da sessão.

Ao receber a mensagem do agente servidor, o agente cliente envia-a para os agentes de recomendação e aguarda pelas propostas destes. Uma vez recebidas as propostas, o agente cliente determina qual o agente de recomendação vencedor e informa-o, bem como aos restantes agentes de recomendação. Enquanto aguarda por pedidos, o agente cliente controla o tempo desde o último pedido de modo a determinar o fim de sessão, o que acontece quando passam 30 minutos sem receber pedidos. Após determinar o fim de sessão, o agente cliente apaga o seu registo no DF e atualiza a matriz de similaridade de itens com a coocorrência de itens da sessão, destruindo-se de seguida.

3.2.1.3 Agente de recomendação (*recommender agent*)

Os agentes de recomendação têm as seguintes funções (Morais, 2013):

- Fazer licitações sempre que recebem um pedido.
- Preparar o conjunto de recomendação enquanto aguardam pelo resultado do leilão.
- Enviar as recomendações ao utilizador, se é o vencedor do leilão.
- Registrar as recomendações na KB.

Quando são criados, os agentes de recomendação registam-se a si próprios no DF e aguardam por pedidos dos agentes clientes. Quando recebem um pedido, estes agentes determinam o valor da sua licitação com base na precisão das recomendações passadas para o mesmo item, enviando a proposta ao agente cliente que lhe fez o pedido. Se for vencedor do leilão, as suas recomendações serão enviadas ao utilizador. Quer vença ou não o leilão, o agente regista as recomendações na KB.

Pode dizer-se que os agentes de recomendação são cooperativos, pois baseiam as suas propostas na satisfação dos utilizadores e não no seu próprio interesse, partilhando os dados necessários à produção das recomendações (Neto & Morais, 2014).

3.2.2 Detalhes de implementação

O sistema multiagente foi implementado em Java, com base na plataforma JADE (<http://jade.tilab.com>). A comunicação com o sítio Web é feita usando AJAX (<https://developer.mozilla.org/en-US/docs/AJAX>), de acordo com Figura 3-4.

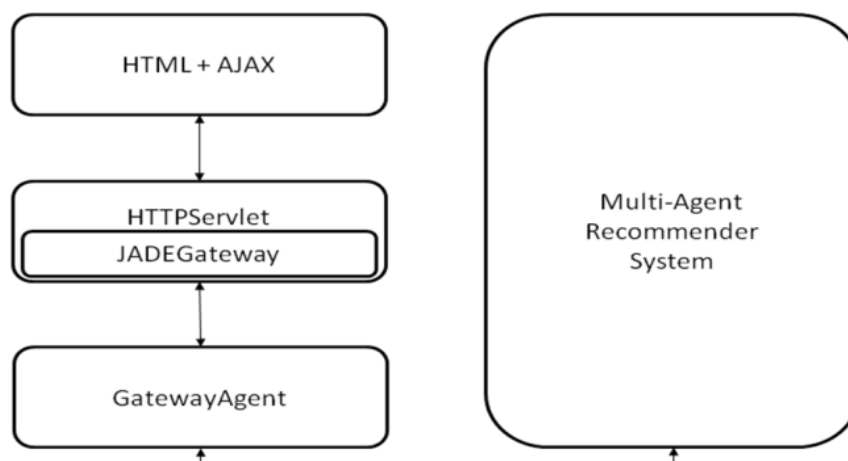


Figura 3-4 – Arquitetura do sistema de recomendação

Na solução desenvolvida e testada por Morais (Morais, 2013) as páginas Web foram escritas em HTML e para a comunicação entre *browser* e o sistema multiagente recorreu-se a AJAX e uma HTTP *servlet* para disponibilizar um gateway para a plataforma JADE. A *Knowledge Base* foi implementada em Apache Derby (<http://db.apache.org/derby/>). A utilização de AJAX permite que o carregamento de uma página Web se faça mesmo que exista algum atraso no envio das recomendações pelo sistema de recomendação.

3.3 Agentes de recomendação

Nas secções anteriores caracterizaram-se os diferentes tipos de agente envolvidos no sistema, descrevendo as suas funções e o modo como interagem entre si. Como ficou depreendido do exposto, podem coexistir no sistema, simultaneamente, diversos agentes cliente, cada um deles representando o seu utilizador, mas todos eles com a mesma funcionalidade. Vimos também que podem existir diversos agentes de recomendação, cada qual baseado no seu algoritmo de recomendação.

No caso do sistema AMAAFWA foram desenvolvidos três agentes de recomendação, baseados em diferentes algoritmos. Nesta secção vamos descrever com detalhe cada um desses três agentes. O primeiro deles é baseado em regras de associação (Agrawal, et al., 1993), o segundo usa um algoritmo de filtragem colaborativa (Sarwar, et al., 2001; Linden, et al., 2003) e o terceiro sugere as páginas mais visitadas (Morais, 2013).

Como refere Morais (2013), um aspeto fundamental a ter em conta em qualquer sistema de recomendação é o tempo gasto na produção e apresentação das recomendações aos utilizadores.

Também já se referiu, recorrendo a Miranda e Jorge (2008), que uma abordagem baseada num modelo incremental e baseada em itens beneficia das vantagens computacionais associadas às soluções baseadas em itens, bem como dos benefícios decorrentes do modelo incremental. Assim, todos os algoritmos desenvolvidos para o sistema AMAAFWA são baseados em memória, incrementais e baseados em itens (Morais, 2013).

Os algoritmos partilham uma matriz de coocorrências $A_{n \times n}$, onde n é o número de itens (páginas Web) e cada $a_{ij} \in A$ regista a coocorrência dos itens i e j na mesma sessão. Como já se referiu a matriz é atualizada cada vez que uma sessão termina.

3.3.1 Agente baseado em regras de associação

Uma regra de associação é uma expressão na forma $X \Rightarrow Y$, onde X e Y são conjuntos de itens, tais que $X \cap Y = \emptyset$. Os conjuntos X e Y são o antecedente e o conseqüente da regra, respetivamente.

Define-se *support count*, $\sigma(X)$, ou *coverage*, $\text{coverage}(X)$, de um conjunto de itens X , ao número de transações que contêm o conjunto de itens X .

Define-se *Suporte* de um conjunto de itens X , $Suporte(X)$, à percentagem de transações da base de dados que contêm os itens de X , pelo que:

$$s(\mathbf{X}) = \frac{coverage(\mathbf{X})}{N} \quad (16)$$

Onde N é o número total de transações.

A força de uma regra de associação pode ser medida pelo seu *suporte* e pela sua *confiança*. Sendo que o *Suporte* nos diz com que frequência a regra é aplicável a um dado conjunto de dados, ou seja, para a regra de associação $\mathbf{X} \Rightarrow \mathbf{Y}$, o *Suporte* é dado por:

$$Suporte(\mathbf{X} \Rightarrow \mathbf{Y}) = \frac{coverage(\mathbf{X} \cup \mathbf{Y})}{N} \quad (17)$$

Por outro lado, a *Confiança* diz-nos com que frequência itens de Y aparecem em transações que contêm X , ou de outro modo, de entre as transações que contêm X , a percentagem de transações que também contêm Y , isto é, para a regra de associação $\mathbf{X} \Rightarrow \mathbf{Y}$:

$$Confiança(\mathbf{X} \Rightarrow \mathbf{Y}) = \frac{Coverage(\mathbf{X} \cup \mathbf{Y})}{Coverage(\mathbf{X})} = \frac{\frac{Coverage(\mathbf{X} \cup \mathbf{Y})}{N}}{\frac{Coverage(\mathbf{X})}{N}} \quad (18)$$

Pelo que:

$$Confiança(\mathbf{X} \Rightarrow \mathbf{Y}) = \frac{Suporte(\mathbf{X} \cup \mathbf{Y})}{Suporte(\mathbf{X})} \quad (19)$$

No caso do sistema de recomendação AMAAFWA, os itens são as páginas Web, sendo registadas as escolhidas durante uma transação (uma sessão Web).

De acordo com Moraes (2013), para aplicação das regras de associação consideram-se apenas conjuntos de itens de tamanho 2, um antecedente e um conseqüente. Com essa restrição os valores do *Suporte* e da *Confiança* obtêm-se diretamente da matriz de coocorrências.

Assim, o agente verifica todas as regras de associação $p_i \rightarrow p_j$, onde p_i e p_j são duas páginas Web distintas, pelo que, seja N o número de sessões, os valores do *Suporte* e da *Confiança*, são dados por:

$$Suporte(\mathbf{i} \Rightarrow \mathbf{j}) = \frac{a_{ij}}{N} \quad (20)$$

$$Confiança(\mathbf{i} \Rightarrow \mathbf{j}) = \frac{a_{ij}}{a_{ii}} \quad (21)$$

A um pedido de um conjunto de n recomendações, o agente proporá as n melhores recomendações que satisfaçam os requisitos mínimos para os valores de *Suporte* e *Confiança*, ordenadas pelo valor da *confiança* (Morais, 2013).

3.3.2 Agente baseado em filtragem colaborativa

Vimos já que existem diferentes técnicas e métodos em que os algoritmos de filtragem colaborativa se baseiam para gerar recomendações, na Tabela 2-1 apresentam-se algumas dessas técnicas e métodos. De qualquer modo, todos esses algoritmos assentam no pressuposto de que os utilizadores classificam as páginas Web (os itens) de acordo com a sua preferência. Também já referimos que os itens podem ser classificados de forma implícita ou explícita, e que existem dois tipos de abordagem, consoante a recomendação tenha por base os utilizadores ou os itens. De acordo com Sarwar, et al. (2001), referidos por Moraes (2013), as abordagens baseadas em itens produzem recomendações de melhor qualidade e maior desempenho.

No caso do sistema AMAAFWA adotou-se uma abordagem baseada em itens com classificação binária implícita: 1 se a página Web for visitada, 0 caso contrário. Tratando-se de uma abordagem baseada em itens, já se referiu que o uso da Similaridade de Cosseno é a escolha adequada para o cálculo da similaridade entre dois itens.

Assim, considerando os itens I e J , então a Similaridade de Cosseno é dada pela expressão:

$$sim(I, J) = \frac{\vec{i} \cdot \vec{j}}{\|\vec{i}\| * \|\vec{j}\|} \quad (22)$$

De acordo com a generalidade dos métodos de filtragem colaborativa, a expressão acima permite prever as classificações para os itens, com base nos itens mais similares entre si. No caso do sistema AMAAFWA, segue-se a abordagem de Linden, et al. (2003), que propõe que o conjunto de recomendações seja constituído pelos N itens mais similares. Esta solução permite maior rapidez na geração das recomendações e não fica exposta às desvantagens da filtragem colaborativa tradicional (Linden, et al., 2003).

Considerando que o sistema AMAAFWA usa classificação binária, o cálculo da similaridade entre os itens torna-se bastante simples através da matriz de coocorrências, pois $a_{ij} = \vec{I} \cdot \vec{J}$; $a_{ii} = \|\vec{I}\|$; $a_{jj} = \|\vec{J}\|$, pelo que:

$$\text{sim}(I, J) = \frac{a_{ij}}{\sqrt{a_{ii}} \sqrt{a_{jj}}} = \frac{a_{ij}}{\sqrt{a_{ii} a_{jj}}} \quad (23)$$

Assim, sempre que recebe um pedido, o agente de recomendação gera o conjunto de recomendações de acordo com a expressão acima.

3.3.3 Agente baseado nas n páginas mais visitadas

Este agente verifica na matriz de coocorrências as n páginas mais visitadas, não tendo em consideração o item para o qual o pedido é feito. De facto, independentemente da página Web que o utilizador visitar, as recomendações geradas por este agente são as n páginas mais populares, obtendo-se por isso resultados menos precisos. Apesar disso, é bastante útil pois permite, por exemplo, completar o conjunto de recomendações dos restantes agentes, quando estes não tenham informação suficiente que lhes permita gerar as n recomendações.

3.4 Recomendações a apresentar ao utilizador

Como já se referiu, aquando da descrição do modo de funcionamento do sistema de recomendação multiagente AMAAFWA, na posse de um pedido de recomendação do seu utilizador, o agente cliente envia-o aos agentes de recomendação descritos nas secções anteriores e aguarda pelas propostas destes.

Na posse do pedido, cada agente de recomendação produz as recomendações e elabora uma proposta de licitação, que envia ao agente cliente. Na posse das propostas enviadas pelos agentes de recomendação, o agente cliente terá de decidir qual a proposta vencedora, escolhendo assim o conjunto de recomendações a apresentar ao utilizador que fez o pedido.

Para determinar qual a melhor proposta, é usada uma abordagem do tipo *market-based* através de leilão. O tipo de leilão escolhido foi o *leilão de lances fechados e primeiro preço* (*first-price sealed-bid*). Morais (2013) justifica esta escolha baseado no que considera ter de ser a característica principal do sistema multiagente: a rapidez na resposta a um pedido de recomendações.

No *leilão de lances fechados e primeiro preço* os licitadores entregam envelopes lacrados com o seu lance, apresentado cada licitante apenas uma proposta. O vencedor do leilão é o licitante que apresenta a melhor proposta, não havendo lugar a qualquer tipo de negociação.

No caso do sistema multiagente AMAAFWA as licitações dos agentes baseiam-se numa pontuação acumulada para cada item. Essa pontuação é obtida a partir das classificações anteriores, sendo as N melhores páginas ordenadas. Se a página seguida é uma das recomendadas, recebe uma pontuação $N-p+1$, onde p é a posição relativa do item. A esta pontuação adiciona-se a percentagem total, como forma de desempate, pelo que se considera a expressão (Morais, et al., 2012):

$$Bid_{agent,item} = Score_{item} + \frac{1}{\#requests * N} * \sum_{i \in Items} Score_i \quad (24)$$

Como decorre da fórmula acima, a pontuação obtida para um dada proposta tem em conta todo o histórico de classificações anteriores obtidas pelo agente. Se no curto prazo de utilização do sistema, como é o caso dos testes realizados, a estratégia parece adequada, no longo prazo, poderá haver interesse em não considerar todo o histórico e introduzir o que podemos designar por fator de esquecimento considerando apenas as classificações mais recentes. Desse modo os agentes que obtiveram más classificações no passado e que no presente estão a produzir recomendações de melhor qualidade, terão condições para verem o seu mérito reconhecido, o que pode não acontecer ao considerar-se todo o histórico. A introdução deste fator de esquecimento permitiria ainda que um novo agente de recomendação, baseado num novo algoritmo, adicionado a um sistema em funcionamento, tivesse condições ver usadas as suas recomendações, caso sejam de qualidade.

3.5 Desempenho *offline* do sistema

Para testar e avaliar o desempenho do sistema, foi utilizada por Morais (2013) uma versão *offline* do sistema para simular acessos ao sítio Web. Nessa versão do sistema os conjuntos de dados de acessos a sítios Web são lidos por um agente simulador que faz o papel do agente de porta de entrada (*gateway agent*). Cada registo do conjunto de dados contém o identificador da página Web, o identificador do utilizador e a data e hora do pedido (*uid,pid,reqtime*).

Os conjuntos de dados em que se basearam os testes estão caracterizados na Tabela 3-1.

Dataset	#items	# records	#sessions	#records/#sessions	#records/#items
e-com	335	1409	413	3.41	4.21
e-gov	133	4047	1244	3.25	30.43
PE100	100	6070	803	7.56	60.70
PE200	200	2042	200	10.21	10.21
Listener	6428	49505	9570	5.17	7.70
Playlist	5428	25641	4267	6.01	4.72

Tabela 3-1 – Caraterização dos conjuntos de dados dos testes offline

Na Tabela 3-2, adaptada de Morais (2013), apresentam-se os resultados dos testes *offline*, tendo sido considerados conjuntos de recomendações de dimensão (N), de 1 a 10. Na referida tabela apresentam-se os resultados de Recall (*R*), Precision (*P*) e *F1-Score* para os algoritmos baseados em regras associativas (*ar*) e filtragem colaborativa (*cf*), para o sistema de recomendação multiagente (*w*) e para o caso hipotético em que um dos agentes de recomendação recomenda uma página seguida pelo utilizador (*b*).

Analisando os resultados dos testes com o propósito de avaliar em que medida se conformam com a hipótese formulada por Morais (2013), segundo a qual uma abordagem multiagente baseada no mercado melhora a capacidade preditiva duma combinação de algoritmos de recomendação, verifica-se que apesar da solução multiagente proposta não ter tido sucesso em todas as situações testadas, se podem considerar positivos os resultados globais obtidos.

Na maioria dos casos, o sistema multiagente de recomendação foi capaz de recomendar itens com melhores resultados que os dos algoritmos individuais e, mesmo nos casos em que tal não aconteceu, a qualidade das recomendações geradas pelo sistema multiagente era similar à obtida pelo melhor dos algoritmos individuais (Morais, 2013).

#R	EM	1	2	3	4	5	6	7	8	9	10	
e-com	ar	R	5.22%	9.24%	11.65%	13.25%	15.46%	16.67%	17.27%	18.27%	18.78%	19.38%
		P	5.22%	4.62%	3.88%	3.31%	3.09%	2.78%	2.47%	2.28%	2.09%	1.94%
		F1	5.22%	6.16%	5.82%	5.30%	5.15%	4.76%	4.32%	4.06%	3.76%	3.52%
	cf	R	4.82%	7.83%	9.84%	10.84%	12.35%	13.25%	14.66%	15.26%	15.96%	16.47%
		P	4.82%	3.92%	3.28%	2.71%	2.47%	2.21%	2.09%	1.91%	1.77%	1.65%
		F1	4.82%	5.22%	4.92%	4.34%	4.12%	3.79%	3.66%	3.39%	3.19%	2.99%
	w	R	6.02%	10.14%	13.55%	15.36%	17.97%	19.38%	20.78%	22.09%	23.19%	24.20%
		P	6.02%	5.07%	4.52%	3.84%	3.59%	3.23%	2.97%	2.76%	2.58%	2.42%
		F1	6.02%	6.76%	6.78%	6.14%	5.99%	5.54%	5.20%	4.91%	4.64%	4.40%
b	R	9.54%	15.16%	18.57%	20.88%	23.39%	25.20%	26.51%	27.61%	29.02%	30.12%	
	P	9.54%	7.58%	6.19%	5.22%	4.68%	4.20%	3.79%	3.45%	3.22%	3.01%	
	F1	9.54%	10.11%	9.29%	8.35%	7.80%	7.20%	6.63%	6.14%	5.80%	5.48%	
e-gov	ar	R	13.20%	19.51%	24.22%	27.68%	31.18%	33.93%	36.46%	38.67%	40.35%	42.06%
		P	13.20%	9.76%	8.07%	6.92%	6.24%	5.65%	5.21%	4.83%	4.48%	4.21%
		F1	13.20%	13.01%	12.11%	11.07%	10.39%	9.69%	9.12%	8.59%	8.07%	7.65%
	cf	R	11.95%	18.27%	23.40%	27.29%	30.11%	32.36%	34.86%	36.50%	38.21%	39.56%
		P	11.95%	9.13%	7.80%	6.82%	6.02%	5.39%	4.98%	4.56%	4.25%	3.96%
		F1	11.95%	12.18%	11.70%	10.92%	10.04%	9.25%	8.71%	8.11%	7.64%	7.19%
	w	R	12.49%	19.27%	24.15%	27.79%	31.11%	33.61%	36.35%	38.35%	40.10%	41.96%
		P	12.49%	9.63%	8.05%	6.95%	6.22%	5.60%	5.19%	4.79%	4.46%	4.20%
		F1	12.49%	12.84%	12.08%	11.12%	10.37%	9.60%	9.09%	8.52%	8.02%	7.63%
b	R	18.48%	27.43%	33.43%	37.96%	41.60%	44.49%	47.27%	49.59%	51.23%	53.44%	
	P	18.48%	13.72%	11.14%	9.49%	8.32%	7.41%	6.75%	6.20%	5.69%	5.34%	
	F1	18.48%	18.29%	16.71%	15.18%	13.87%	12.71%	11.82%	11.02%	10.25%	9.72%	
PE100	ar	R	6.15%	10.14%	13.35%	16.46%	19.42%	21.95%	24.23%	26.28%	28.52%	30.43%
		P	6.15%	5.07%	4.45%	4.12%	3.88%	3.66%	3.46%	3.28%	3.17%	3.04%
		F1	6.15%	6.76%	6.67%	6.58%	6.47%	6.27%	6.06%	5.84%	5.70%	5.53%
	cf	R	7.23%	11.98%	15.63%	18.68%	20.96%	23.49%	25.78%	27.64%	29.49%	31.23%
		P	7.23%	5.99%	5.21%	4.67%	4.19%	3.91%	3.68%	3.46%	3.28%	3.12%
		F1	7.23%	7.99%	7.81%	7.47%	6.99%	6.71%	6.45%	6.14%	5.90%	5.68%
	w	R	7.50%	11.96%	15.74%	18.63%	21.28%	24.09%	26.77%	29.07%	30.91%	32.73%
		P	7.50%	5.98%	5.25%	4.66%	4.26%	4.02%	3.82%	3.63%	3.43%	3.27%
		F1	7.50%	7.97%	7.87%	7.45%	7.09%	6.88%	6.69%	6.46%	6.18%	5.95%
b	R	12.59	19.61%	24.66%	28.54%	32.30%	35.30%	38.45%	41.09%	43.23%	45.68%	
	P	12.59	9.81%	8.22%	7.13%	6.46%	5.88%	5.49%	5.14%	4.80%	4.57%	
	F1	12.59	13.08%	12.33%	11.41%	10.77%	10.08%	9.61%	9.13%	8.65%	8.31%	
PE200	ar	R	3.26%	5.92%	7.71%	9.34%	10.53%	12.21%	13.36%	14.71%	16.02%	17.54%
		P	3.26%	2.96%	2.57%	2.33%	2.11%	2.04%	1.91%	1.84%	1.78%	1.75%
		F1	3.26%	3.94%	3.85%	3.74%	3.51%	3.49%	3.34%	3.27%	3.20%	3.19%
	cf	R	2.93%	5.81%	7.60%	9.28%	10.86%	12.00%	13.46%	14.98%	16.18%	16.83%
		P	2.93%	2.90%	2.53%	2.32%	2.17%	2.00%	1.92%	1.87%	1.80%	1.68%
		F1	2.93%	3.87%	3.80%	3.71%	3.62%	3.43%	3.37%	3.33%	3.24%	3.06%
	w	R	3.58%	6.41%	8.63%	10.37%	12.00%	13.84%	15.47%	16.99%	18.24%	19.49%
		P	3.58%	3.20%	2.88%	2.59%	2.40%	2.31%	2.21%	2.12%	2.03%	1.95%
		F1	3.58%	4.27%	4.32%	4.15%	4.00%	3.96%	3.87%	3.78%	3.65%	3.54%
b	R	6.79%	11.40%	14.39%	17.59%	19.98%	22.37%	24.48%	26.76%	28.45%	30.08%	
	P	6.79%	5.70%	4.80%	4.40%	4.00%	3.73%	3.50%	3.35%	3.16%	3.01%	
	F1	6.79%	7.60%	7.19%	7.04%	6.66%	6.39%	6.12%	5.95%	5.69%	5.47%	
Listener	ar	R	15.37%	23.61%	28.29%	31.23%	33.29%	34.73%	35.85%	36.58%	37.16%	37.69%
		P	15.37%	11.81%	9.43%	7.81%	6.66%	5.79%	5.12%	4.57%	4.13%	3.77%
		F1	15.37%	15.74%	14.14%	12.49%	11.10%	9.92%	8.96%	8.13%	7.43%	6.85%
	cf	R	17.08%	25.31%	29.39%	31.86%	33.64%	34.81%	35.63%	36.18%	36.70%	37.11%
		P	17.08%	12.66%	9.80%	7.97%	6.73%	5.80%	5.09%	4.52%	4.08%	3.71%
		F1	17.08%	16.87%	14.69%	12.75%	11.21%	9.94%	8.91%	8.04%	7.34%	6.75%
	w	R	16.64%	24.60%	28.82%	31.59%	33.44%	34.77%	35.80%	36.49%	37.05%	37.60%
		P	16.64%	12.30%	9.61%	7.90%	6.69%	5.80%	5.11%	4.56%	4.12%	3.76%
		F1	16.64%	16.40%	14.41%	12.64%	11.15%	9.94%	8.95%	8.11%	7.41%	6.84%
b	R	20.84%	28.86%	32.94%	35.41%	37.08%	38.12%	38.99%	39.54%	40.05%	40.52%	
	P	20.84%	14.43%	10.98%	8.85%	7.42%	6.35%	5.57%	4.94%	4.45%	4.05%	
	F1	20.84%	19.24%	16.47%	14.17%	12.36%	10.89%	9.75%	8.79%	8.01%	7.37%	
Playlist	ar	R	7.51%	13.44%	17.53%	20.61%	22.95%	25.01%	26.52%	27.73%	28.75%	29.67%
		P	7.51%	6.72%	5.84%	5.15%	4.59%	4.17%	3.79%	3.47%	3.19%	2.97%
		F1	7.51%	8.96%	8.77%	8.24%	7.65%	7.15%	6.63%	6.16%	5.75%	5.39%
	cf	R	8.38%	14.40%	18.71%	22.05%	24.52%	26.33%	27.88%	29.03%	29.92%	30.65%
		P	8.38%	7.20%	6.24%	5.51%	4.90%	4.39%	3.98%	3.63%	3.32%	3.07%
		F1	8.38%	9.60%	9.36%	8.82%	8.17%	7.52%	6.97%	6.45%	5.98%	5.57%
	w	R	8.27%	14.09%	18.55%	21.69%	24.09%	26.05%	27.57%	28.78%	29.75%	30.60%
		P	8.27%	7.04%	6.18%	5.42%	4.82%	4.34%	3.94%	3.60%	3.31%	3.06%
		F1	8.27%	9.39%	9.27%	8.67%	8.03%	7.44%	6.89%	6.40%	5.95%	5.56%
b	R	12.57%	19.89%	24.30%	27.37%	29.90%	31.81%	33.35%	34.55%	35.56%	36.49%	
	P	12.57%	9.94%	8.10%	6.84%	5.98%	5.30%	4.76%	4.32%	3.95%	3.65%	
	F1	12.57%	13.26%	12.15%	10.95%	9.97%	9.09%	8.34%	7.68%	7.11%	6.63%	

Tabela 3-2 – Resultados dos testes *offline*

3.6 Adaptação do Sistema de Recomendação Web AMAAFWA para utilização *online*

Como um dos possíveis trabalhos futuros de desenvolvimento do sistema, Morais (2013) apontava o teste do sistema de recomendação em funcionamento *online*, de modo a verificar se a qualidade das recomendações numa situação real é similar à obtida nos testes *offline*. Em face do interesse do tema, é esse o âmbito do projeto de investigação em que se insere a presente dissertação.

Como já atrás se referiu, além do teste *online* do sistema, pretende-se também avaliar em que medida o sistema de recomendação AMAAFWA (Morais, 2013) pode proporcionar, na prática, uma solução que permita uma melhoria da experiência de navegação por parte dos utilizadores e potenciar os objetivos a que o sítio Web que acolhe o sistema de recomendação se propõe.

Assim, com objetivo de prosseguir com o referido estudo, procedeu-se à adaptação do referido sistema para utilização *online*, de modo a testar o sistema em funcionamento real.

Considerando o esquema da Figura 3-5, que representa o sistema de recomendação como originalmente concebido (Morais, 2013), o trabalho realizado consistiu na integração do sistema de recomendação AMAAFWA num sítio Web. Do ponto de vista de programação, o trabalho desenvolvido consistiu no desenvolvimento dos módulos a sombreado na figura seguinte.

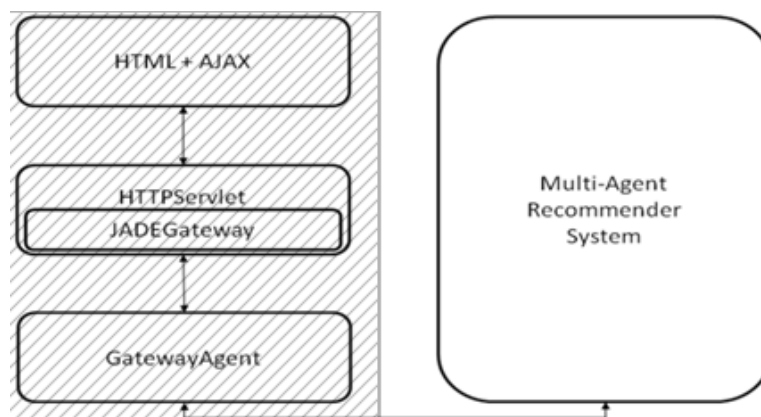


Figura 3-5 – Arquitetura do sistema de recomendação – módulos a adaptar

3.6.1 Detalhe de implementação

A comunicação entre o *browser* do cliente e o sistema de recomendação foi implementada usando AJAX e uma HTTP *servlet* que incorpora um *gateway* para a plataforma JADE, onde um agente assegura todas as comunicações com o sistema de recomendação multiagente.

Para teste do sistema foi usado o sítio Web de fotografia 1000 Palavras (www.1000palavras.pt), implementado em PHP, HTML e *Javascript*, que foi adaptado de modo a acolher o sistema de recomendação.

O sítio Web inclui 344 fotografias distribuídas por 8 galerias, num total de 353 páginas Web se considerarmos também a página principal do sítio Web e as 8 páginas de galerias. Tratando-se de um sítio Web de fotografia, o sistema de recomendação foi adaptado de forma a recomendar fotos pertencentes ao sítio, pelo que se deve considerar um conjunto de dados com 344 itens. Na Figura 3-6 apresenta-se a arquitetura global do sistema (Neto & Morais, 2014).

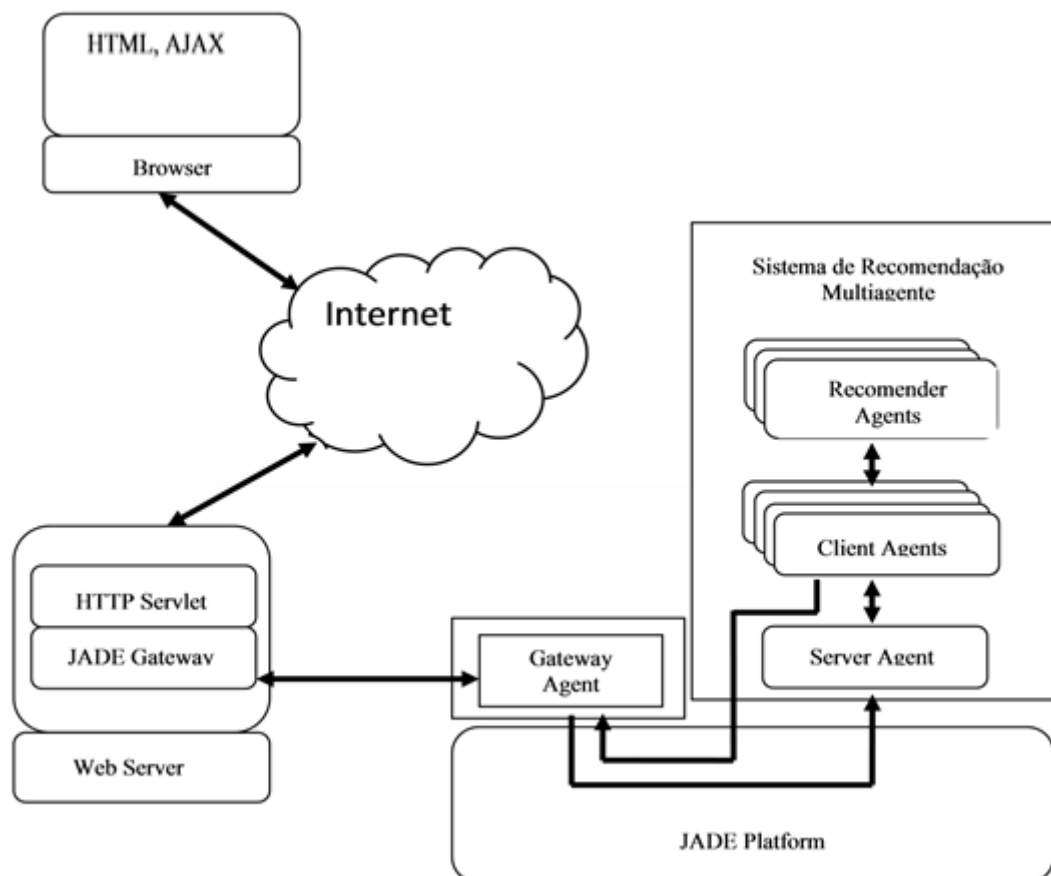


Figura 3-6 – Arquitetura global do sistema de recomendação (adaptação para utilização *online*)

3.6.2 Funcionamento do sistema

De acordo com o definido na arquitetura do sistema de recomendação AMAAFWA, cada página Web, quando carregada, gera um pedido (*request*) a enviar ao sistema de recomendação, com o seguinte conteúdo:

$$Request=(uid, pid, reqtime) \quad (25)$$

Onde:

- *uid* – identifica do utilizador
- *pid* – identifica a página carregada pelo utilizador
- *reqtime* - data e hora em que a página é carregada.

Este pedido é enviado ao sistema de recomendação recorrendo à tecnologia *AJAX* e a uma *HTTP Servlet* que inclui um *gateway* para a plataforma *JADE*.

A informação recebida do *browser* é encaminhada para o sistema de recomendação através de um agente, *gateway agent*, especificamente desenvolvido para o efeito. Ao receber o pedido do *browser*, o *gateway agent* entrega-o ao agente servidor (*server agent*). Já dentro do sistema de recomendação, o agente servidor encaminha o pedido ao agente cliente (*client agent*) que representa o utilizador no sistema. Caso o agente cliente que representa o utilizador que formulou o pedido não exista, será criado pelo agente servidor. Na posse do pedido, o agente cliente envia-o aos agentes de recomendação registados no *DF*, cada um deles respondendo com a sua proposta de licitação e respetivo conjunto de recomendações. Na posse das propostas, o agente cliente determina qual a melhor e envia-a ao *gateway agent*, que, usando a tecnologia *AJAX* e *HTTP Servlet* disponibiliza ao utilizador, através do *browser*, um conjunto de *N* recomendações. Nos testes efetuados consideramos *N=10*, pelo que foram apresentadas aos utilizadores 10 itens.

3.6.3 Adaptação do sistema para funcionamento com classificação explícita dos itens

Apesar de o presente trabalho de investigação ter tido como principal propósito a adaptação do sistema de recomendação multiagente AMAAFWA para funcionamento *online* e consequente avaliação de desempenho, procedeu-se também a uma alteração do sistema para funcionamento baseado numa classificação explícita dos itens pelos utilizadores. Pretendeu-se assim avaliar em que medida a incorporação de informação explícita no sistema influencia o seu desempenho.

Como já se referiu, o sistema de recomendação multiagente AMAAFWA, como concebido e desenvolvido por Morais (2013), baseia-se numa classificação binária implícita dos itens, em que a visualização de uma página de foto vale 1, valendo 0 caso contrário.

No desenvolvimento de uma solução baseada em informação explícita há que definir como o utilizador explicita as suas preferências para um dado item, se um simples *gosto*, como no Facebook (<http://www.facebook.com>), ou se através de uma escala de preferências de 1 a 5 como na Amazon (<http://www.amazon.com>).

No caso presente optou-se por manter a característica binária da classificação usada por Morais (2013) no sistema de recomendação multiagente AMAAFWA, adotando-se uma solução do tipo Facebook.

Assim, foram introduzidas alterações no sítio Web 1000 Palavras (www.1000palavras.pt), que passou a incluir um botão de *gosto* para que os utilizadores pudessem mostrar a sua preferência.

De modo a ter em consideração os casos em que um utilizador carrega uma página de foto, mas não explicita a sua opinião, optou-se por considerar esse “visualizar de página” como um “*gosto*” mais fraco, como se de um “*gosto pouco*” ou “*gosto menos*” se tratasse, em contraponto ao gosto expresso explicitamente pelo utilizador. Definiu-se assim que um “*gosto*” numa página, explicitamente expresso pelo utilizador, vale 1 ponto, valendo 0,5 pontos quando o utilizador apenas visualiza a foto.

4. Testes e resultados

Concluídos os trabalhos de adaptação do sistema de recomendação multiagente AMAAFWA para funcionamento *online* com o sítio Web 1000 Palavras (www.1000palavras.pt), passou-se à realização dos testes, os quais decorreram em duas fases, num total de três testes.

4.1 Descrição dos testes realizados

Na primeira fase o sistema de recomendação foi usado como originalmente desenvolvido por Morais (2013), sendo as classificações dos itens baseadas em informação implícita, obtida com base no comportamento dos utilizadores. Cada visita a uma página Web para visualização de uma fotografia era considerada equivalente a um “Gosto”, recebendo a pontuação de 1 (um). Nesta fase foram realizados dois testes:

1. No primeiro teste o sítio Web 1000 Palavras (www.1000palavras.pt) foi colocado *online* com o sistema de recomendação em funcionamento, mas as recomendações não foram apresentadas aos utilizadores. Na Figura 4-1 apresenta-se o aspeto de uma página de foto.

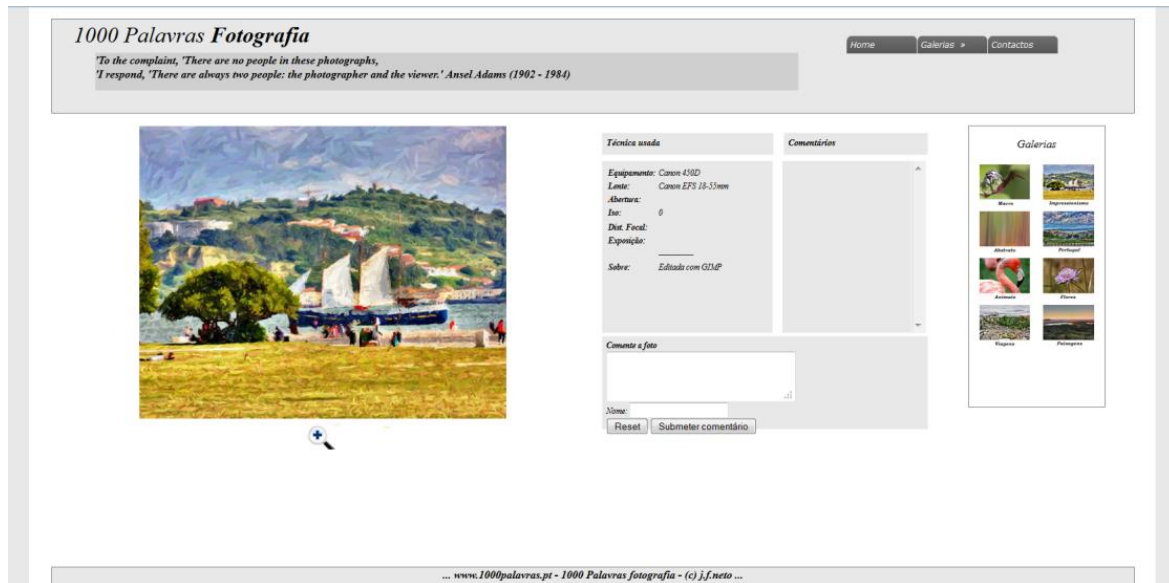


Figura 4-1 – Página de foto do sítio Web: 1º teste (recomendações inativas)

2. No segundo teste o sítio Web 1000 Palavras (www.1000palavras.pt) foi colocado *online* com o sistema de recomendação em funcionamento pleno, com as recomendações a serem apresentadas aos utilizadores, de modo a que estes pudessem seguir essas recomendações sugeridas pelo sistema de recomendação. Na Figura 4-2 apresenta-se o aspeto de uma página de foto do sítio Web, onde é visível conjunto de recomendações.

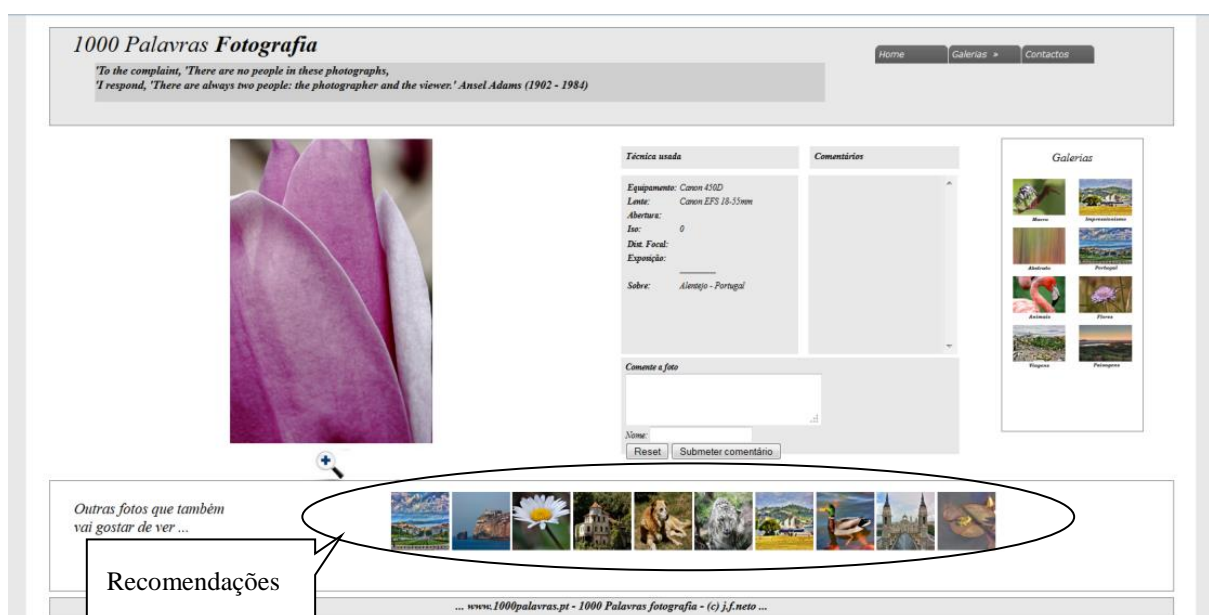


Figura 4-2 - Página de foto do sítio Web: 1º teste (recomendações ativas)

Na segunda fase foram introduzidas no sistema as modificações descritas na secção 3.6.3, de modo a permitir que os utilizadores classifiquem os itens de forma explícita. Os utilizadores foram convidados a classificar a foto através de um botão de “Gosto”. Na Figura 4-3 apresenta-se uma página de foto do sítio Web, sendo visível o botão de “Gosto” e o conjunto de recomendações.

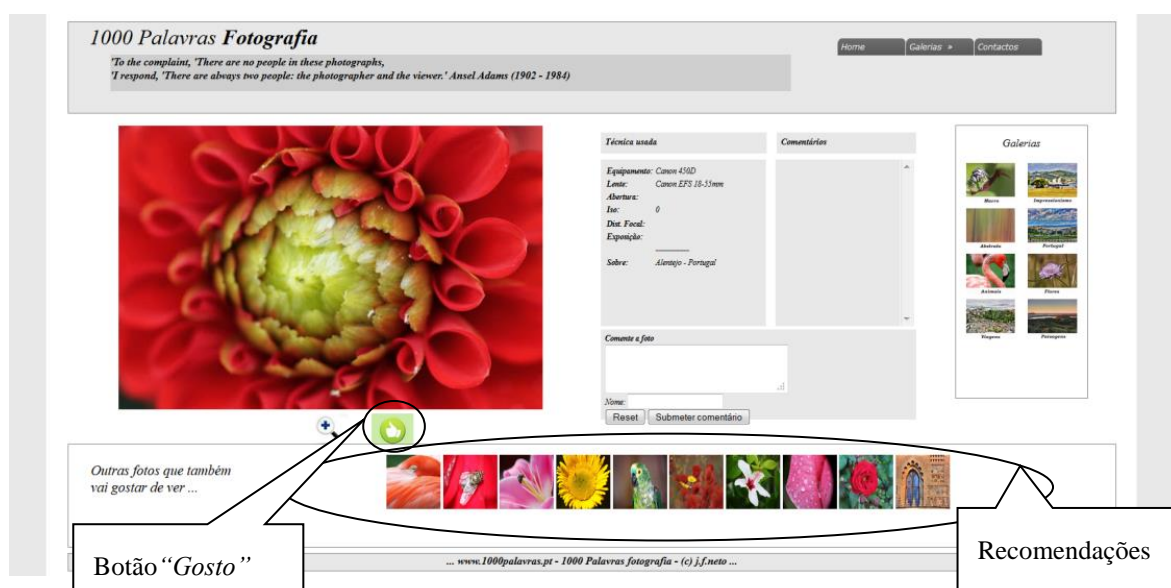


Figura 4-3 - Página de foto do sítio Web: 3º teste (recomendações ativas e botão “Gosto”)

Com primeira fase de testes *online* pretendeu-se avaliar o desempenho do Sistema de Recomendação AMAAFWA (Morais, 2013), segundo as três vertentes seguintes:

- Comparar o comportamento dos utilizadores num sítio Web com e sem sistema de recomendação, aferindo em que medida o sistema AMAAFWA pode contribuir para uma melhoria da experiência de navegação por parte dos utilizadores.
- Avaliar em que medida o sistema AMAAFWA é capaz de potenciar os objetivos a que o sítio Web se propõe, os quais, no caso presente, se podem medir em termos do aumento de visualizações de fotos face ao sítio Web sem sistema de recomendação.
- Determinar se o desempenho do sistema multiagente de recomendação, com agentes baseados em diferentes algoritmos de recomendação, tem melhor desempenho que um sistema de recomendação baseado num único algoritmo de recomendação.

A segunda fase teve como propósito comparar o desempenho do sistema baseado numa classificação implícita dos itens com um sistema em que é usada classificação explícita.

4.2 Análise dos Resultados

Na secção 4.2.1 faz-se uma análise segundo as vertentes a) e b) acima referidas, na secção 4.2.2 far-se-á uma análise segundo a vertente referida na alínea c) e na secção 4.2.3 compara-se a prestação do sistema com base na estratégia adotada para classificação dos itens.

4.2.1 Experiência de Navegação dos Utilizadores e Objetivos do Sítio Web

Para melhor legibilidade passaremos a identificar os testes 1 e 2 da primeira fase, por RECS_OFF e RECS_ON respetivamente. Na Tabela 4-1 resumem-se as características dos conjuntos de dados de cada um dos testes da 1ª fase.

	1º Teste RECS_OFF	2º Teste RECS_ON
#itens	344	344
#pedidos	2514	2377
#sessões	364	205
#pedidos/#itens	7,3081	6,9098
#pedidos/#sessões	6,9066	11,5951
#fotos/#sessões	3,57	7,34

Tabela 4-1 - Caracterização dos conjuntos de dados de ambos os testes

Um primeiro dado relevante que decorre da tabela acima, e que importa salientar, prende-se com o facto de, com o sistema de recomendação ligado, os utilizadores permanecerem no sítio Web de uma forma mais ativa, como se pode inferir do facto do número de páginas visitadas por sessão ser cerca de 60% superior, passando de 3,57 para 7,34 fotos por sessão. A importância deste dado resulta do facto de poder indiciar um acréscimo de satisfação do utilizador quanto ao que lhe é proporcionado pelo sítio Web.

Também são de realçar os dados apresentados na Tabela 4-2, onde se pode constatar que, com o sistema de recomendação ligado, a percentagem de páginas de fotos visitadas passou de 51,75% para 63,27%, o que representa uma taxa de aumento de 22,26%. Pelo que, sendo objetivo do sítio Web a divulgação de fotos, o acréscimo de páginas de fotos visitadas pode representar uma mais-valia proporcionada pelo sistema de recomendação.

	1º Teste RECS_OFF	2º Teste RECS_ON
#pedidos	2514	2377
#pedidos de fotos	1301	1504
%pedidos de fotos	51,75%	63,27%
%de fotos não visitadas	20,64%	24,71%

Tabela 4-2 – Percentagem de visualização de fotos

Um outro aspeto que importa analisar é o de perceber em que medida os utilizadores seguiram as recomendações que lhes foram sendo sugeridas pelo sistema de recomendação. Dos resultados obtidos, apresentados na Tabela 4-3, pode inferir-se que aproximadamente uma em cada duas fotos visitadas decorre de recomendações sugeridas pelo sistema de recomendação.

	2º teste RECS_ON
#pedidos	2377
#pedidos de fotos	1504
#pedidos que seguiram recomendação	739
%do total de pedidos que seguiram recomendação	31,09%
%do total fotos vistas que seguiram recomendação	49,14%

Tabela 4-3 – Percentagem de recomendações seguidas

Importa ainda realçar que apesar de cerca de 50% das páginas de fotos visitadas resultarem de recomendações seguidas pelos utilizadores, retira-se da Tabela 4-2 que o número de páginas de fotos que nunca foram visitadas é apenas cerca de 4% superior que o obtido com as recomendações desligadas. A relevância deste dado resulta do facto de se poder inferir que, com as recomendações a serem apresentadas aos utilizadores, não se assistiu a restrição significativa do conjunto de páginas de fotos visitadas, facto que é confirmado pelo gráfico de dispersão da Figura 4-4.

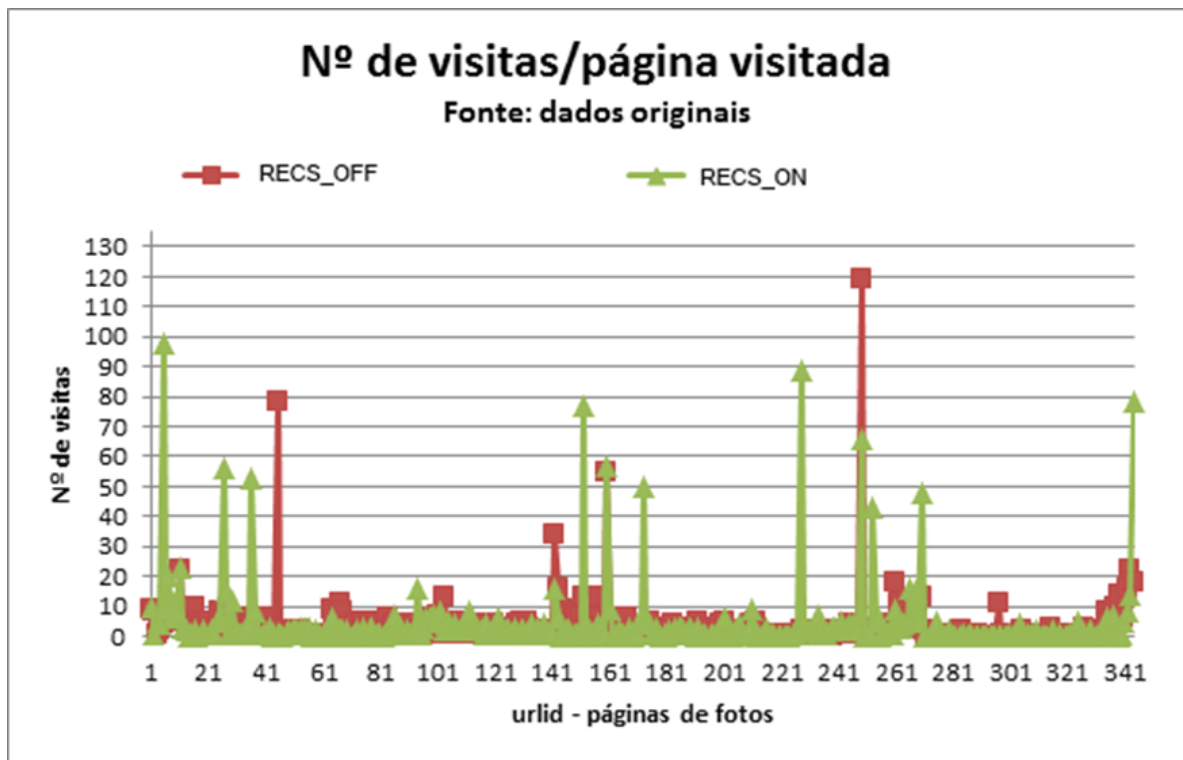


Figura 4-4 - Gráfico de dispersão (nº de visitas/página) baseado em dados originais

O gráfico da Figura 4-4 confirma a semelhança de visualizações de fotos entre os dois testes quanto à dispersão de visualizações por todo o conjunto de itens.

Também perceptível no gráfico é o facto de se obter um maior número de picos com as recomendações ativas, isto é, mais páginas cujo número de visualizações sobressai relativamente às restantes, facto que se entende em face de cerca de 50% das visualizações resultarem de recomendações sugeridas pelo sistema ao utilizador.

Toda a análise de resultados até aqui apresentada suporta-se nos dados em bruto, sem qualquer tipo de filtragem. No entanto, o modo como, em ambas as fases, o sítio Web foi divulgado e publicitado, poderá ter originado algum enviesamento, designadamente quanto ao número de visualizações que algumas páginas de fotos apresentam.

De facto, a divulgação do sítio Web foi feita quer divulgando a hiperligação para a sua página principal, quer divulgando o *link* para uma foto em concreto, facto que, em qualquer dos cenários, poderá resultar num número de visitas a uma foto maior do que era expectável.

Assim, de modo a analisar os dados purgados desse eventual enviesamento, desprezamos o pedido referente à primeira página visitada de todas as sessões, cuja página visualizada foi

uma página de foto. Na Tabela 4-4 caracterizam-se ambos os conjuntos de dados, realçando-se a sombreado os dados já filtrados.

	Fonte: dados originais		Fonte: dados filtrados	
	1º Teste RECS_OFF	2º Teste RECS_ON	1º Teste RECS_OFF	2º Teste RECS_ON
#itens	344	344	344	344
#pedidos	2514	2377	2303	2338
#sessões	364	205	273	191
#pedidos/#itens	7,3081	6,9098	6,6947	6,7965
#pedidos/#sessões	6,9066	11,5951	8,4359	12,2408
#fotos/#sessões	3,57	7,34	3,99	7,67

Tabela 4-4 – Conjuntos de dados (dados originais vs dados filtrados)

O dado mais relevante a extrair da tabela acima é a significativa redução do número de pedidos e sessões a considerar para análise no que se refere ao teste com as recomendações não ativas. Essa diferença significa que o acesso ao sítio através da hiperligação para uma foto teve um peso maior durante o referido teste.

As diferenças são também evidentes se analisarmos o número de páginas de fotos visitadas, como se pode inferir analisando a Tabela 4-5, merecendo realce o acréscimo no diferencial de visitas a páginas de fotos entre os dois testes.

	Fonte: dados originais		Fonte: dados filtrados	
	1º Teste RECS_OFF	2º Teste RECS_ON	1º Teste RECS_OFF	2º Teste RECS_ON
#pedidos	2514	2377	2303	2338
#pedidos de fotos	1301	1504	1090	1465
%pedidos de fotos	51,75%	63,27%	47,33%	62,66%
Diferencial de pedidos de fotos	22,27%		32,39%	
%de fotos não visitadas	20,64%	24,71%	20,64%	25,29%

Tabela 4-5 – Resultados (dados originais vs dados filtrados)

Com base nos dados expurgados da primeira página visitada de todas as sessões cuja página visualizada é uma página de foto verifica-se que, com as recomendações ativas, as visitas a páginas de fotos aumentam 32,39%, ao passo que, com os dados originais, a diferença é de 22,27%. Estes dados confirmam e reforçam que, com as recomendações ativas, é potenciado aquele que é um dos principais objetivos do sítio Web, a divulgação das suas fotos.

Na Tabela 4-6 apresentam-se os resultados obtidos, os quais também confirmam o padrão de que aproximadamente uma em cada duas páginas de fotos visitadas resulta de recomendações sugeridas pelo sistema de recomendação.

	Fonte: dados originais	Fonte: dados filtrados
	2º Teste RECS_ON	2º Teste RECS_ON
#pedidos	2377	2338
#pedidos de fotos	1504	1465
#pedidos que seguiram recomendação	739	739
%do total de pedidos que seguiram recomendação	31,09%	31,61%
%do total fotos vistas que seguiram recomendação	49,14%	50,44%

Tabela 4-6 - Percentagem de recomendações seguidas (dados originais e dados filtrados)

Para concluir esta análise, vamos socorrer-nos do gráfico de dispersão da Figura 4-5, semelhante ao da Figura 4-4, mas agora com base nos dados expurgados da primeira página visitada de todas as sessões cuja página visualizada seja uma página de foto.




Figura 4-5 - Gráfico de dispersão (nº de visitas/página) baseado em dados filtrados

Uma leitura atenta do gráfico da Figura 4-5 confirma os dados que já se vinham a revelar nas tabelas anteriores. De facto, quanto aos dados obtidos com as recomendações inativas, é possível constatar a eliminação dos dois picos mais pronunciados visíveis no gráfico da

Figura 4-4. Essas duas páginas de fotos (nº 45 com 78 visualizações e nº 249 com 119 visualizações) correspondem de facto a hiperligações usadas para publicitar e divulgar o sítio 1000 Palavras (www.1000palavras.pt). Já quanto aos dados obtidos com as recomendações ativas, os gráficos correspondentes são quase indistinguíveis.

No gráfico de dispersão da Figura 4-6 comparam-se as visualizações de uma dada página para cada um dos testes, sendo também possível confirmar que com o sistema de recomendação em funcionamento pleno (RECS_ON) o número de visualizações de uma dada página de foto tende a ser superior, o que está em linha com o facto de mais de 50% das visualizações resultarem de recomendações seguidas.

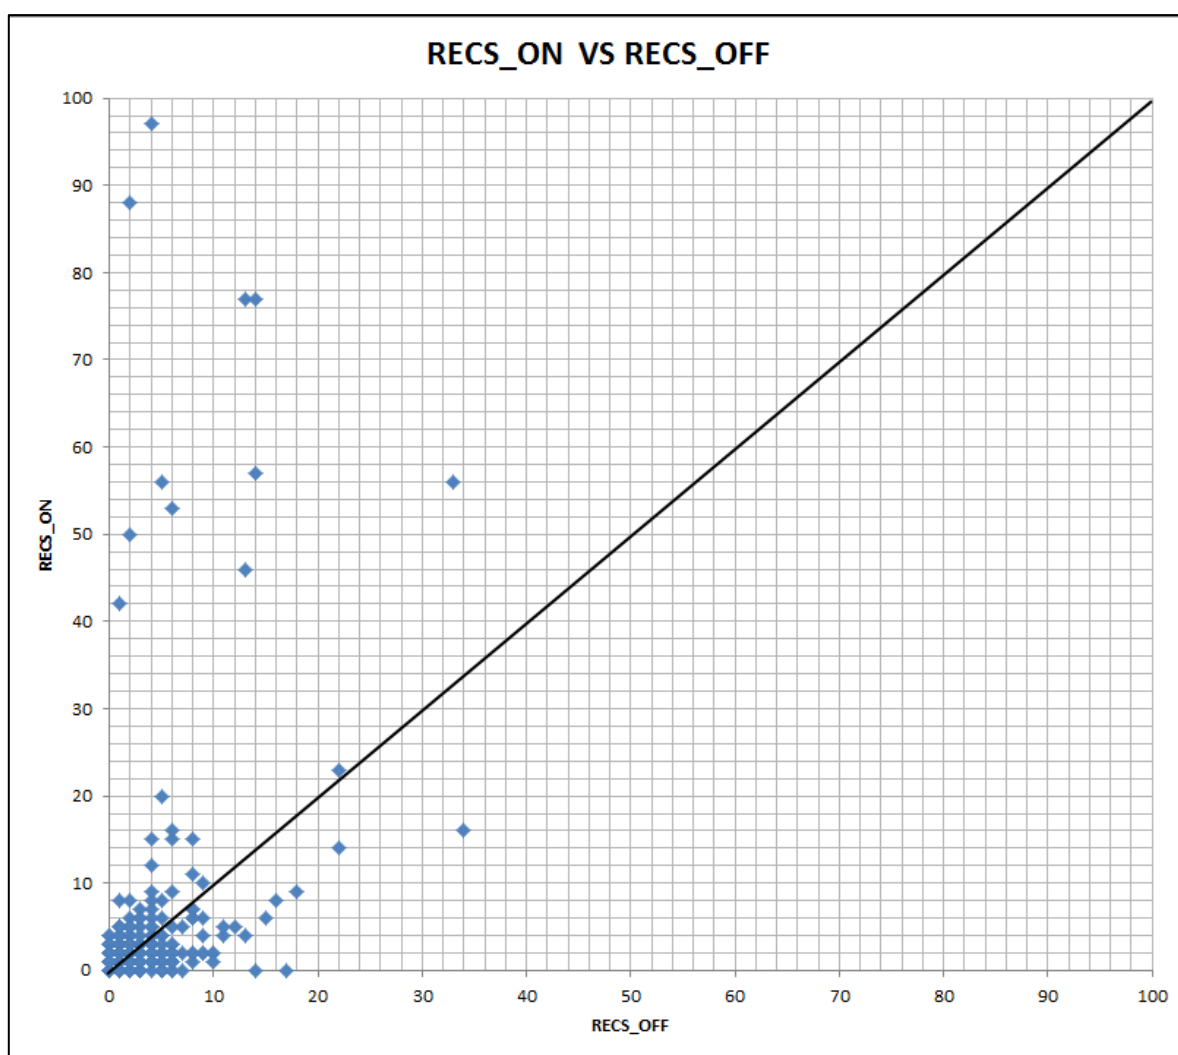


Figura 4-6 - Gráfico de dispersão (RECS_ON VS RECS_OFF) baseado em dados filtrados

A análise efetuada teve como propósito comparar o comportamento dos utilizadores num sítio Web com e sem sistema de recomendação, aferindo em que medida o sistema multiagente AMAAFWA poderá contribuir para uma melhoria da experiência de navegação por parte dos

utilizadores e, ao mesmo tempo, ser capaz de potenciar os objetivos a que o sítio Web se propõe, levando a que, no caso presente, os utilizadores permaneçam mais tempo no sítio Web e visualizem mais fotos do face a um sítio Web sem sistema de recomendação.

Recuperando os dados das Tabela 4-4 e Tabela 4-5, resumem-se na Tabela 4-7 os dados globais dos dois conjuntos de dados. Importa realçar que vamos considerar como base para a análise os dados expurgados da primeira página visitada de todas as sessões.

	Fonte: dados filtrados	
	1º Teste RECS_OFF	2º Teste RECS_ON
#itens	344	344
#pedidos	2303	2338
#sessões	273	191
#pedidos/#itens	6,6947	6,7965
#pedidos/#sessões	8,4359	12,2408
#fotos/#sessões	3,9927	7,6702
#pedidos de fotos	1090	1465
%pedidos de fotos (#pedidos de fotos/#pedidos)	47,33%	62,66%

Tabela 4-7 – Conjunto de dados da 1ª fase (dados filtrados)

Dos dados da Tabela 4-7, pode concluir-se que, na perspetiva do sítio Web, é cumprido o objetivo. De facto, com o sistema de recomendação em funcionamento pleno, isto é, a apresentar recomendações aos utilizadores, a percentagem de páginas de fotos visitadas em função do número total de páginas visitadas no sítio Web, passa de 47,33% para 62,66% e o número médio de fotos visitadas por sessão passa de 3,99 para 7,67.

Por outro lado, também da Tabela 4-7, se pode inferir que, da perspetiva do utilizador, existe uma melhoria da experiência de navegação, que o leva a permanecer no sítio Web por mais tempo, pois o número de pedidos e de fotos visitadas por sessão aumentam 45,1% e 92,1%, respetivamente.

Já anteriormente se referiu que um pressuposto fundamental do sistema multiagente é ser capaz de responder de forma rápida a um pedido de recomendações. O utilizador deve ter acesso às recomendações em tempo real, pelo que o tempo que medeia entre o carregamento da página, coincidente com o envio do pedido de recomendação ao sistema, e a disponibilização das recomendações aos utilizadores, é um outro elemento relevante para aferir da satisfação dos utilizadores, pelo que se procedeu ao registo desse tempo.

Nas Tabela 4-8 e Tabela 4-9 apresentam-se os valores observados para o tempo de resposta do sistema de recomendação.

	Tempo de resposta (milissegundos)
Valor médio	551,66
Desvio Padrão	107,61
Valor Máximo	1046
Valor Mínimo	250
Amplitude	796
Mediana	546
Moda	546

Tabela 4-8- Caracterização dos resultados observados

Intervalo de tempo (milissegundos)	Frequência relativa (%)	Frequência cumulativa (%)	Intervalo de tempo (milissegundos)	Frequência relativa (%)	Frequência cumulativa (%)
[241,261[0,20%	0,20%	[661,681[0,39%	93,07%
[261,281[0,29%	0,49%	[681,701[1,17%	94,24%
[281,301[0,49%	0,98%	[701,721[0,78%	95,02%
[301,321[0,68%	1,66%	[721,741[0,29%	95,31%
[321,341[1,46%	3,13%	[741,761[0,29%	95,61%
[341,361[2,64%	5,76%	[761,781[0,49%	96,09%
[361,381[0,68%	6,45%	[781,801[0,49%	96,58%
[381,401[0,78%	7,23%	[801,821[0,39%	96,97%
[401,421[0,68%	7,91%	[821,841[0,10%	97,07%
[421,441[0,78%	8,69%	[841,861[0,29%	97,36%
[441,461[1,27%	9,96%	[861,881[0,10%	97,46%
[461,481[0,78%	10,74%	[881,901[0,20%	97,66%
[481,501[11,04%	21,78%	[901,921[0,68%	98,34%
[501,521[9,57%	31,35%	[921,941[0,00%	98,34%
[521,541[11,52%	42,87%	[941,961[0,10%	98,44%
[541,561[15,92%	58,79%	[961,981[0,39%	98,83%
[561,581[15,82%	74,61%	[981,1001[0,10%	98,93%
[581,601[7,52%	82,13%	[1001,1021[0,20%	99,12%
[601,621[3,91%	86,04%	[1021,1041[0,68%	99,80%
[621,641[5,37%	91,41%	[1041,1061]	0,20%	100,00%
[641,661[1,27%	92,68%			

Tabela 4-9 – Tabela de frequências relativa e cumulativa

Nos gráficos das Figura 4-7 e Figura 4-8 apresentam-se os histogramas da frequência relativa e cumulativa para o conjunto de dados observados.

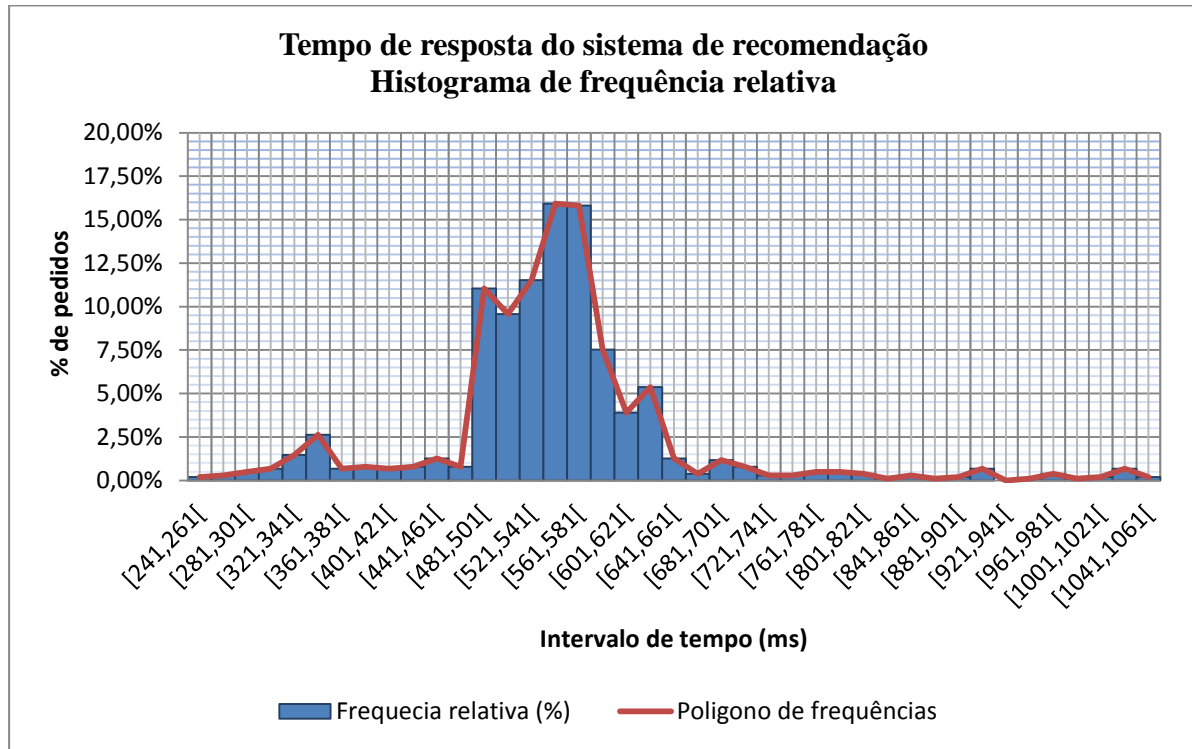


Figura 4-7 -Tempo de resposta do sistema de recomendação: histograma de frequência relativa




Figura 4-8-Tempo de resposta do sistema de recomendação: histograma de frequência cumulativa

O valor médio dos dados observados é de cerca de 552 milissegundos, sendo o valor máximo obtido para o tempo de resposta do sistema de recomendação de cerca de 1 segundo. É também de registar que 60,35% dos pedidos de recomendação foram respondidos num tempo compreendido entre os 500 e 600 milissegundos.

Com base no histograma da frequência cumulativa, conclui-se também que 82,13% dos pedidos foram respondidos em menos de 600 milissegundos e 98,93% em menos de 1 segundo.

Os valores observados estão de acordo com a experiência de navegação sentida pelos utilizadores ao navegar no sítio 1000 Palavras (www.1000palavras.pt), que mostrou uma resposta do sistema de recomendação em tempo que se pode considerar adequado e consentâneo com o expectável pelos utilizadores.

4.2.2 Análise do desempenho do sistema de recomendação multiagente

Nesta secção vamos debruçar-nos sobre os resultados obtidos, tendo em mente avaliar se o desempenho do sistema multiagente de recomendação, com agentes baseados em diferentes algoritmos de recomendação, tem melhor desempenho que um sistema de recomendação baseado num único algoritmo de recomendação.

Refira-se que se optou pela recomendação de 10 páginas de fotos (N=10), pelo que toda a análise aqui efetuada tem por base essa dimensão para o conjunto de recomendações.

Importa agora incidir a análise sobre os resultados do sistema de recomendação, analisando o seu desempenho em ambos os testes da 1.^a fase, isto é, com base no conjunto de dados de navegação obtidos no primeiro teste – sítio Web com o sistema de recomendação em funcionamento, mas em que as recomendações são geradas mas não são apresentadas ao utilizador; e usando os dados do segundo teste – sítio Web com o sistema de recomendação em funcionamento real, isto é, as recomendações são geradas e apresentadas ao utilizador.

Para avaliar o desempenho do sistema de recomendação vamos considerar as medidas *precision* e *recall*, já anteriormente referidas.

Na Tabela 4-10 apresentam-se os dados referentes ao número de páginas de foto visitadas que foram recomendadas pelo sistema de recomendação.

	Sistema de Recomendação (Modo de Funcionamento)	
	RECS_OFF	RECS_ON
#Total de páginas de fotos visitadas	1090	1465
#Vezes que página seguida foi recomendada pelo agente vencedor	217 (19,91%)	739 (50,44%)
#Vezes que Página seguida foi recomendada por um agente que não o agente vencedor	112 (10,28%)	24 (1,64%)
#vezes que foi seguida página não recomendada	873	726

Tabela 4-10 – Páginas de foto visitadas (com e sem a recomendações ativas)

Quanto ao sistema em modo RECS_ON, já atrás fizemos uma análise dos resultados, os quais indicam que para aproximadamente uma em cada duas páginas de fotos visitadas, o utilizador seguiu uma das dez fotos recomendadas pelo sistema. Da Tabela 4-10 constata-se que os resultados obtidos em modo RECS_OFF, o sistema de recomendação recomendou 19,91% das páginas visitadas pelos utilizadores, já indiciavam um bom desempenho para o sistema de recomendação.

De notar que para efeitos da avaliação do desempenho do sistema de recomendação AMAAFWA, não consideramos para os cálculos apresentados a última página visitada de todas sessões, pois, por ter expirado a sessão, não é possível determinar se o utilizador seguiria ou não uma das recomendações sugeridas.

Na Tabela 4-11 apresentam-se os resultados para cada um dos agentes de recomendação verificando-se que o agente baseado em regras de associação (ARPROV) é o agente que mais vezes aparece como vencedor do leilão, ou seja, é o agente cuja proposta é mais vezes apresentada ao utilizador.

Importa realçar que os resultados para os agentes de recomendação da Tabela 4-11 são os obtidos no âmbito do sistema de recomendação multiagente, isto é, em que os três agentes coexistem e competem entre si no sentido de apresentar a melhor proposta de recomendação,

pelo que, o que se retira da tabela é o peso de cada um deles nas recomendações apresentadas pelo sistema de recomendação.

	ARPROV		TTPROV		CFPROV	
	RECS_OFF	RECS_ON	RECS_OFF	RECS_ON	RECS_OFF	RECS_ON
#vezes que foi seguida página não recomendada	713	780	803	1226	718	1089
#Vezes que página seguida foi recomendada	228	665	125	600	276	597
#Vezes que o agente ganhou o leilão e foi seguida página foi recomendada	104	494	14	48	99	220
#Vezes que o agente ganhou o leilão	1370	1336	304	303	839	737
% Vezes que o agente ganhou o leilão	54,52%	56,23%	12,10%	12,75%	33,39%	31,02%

Tabela 4-11 - Resultados por agente de recomendação

Um aspeto relevante e fundamental para a avaliação do desempenho do sistema de recomendação AMAAFWA, é saber se a abordagem de sistema multiagente que lhe está subjacente, em que agentes baseados em diferentes algoritmos propõem as suas recomendações, contribui para melhores recomendações do que os algoritmos considerados individualmente. Tal como questiona Morais (2013), o que se pretende determinar é se o desempenho de um sistema de recomendação multiagente, com agentes implementando diferentes algoritmos, tem melhor desempenho que os algoritmos considerados individualmente.

Para avaliação do desempenho do sistema de recomendação multiagente, vão usar-se as métricas de avaliação *recall*, *precision* e *F1*, apresentadas na secção 3.1.3.

Os resultados obtidos apresentam-se na Tabela 4-12 e na Tabela 4-13, tendo-se calculado aquelas métricas de avaliação para o sistema de recomendação multiagente (SRMA) e para os três algoritmos considerados individualmente: O ARPROV refere-se ao algoritmo baseado em regras associativas; o TTPROV diz respeito ao algoritmo que recomenda os dez itens mais populares e o CFPROV implementa um algoritmo baseado em filtragem colaborativa. Apresentamos também valores para o que designamos por melhor caso (MC), isto é, o caso hipotético em que pelo menos um dos agentes de recomendação recomendou a página seguida pelo utilizador.

Na Tabela 4-12 consideraram-se todos os registos, mesmo aqueles em que o utilizador segue para uma página Web que não pertence ao conjunto itens elegíveis para recomendação, referimo-nos aos casos em que o utilizador opta por visitar uma das páginas de galerias ou a página principal do sítio Web. Os registos que se referem a finais de sessão não são considerados.

Métricas de avaliação	SRMA		ARPROV		TTPROV		CFPROV		MC	
	RECS OFF	RECS ON	RECS OFF	RECS ON	RECS OFF	RECS ON	RECS OFF	RECS ON	RECS OFF	RECS ON
Recall	12,05%	34,02%	10,60%	30,62%	6,33%	27,62%	13,30%	27,49%	15,30%	35,13%
Precision	1,20%	3,40%	1,06%	3,06%	0,63%	2,76%	1,33%	2,75%	1,53%	3,51%
F1	2,19%	6,19%	1,93%	5,57%	1,15%	5,02%	2,42%	5,00%	2,78%	6,39%

Tabela 4-12- Resultados para 1ª fase – apenas não são considerados os fins de sessão

Na Tabela 4-13 consideraram-se apenas os registos em que o utilizador segue para uma página Web que pertença ao conjunto de itens que o sistema de recomendação pode recomendar. Não são assim considerados os registos que se referem aos casos em que o utilizador opta por visitar uma das páginas de galerias ou a página principal do sítio Web. Os registos que se referem a finais de sessão não são considerados.

Métricas de avaliação	SRMA		ARPROV		TTPROV		CFPROV		MC	
	RECS OFF	RECS ON	RECS OFF	RECS ON	RECS OFF	RECS ON	RECS OFF	RECS ON	RECS OFF	RECS ON
Recall	31,70%	58,01%	27,91%	52,20%	16,65%	47,10%	35,01%	46,86%	40,27%	59,89%
Precision	3,17%	5,80%	2,79%	5,22%	1,66%	4,71%	3,50%	4,69%	4,03%	5,99%
F1	5,76%	10,55%	5,07%	9,49%	3,03%	8,56%	6,36%	8,52%	7,32%	10,89%

Tabela 4-13 - Resultados para 1ª fase – apenas são considerados itens elegíveis para recomendação

Importa analisar os resultados apresentados na Tabela 4-12 e Tabela 4-13 segundo duas perspetivas. Na primeira é interessante comparar os resultados obtidos com o sistema de recomendação desligado, com os resultados *offline* obtidos por Morais (2013), na segunda

analisar-se-ão os resultados comparando os resultados obtidos *online*, para o sítio Web 1000 Palavras (www.1000palavras.pt), com e sem o sistema de recomendação ligado.

Quanto à comparação entre os resultados obtidos com o sistema de recomendação desligado e os obtidos *offline* verifica-se que apesar de o sistema multiagente de recomendação ter obtido resultados inferiores ao obtido pelo algoritmo CFPROV, pode considerar-se que, ainda assim, a qualidade das recomendações geradas pelo sistema multiagente é similar à obtida pelo algoritmo CFPROV.

Por outro lado, quando consideramos o sistema de recomendação multiagente no seu funcionamento pleno, gerando recomendações e apresentando-as aos utilizadores, verifica-se que este obtém melhores resultados que os algoritmos individuais. De facto, como se pode concluir da Tabela 4-13, que tem em conta os registos em que apenas são considerados itens elegíveis para recomendação, o sistema de recomendação multiagente apresenta um desempenho 5,8% superior ao apresentado pelo algoritmo baseado em regras de associação e 11,15% acima que o baseado em filtragem colaborativa.

Ainda de acordo com as Tabela 4-12 e Tabela 4-13 verifica-se um acréscimo na percentagem de sucesso de aproximadamente 22% e 26%, relativamente aos resultados obtidos no teste em que as recomendações não são apresentadas aos utilizadores. Este resultado está alinhado com o que já se disse quanto ao acréscimo registado na percentagem de vezes que o utilizador seguiu uma das recomendações sugeridas pelo sistema, 19,91% quando as recomendações não são apresentadas ao utilizador e 50,44% quando são apresentadas e o utilizador tem possibilidade de as seguir.

4.2.3 Classificação Implícita versus Classificação Explícita dos Itens

Como já se referiu na secção 3.6.3, procedeu-se a uma alteração no sistema de modo a que a classificação dos itens por parte dos utilizadores deixasse de ser exclusivamente implícita, isto é, apenas baseada no facto de um utilizador visitar uma página, para passar a ter em consideração a efetiva opinião do utilizador acerca do item. O teste desta nova versão do sistema decorreu na segunda fase de testes conforme já descrito na secção 4.1

Nesta secção apresentam-se os resultados obtidos na 2ª fase, 3º teste, comparando-os com os resultados obtidos na 1ª fase, 2º teste. Desta forma coloca-se lado a lado o desempenho do sistema de recomendação multiagente baseado em classificações explícitas e implícitas dos itens por parte dos utilizadores.

Na Tabela 4-14 resumem-se as características dos conjuntos de dados dos testes: um baseado em classificações implícitas (IMP) e o outro baseado em classificações explícitas (EXP) dos itens.

Em qualquer dos testes as recomendações geradas foram apresentadas aos utilizadores.

À semelhança da análise da secção anterior, vamos considerar como base para a análise os dados expurgados da primeira página visitada de todas as sessões

	Sistema de Recomendação (tipo de classificação dos itens)	
	IMP	EXP
#itens	344	344
#pedidos	2338	2337
#sessões	191	167
#pedidos/#itens	6,7965	6,7936
#pedidos/#sessões	12,2408	13,9940
#fotos/#sessões	7,6702	8,6168

Tabela 4-14 – Caraterização dos conjuntos de dados de ambos os testes

Na Tabela 4-15 apresentam-se os dados obtidos relativos à percentagem de visualização de páginas de fotos e à percentagem páginas de fotos visitadas no seguimento de recomendações, para cada um dos tipos de classificação dos itens.

	Sistema de Recomendação (tipo de classificação dos itens)	
	IMP	EXP
#pedidos	2338	2337
#pedidos de fotos (páginas de foto visitadas)	1465	1439
%pedidos de fotos (#pedidos de fotos/#pedidos)	62,66%	61,57%
%do total de pedidos que seguiram recomendação	31,61%	31,15%
%de fotos não visitadas	25,29%	37,50%
%pedidos de fotos que seguiram recomendação	50,44%	50,59%
%de vezes que a foto vista foi recomendada por um agente que não o agente vencedor	1,64%	3,41%
%de fotos (itens) que foram objeto de recomendação	47,67%	54,65%

Tabela 4-15 - Percentagem de visualização de fotos e recomendações: classificação implícita e explícita

O dado principal que sobressai dos dados apresentados nas tabelas anteriores é a semelhança de resultados para ambas as versões do sistema. Em particular, merece realce o facto de ser apenas de 0,15% a diferença no que se refere à percentagem de fotos vistas que seguiram uma das recomendações que lhe foi apresentada.

De modo a fazermos uma avaliação mais detalhada e a inferir eventuais tendências quanto ao comportamento do utilizador perante cada um dos sistemas, resumem-se na Tabela 4-16 os parâmetros de análise que constam nas tabelas anteriores, que espelham diferenças entre as duas versões do sistema testadas.

	Sistema de Recomendação (tipo de classificação dos itens)	
	IMP	EXP
#pedidos	2338	2337
#sessões	191	167
#pedidos/#sessões	12,2408	13,9940
#fotos/#sessões	7,6702	8,6168
%de fotos não visitadas	25,29%	37,50%
%de fotos (itens) que foram objeto de recomendação	47,67%	54,65%

Tabela 4-16 – Comparação de resultados: classificação implícita e explícita

Os parâmetros da Tabela 4-16 relativos às sessões poderão indiciar, ainda que não de forma significativa, que o utilizador permaneceu mais tempo no sítio Web, pois para um número de registos praticamente igual, o número de sessões é menor, pelo que os utilizadores visitaram em média mais fotos por sessão.

Relativamente aos restantes dois parâmetros, *%de fotos não visitadas* e *%de fotos (itens) que foram objeto de recomendação*, verifica-se que para o primeiro se obtém um valor de cerca de 12% superior na solução baseada em classificações explícitas, enquanto no segundo, esse acréscimo é de cerca de 7%.

Assim, com o sistema baseado em classificações explícitas verifica-se uma diminuição do número de fotos vistas, no entanto, o número de fotos recomendadas pelo sistema aumentou.

Na Figura 4-9 apresenta-se os gráficos de dispersão para ambos os testes em função das páginas de fotos visitadas. Os gráficos são similares quanto à dispersão de visualizações por todo o conjunto de itens, sendo, no entanto, as fotos mais vistas num e noutro caso diferentes. Esta diferença fica ainda mais clara na Figura 4-10.




Figura 4-9 – Gráfico de dispersão (nº visitas/página): classificação implícita e explícita

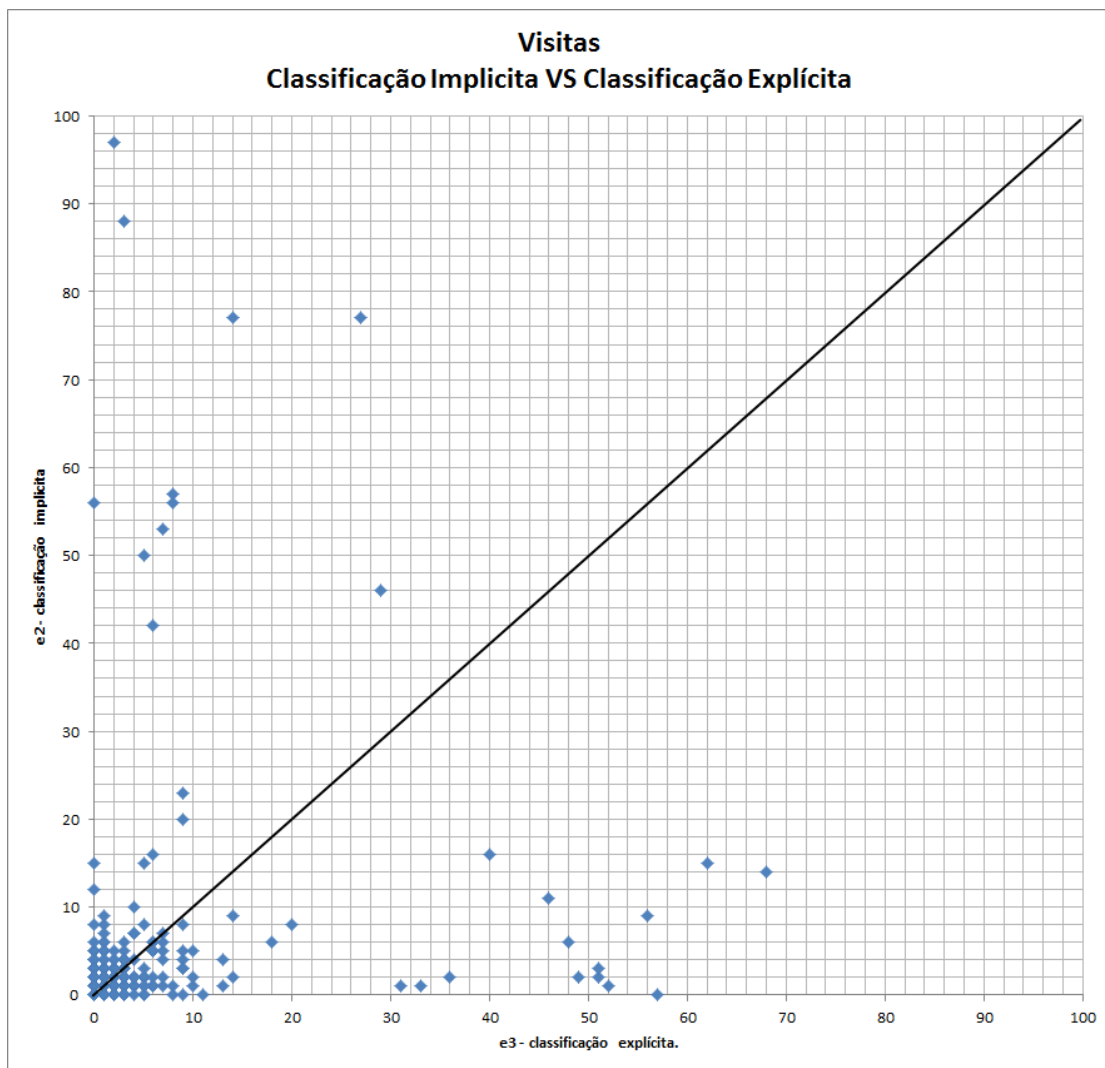


Figura 4-10 – Gráfico de Dispersão (Classificação Implícita VS Explícita)

Na apresenta-se o contributo de cada um dos agentes para as recomendações apresentadas pelo sistema de recomendação multiagente. Em qualquer dos testes é o agente baseado em regras de associação (ARPROV) que mais vezes aparece como vencedor do leilão, ou seja, é o agente cuja proposta é mais vezes apresentada ao utilizador. Regista-se um ligeiro aumento do peso do algoritmo baseado em filtragem colaborativa (CFPROV), principalmente em prejuízo do algoritmo que recomenda os itens mais populares (TTPROV).

	ARPROV		TTPROV		CFPROV	
	IMP	EXP	IMP	EXP	IMP	EXP
% Vezes que o agente ganhou o leilão	56,23%	55,15%	12,75%	9,45%	31,02%	35,40%

Tabela 4-17 – Peso dos agentes de recomendação nas recomendações apresentadas

Para avaliação do desempenho do sistema de recomendação multiagente, vão usar-se também as métricas de avaliação *recall*, *precision* e *F1*, apresentando-se os resultados na Tabela 4-18 e na Tabela 4-19.

Tal como na secção anterior, calcularam-se aquelas métricas de avaliação para o sistema de recomendação multiagente (SRMA) e para os três algoritmos considerados individualmente: O ARPROV refere-se ao algoritmo baseado em regras associativas; o TTPROV diz respeito ao algoritmo que recomenda os dez itens mais populares e o CFPROV implementa um algoritmo baseado em filtragem colaborativa, bem como para o que designamos por melhor caso (MC), como definido anteriormente.

Na Tabela 4-18 consideraram-se todos os registos, mesmo aqueles em que o utilizador segue para uma página Web que não pertence ao conjunto de itens elegíveis para recomendação. Os registos que se referem a finais de sessão não são considerados.

Métricas de avaliação	SRMA		ARPROV		TTPROV		CFPROV		MC	
	IMP	EXP	IMP	EXP	IMP	EXP	IMP	EXP	IMP	EXP
Recall	34,02%	33,21%	30,62%	31,11%	27,62%	23,68%	27,49%	29,84%	35,13%	35,45%
Precision	3,40%	3,32%	3,06%	3,11%	2,76%	2,37%	2,75%	2,98%	3,51%	3,54%
F1	6,19%	6,04%	5,57%	5,66%	5,02%	4,30%	5,00%	5,42%	6,39%	6,44%

Tabela 4-18 – Resultados considerando todos os registos, exceto os fins de sessão

Na Tabela 4-19 consideraram-se apenas os registos em que o utilizador segue para uma página Web pertencente ao conjunto de itens elegíveis para recomendação. Os registos que se referem a finais de sessão não são considerados.

Métricas de avaliação	SRMA		ARPROV		TTPROV		CFPROV		MC	
	IMP	EXP	IMP	EXP	IMP	EXP	IMP	EXP	IMP	EXP
Recall	58,01%	57,23%	52,20%	53,62%	47,10%	40,80%	46,86%	51,42%	59,89%	61,08%
Precision	5,80%	5,72%	5,22%	5,36%	4,71%	4,08%	4,69%	5,14%	5,99%	6,11%
F1	10,55%	10,41%	9,49%	9,75%	8,56%	7,42%	8,52%	9,35%	10,89%	11,11%

Tabela 4-19 – Resultados considerando apenas os itens elegíveis para recomendação

O dado mais significativo que ressalta das Tabela 4-18 e Tabela 4-19 é, mais uma vez, a similaridade dos resultados obtidos em ambas as versões do sistema. Um outro aspeto a registar é uma melhoria de cerca de 5% no desempenho do algoritmo baseado em filtragem colaborativa, enquanto o agente TTPROV tem um decréscimo de cerca de 7%.

5. Conclusões e Trabalho Futuro

O trabalho de investigação desenvolvido no âmbito desta dissertação teve como base o sistema de recomendação multiagente AMAAFWA desenvolvido por Morais (2013) e consistiu na sua adaptação para funcionamento *online*.

Na sua tese de doutoramento, Morais (2013) apresentou um sistema de recomendação baseado numa abordagem multiagente, em que agentes inteligentes autónomos, implementando diferentes técnicas e algoritmos de recomendação, competem entre si para proporcionar as melhores recomendações aos visitantes de um sítio Web.

Morais (2013) formula um conjunto de questões de investigação, procedendo a um conjunto de testes *offline*, na procura de respostas para essas questões e para avaliar em que medida os resultados obtidos se conformam com a hipótese formulada, de que uma abordagem multiagente baseada no mercado (*market-based*) melhora a capacidade preditiva duma combinação de algoritmos de recomendação.

Nas suas conclusões, Morais (2013) considera que apesar de a solução multiagente proposta não ter tido sucesso em todas as situações, se podem considerar positivos os resultados globais obtidos. Refere ainda que o sistema multiagente de recomendação foi capaz de, na maioria das situações, recomendar itens com melhores resultados que os dos algoritmos

individuais e, mesmo nos casos em que tal não aconteceu, a qualidade das recomendações geradas pelo sistema multiagente era similar à obtida pelo melhor dos algoritmos individuais.

5.1 Respostas às questões de investigação formuladas

O trabalho de investigação desenvolvido teve como propósito procurar respostas para as três questões de investigação formuladas no capítulo 1, a saber:

1. *Poderá o sistema de recomendação multiagente AMAAFWA (Morais, et al., 2012), em funcionamento online, ser capaz de disponibilizar ao utilizador a informação que este procura, em tempo real e de forma satisfatória?*
2. *Poderá esse sistema de recomendação multiagente ser capaz de potenciar os objetivos do sítio Web em que se insere?*
3. *Poderá um sistema de recomendação multiagente, com agentes baseados em diferentes algoritmos de recomendação, apresentar um melhor desempenho que um sistema de recomendação baseado num único algoritmo de recomendação?*

Para tentar responder às três questões acima, vamos socorrer-nos dos resultados dos testes apresentados e discutidos no capítulo 4.

Questão 1: Poderá o sistema de recomendação multiagente AMAAFWA (Morais, et al., 2012), em funcionamento online, ser capaz de disponibilizar ao utilizador a informação que este procura, em tempo real e de forma satisfatória?

Um sistema de recomendação tem como um dos objetivos principais maximizar a satisfação do utilizador, providenciando recomendações que lhe sejam úteis e proporcionando-lhe uma melhoria da experiência de navegação.

No caso do sistema de recomendação multiagente AMAAFWA, pode inferir-se a satisfação do utilizador, comparando o tempo de permanência dos utilizadores no *sítio Web* com e sem o sistema de recomendação a apresentar as recomendações para poderem ser seguidas. Saber se as recomendações que são propostas pelo sistema o são em tempo e de forma satisfatória, é também um indicador de satisfação do utilizador.

Com base nos resultados apresentados e discutidos no capítulo 4, constata-se que o utilizador tende a permanecer por mais tempo no *sítio Web* quando o sistema de recomendação está ativo e a apresentar as recomendações aos utilizadores. De facto, analisando os dados da Tabela 4-7 constata-se um aumento no número de pedidos por sessão de aproximadamente

45%, sendo esse aumento ainda mais significativo, cerca de 92%, quando consideramos o número de fotos vistas por sessão.

Relativamente ao comportamento dos utilizadores face às recomendações que lhe foram sugeridas, se atendermos aos dados da Tabela 4-10, verifica-se que com o sistema de recomendação a não apresentar as recomendações aos utilizadores (em modo RECS_OFF), 19,91% das páginas visitadas pelos utilizadores seriam recomendadas pelo sistema. Sendo razoável assumir esse valor como o valor mínimo exetável de alcançar com o sistema em funcionamento pleno, isto é, com o sistema a apresentar as suas recomendações aos utilizadores (em modo RECS_ON), pode considerar-se que os 50,44% obtidos representam uma resposta bastante positiva dos utilizadores à qualidade das recomendações apresentadas.

Quanto ao tempo de resposta do sistema de recomendação, com um tempo médio de resposta de 552 milissegundos e 82,13% dos pedidos respondidos em menos de 600 milissegundos, pode considerar-se que o sistema de recomendação responde em tempo adequado ao utilizador.

Em face do exposto pode assim considerar-se que o sistema de recomendação multiagente AMAAFWA é capaz de disponibilizar ao utilizador a informação que este procura, em tempo real e de forma satisfatória.

Questão 2: Poderá esse sistema de recomendação multiagente ser capaz de potenciar os objetivos do sítio Web em que se insere?

Esta questão está em muito ligada à questão anterior, pois só com a satisfação do utilizador será possível potenciar os objetivos que o sítio Web se propõe alcançar.

Para além de procurar maximizar a satisfação dos utilizadores, proporcionando-lhes recomendações úteis, um sistema de recomendação, quando integrado num *sítio Web*, deve também ser capaz de potenciar os objetivos desse sítio Web, isto é, a satisfação do utilizador deve traduzir-se numa mais-valia para o proprietário do sítio Web, seja aumentando o volume de vendas, caso se trate de uma loja *online*, seja aumentando a visibilidade da oferta de produtos de uma empresa, ou qualquer outro propósito que o sítio Web se proponha alcançar.

No caso do sítio Web 1000 Palavras (www.1000palavras.pt), que serviu de base aos testes *online* do sistema de recomendação multiagente AMAAFWA, o seu principal propósito é a divulgação das suas fotos.

Assim, considerando que, com o sistema a apresentar as suas recomendações aos utilizadores (em modo RECS_ON), o número de fotos vistas passa de 47,33% para 62,66% e que se regista um aumento de cerca de 92% no número de fotos vistas por sessão, pode inferir-se que o sistema de recomendação multiagente é capaz de potenciar os objetivos do sítio Web em que se insere.

Questão 3: Poderá um sistema de recomendação multiagente com agentes baseados em diferentes algoritmos de recomendação, apresentar um melhor desempenho que um sistema de recomendação baseado num único algoritmo de recomendação?

Esta questão pode considerar-se a questão central a investigar no âmbito da presente dissertação, estando a mesma relacionada com a hipótese formulado por Morais (2013), de que uma abordagem multiagente baseada no mercado (*market-based*) melhora a capacidade preditiva de uma combinação de algoritmos de recomendação.

Já atrás referimos que nos testes *offline* efetuados por Morais (2013) o sistema multiagente de recomendação foi capaz de recomendar itens com melhores resultados que os dos algoritmos individuais na maioria das situações e, mesmo nos casos em que tal não aconteceu, a qualidade das recomendações geradas pelo sistema multiagente era similar à obtida pelo melhor dos algoritmos individuais.

Concluídos os trabalhos de adaptação e integração no sítio Web 1000 Palavras (www.1000palavras.pt) descritos no capítulo 3.6, procedeu-se ao teste do sistema de recomendação multiagente AMAAFWA em funcionamento *online*, através da realização dos testes descritos na secção 4.1.

Os testes decorreram em duas fases, na primeira o propósito foi testar o sistema tal como desenvolvido por Morais (2013), na segunda fase foi introduzida uma alteração no sistema, descrita na secção 3.6.3, de modo a testar o seu desempenho baseado numa classificação explícita dos itens por parte dos utilizadores.

Os resultados obtidos na primeira fase de testes, apresentados e discutidos na secção 4.2, permitem concluir que, quando consideramos o sistema de recomendação multiagente no seu funcionamento pleno, isto é, funcionamento *online* e a apresentar aos utilizadores as recomendações geradas a cada pedido do utilizador, a solução multiagente obtém melhores resultados que os obtidos pelos algoritmos individuais.

Quanto aos resultados obtidos na segunda fase de testes, pode concluir-se que, para o caso em estudo, a introdução no sistema de um mecanismo de classificação explícita dos itens por

parte dos utilizadores não tem como consequência um acréscimo no desempenho do sistema de recomendação multiagente. Importa, no entanto, referir que, apesar de esta conclusão dever ser interpretada tendo em consideração as características do sítio Web 1000 Palavras (www.1000palavras.pt) e o tipo de classificação explícita usada no teste, não se pode considerar um resultado surpreendente, em face do que referem Schafer, et al. (2006), de que, em alguns domínios, modelos baseados em informação implícita podem mesmo conduzir a resultados mais precisos que os obtidos com modelos baseados em informação explícita.

De qualquer modo, é de realçar que os resultados globais obtidos com o sistema baseado em informação explícita, estando em linha com os resultados obtidos com o sistema baseado em informação implícita, como originalmente concebido por Morais (2013), vêm reforçar o que já se referiu relativamente às três questões formuladas e para as quais procuramos respostas no âmbito da presente dissertação.

Assim, como conclusão final dos trabalhos desenvolvidos, pode inferir-se que o sistema de recomendação multiagente AMAAFWA é capaz de contribuir para a satisfação do utilizador, ao providenciar-lhe recomendações que lhe são úteis; é capaz de potenciar os objetivos a que o sítio Web que acolhe o sistema de recomendação se propõe e é capaz de apresentar um melhor desempenho que um sistema de recomendação baseado num único algoritmo de recomendação.

5.2 Trabalho futuro

O trabalho desenvolvido no âmbito da presente dissertação centrou-se na realização de testes *online* ao sistema de recomendação multiagente AMAAFWA, testes esses já sugeridos por Morais (2013) na sua tese de doutoramento como trabalho futuro de interesse a realizar. Ainda no âmbito desta dissertação, introduziu-se uma alteração no sistema de modo a considerar também a opinião explícita dos utilizadores acerca dos itens.

Assim, para trabalho futuro entende-se ser importante manter o sugerido por Morais (2013), a saber:

- Testar outros tipos de licitação e de negociação entre os agentes de recomendação.
- Preparar o sistema multiagente para testar, *online*, agentes baseados noutros algoritmos de recomendação.

Considera-se também importante fazer mais testes *online*, seja com o sítio Web 1000 Palavras (www.1000palavras.pt), seja com outros sítios Web. Para além de terem o propósito de confirmar os resultados que vêm sendo obtidos, os testes devem também servir para ajudar a encontrar novas soluções para os problemas que se vão encontrando de modo a introduzir melhorias no sistema de recomendação multiagente.

Também de interesse futuro é o teste de outros tipos de classificação explícita, introduzindo por exemplo escalas de classificação de 0 a 5 em vez do simples “gosto” usado no teste realizado no âmbito da presente dissertação. Este trabalho deve ser feito não só para o sítio Web 1000 Palavras (www.1000palavras.pt), mas também para sítios Web com características e propósitos diferenciados.

Assim, podemos resumir o seguinte conjunto de áreas de intervenção que no futuro podem ser importantes no estudo do sistema de recomendação multiagente AMAAFWA e no tipo de abordagem multiagente apresentados por Morais (2013):

- Proceder a mais testes *online* com o sítio Web 1000 Palavras (www.1000palavras.pt).
- Testar outros tipos de classificação explícita dos itens.
- Testar outros tipos de licitação e de negociação entre os agentes de recomendação.
- Preparar o sistema multiagente para testar, *online*, agentes baseados noutros algoritmos de recomendação.
- Proceder a testes com outros sítios Web.

6. Referências Bibliográficas

- 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, VOL. 17, NO. 6* (pp. 734-749). IEEE.
- Agrawal, R., Imielinski, T., & Swami, A. (1993). Mining Association Rules between Sets of Items in Large Databases. *ACM SIGMOD International Conference on Management of Data* (pp. 207-216). Washington: ACM Press.
- Albayrak, S., Wollny, S., Varone, N., Lommatzsch, A., & and Milosevic, D. (2005). Agent technology for personalized information filtering: the pia-system. *Proceedings of the 2005 ACM symposium on Applied computing* (pp. 54-59). New York: ACM Press.
- Ardissono, L., Goy, A., Petrone, G., & Segnan, M. (2005). A multi-agent infrastructure for developing personalized web-based systems. *ACM Trans. Inter. Tech 5 (1)* (pp. 47-69). ACM.
- Balabanovic, M., & Shoham, Y. (1997). Content-Based, Collaborative Recommendation. *COMMUNICATIONS OF THE ACM, Vol. 40, n°3*, 66-72.
- Breese, J. S., Heckerman, D., & Kadie, C. (1998). Empirical analysis of predictive algorithms for collaborative filtering. *Proceedings of the Fourteenth conference on Uncertainty in artificial intelligence (UAI'98)* (pp. 43-52). San Francisco, CA, USA: Morgan Kaufmann Publishers Inc.
- Brooks, R. A. (1991). Intelligence without reason. *Proceedings of the Twelfth International Joint Conference Artificial Intelligence (IJCAI-91)*569-595. Sydney, Australia.
- Cooley, R., Mobasher, B., & Srivastava, J. (1999). Data Preparation for Mining World Wide Web Browsing Patterns. *Knowledge and Information Systems Vol 1(1)*, 5-32.
- Coutinho, C., Sousa, A., Dias, A., Bessa, F., Ferreira, M. J., & Vieira, S. (2008). Investigação-Ação - Metodologia preferencial nas práticas educativas. *Psicologia, Educação e Cultura, Vol. XIII, n° 2*, 455-479. Obtido em 02 de 01 de 2013 - 20:50, de http://faadsaze.com.sapo.pt/7_caracteristicas.htm

- Franklin, S., & Graesser, A. (Springer-Verlag de 1996). Is it an Agent, or just a Program?: A Taxonomy for Autonomous Agents. *Proceedings of the Third International Workshop on Agent Theories, Architectures, and Languages*.
- Gilbert, D., Aparicio, M., Atkinson, B., Brady, S., Ciccarino, J., Grosz, B., . . . Wilson, L. (1995). IBM intelligent agent strategy. White paper. IBM Corporation.
- Goldberg, D., Nichols, D., Oki, B. M., & Terry, D. (1992). Using collaborative filtering to weave an information tapestry. *Communications of ACM*, vol. 35, no. 12, 61–70.
- Guo, G. (2012). Resolving data sparsity and cold start in recommender systems. *Proceedings of the 20th international conference on User Modeling, Adaptation, and Personalization (UMAP'12)* (pp. 361-364.). Berlin, Heidelberg: Springer-Verlag.
- Herlocker, J. L., Konstan, J. A., Borchers, A., & Riedl, J. (1999). An algorithmic framework for performing collaborative filtering. *Proceedings of the 22nd annual international ACM SIGIR conference on Research and development in information in information retrieval (SIGIR '99)* (pp. 230-237). New York, NY, USA,: ACM.
- Herlocker, J. L., Konstan, J. A., Terveen, L. G., & Riedl, J. T. (2004). Evaluating Collaborative Filtering Recommender Systems. *ACM Transactions on Information Systems*, 22 - n° 1, 5–53.
- Huang, Z., Chen, H., & Zeng, D. (2004). Applying associative retrieval techniques to alleviate the sparsity problem in collaborative filtering. *ACM Transactions on Information Systems (TOIS) Volume 22 Issue 1*, (pp. 116-142.). New York, NY, USA .
- Jannach, D., Zanker, M., Felfernig, A., & Friedrich, G. (2011). *Recommender Systems: An Introduction*. New York: Cambridge University Press.
- Jennings, N. R. (Sep de 1999). On agent-based software engineering. *Artificial Intelligence* 117 (2000) 277–296.
- Jennings, N. R., Sycara, K., & Wooldridge, M. (1998). A Roadmap of Agent Research and Development. *Autonomous Agents and Multi-Agent Systems*, 1, 275–306.
- Linden, G., Smith, B., & York, J. (2003). Amazon.com recommendations: item-to-item collaborative filtering, *Internet Computing*, IEEE 7 (2003), no. 1, 76–80. *Internet Computing*, IEEE 7 n° 1, 76-80.

- Maes, P. (1991). The Agent Network Architecture (ANA). *SIGART Bulletin, Volume2 n.4:115-120*.
- Marcos, A. F. (2012). Duas perspetivas sobre ciência: Positivismo e Interpretativismo. Apresentação no âmbito da Unidade Curricular "Seminário de Investigação em Tecnologia Web" do curso de Mestrado em Tecnologias e Sistemas Web. Universidade Aberta, 2012.
- Miranda, C., & Jorge, A. M. (2008). Incremental collaborative filtering for binary ratings. *Proceeding of: 2008 IEEE / WIC / ACM International Conference on Web Intelligence, WI 2008* (pp. 389-392). Sydney, Austrália: IEEE Computer Society.
- Morais, A. J. (2009). A Multi-Agent approach for Web Adaptation. *7th International Conference on Practical Applications of Agents and Multi-Agent Systems (PAAMS 2009)*, pp. 349-355.
- Morais, A. J. (2013). A Multi-Agent approach for Web Adaptation; Tese de Doutoramento. Faculdade de Engenharia da Universidade do Porto.
- Morais, A. J., Neto, J., Oliveira, E., & Jorge, A. M. (Abril de 2014). Sistema de recomendação Web usando agentes. *Revista de Ciências da Computação, 2013, n° 8*, pp. 24-36.
- Morais, A. J., Oliveira, E., & Jorge, A. M. (2012). A Multi-Agent Recommender System. *9th International Conference on DCAI'12, AISC 151*, 281-288.
- Neto, J., & Morais, A. J. (2014). Multi-Agent Web Recommendations. *Distributed Computing and Artificial Intelligence, 11th International Conference ; Advances in Intelligent Systems and Computing Volume 290* (pp. 235-242). Salamanca: Springer International Publishing.
- Papagelis, M., Plexousakis, D., & Kutsuras, T. (2005). Alleviating the sparsity problem of collaborative filtering using trust inferences. *Proceedings of the Third international conference on Trust Management (iTrust'05)* (pp. 224-239). Berlin, Heidelberg: Springer-Verlag.
- Papagelis, M., Rousidis, I., Plexousakis, D., & Theoharopoulos, E. (2005). Incremental collaborative filtering for highly-scalable recommendation algorithms. *Proceedings of the 15th international conference on Foundations of Intelligent Systems (ISMIS'05)* (pp. 553-561). Berlin, Heidelberg: Springer-Verlag.

- Pazzani, M. J. (1999). A Framework for Collaborative, Content-Based and Demographic Filtering. *Artificial Intelligence Review* 13, 5-6 (pp. 393-408). Norwell, MA, USA : Kluwer Academic Publishers.
- Rashid, A. M., Albert, I., Cosley, D., Lam, S. K., McNee, S. M., Konstan, J. A., & Riedl, J. (2002). Getting to know you: learning new user preferences in recommender systems. *Proceedings of the 7th international conference on Intelligent user interfaces (IUI '02)* (pp. 127-134). New York, NY, USA: ACM.
- Reis, L. P. (Julho de 2003). Coordenação em Sistemas Multi-Agente: Aplicações na Gestão Universitária e Futebol Robótico (Coordination in Multi-Agent Systems: Applications in University Management and Robotic Soccer). *Tese de Doutorado*. Faculdade de Engenharia da Universidade do Porto
- Resnick, P., & Varian, H. R. (1997). Recommender Systems. *Communications of the ACM*, Vol 40, n° 3, 56-58.
- Russell, S., & Norvig., P. (1995). *Artificial Intelligence: A Modern Approach*. . Saddle River, NJ: Prentice-Hall.
- Sarwar, B., Karypis, G., Konstan, J., & Riedl, J. (2001). Item-based collaborative filtering recommendation algorithms. *Proceedings of the 10th international conference on World Wide Web (WWW '01)* (pp. 285-295). New York, NY, USA: ACM.
- Schafer, J., Frankowski, D., Herlocker, J., & Sen, S. (2006). Collaborative Filtering Recommender Systems. In P. Brusilovsky, A. Kobsa, & W. Nejdl (Edits.), *The Adaptive Web* (pp. 291 - 394). Springer Verlag.
- Wei, Z. A., Moreau, L., & Jennings, N. R. (2005). A Market-Based Approach to Recommender Systems. *ACM Transactions on Information Systems*, Vol. 23, No. 3, (pp. 227-266). New York: ACM.
- Wooldridge , M., & Jennings, N. (Jun de 1995). *Intelligent Agents: Theory and Practice*. Obtido em 23 de Abril de 2012, de <http://www.csc.liv.ac.uk>: <http://www.csc.liv.ac.uk/~mjw/pubs/ker95/ker95-html.html>
- Wooldridge, M. (2009). *An Introduction to MultiAgent Systems, Second Edition*. Wiley.
- Wooldridge, M., & Jennings, N. (Jun de 1995). *Intelligent Agents: Theory and Practice*. Obtido em 23 de Abril de 2012, de <http://www.csc.liv.ac.uk>: <http://www.csc.liv.ac.uk/~mjw/pubs/ker95/ker95-html.html>

Yu, K., Schwaighofer, A., Tresp, V., Xu, X., & Kriege, H.-P. (2004). Probabilistic Memory-Based Collaborative Filtering. *IEEE TRANSACTIONS ON KNOWLEDGE AND DATA ENGINEERING* 16, 1 (pp. 56-69). IEEE.