



# ESTRATÉGIA HÍBRIDA DE RECOMENDAÇÕES NUM GESTOR DE CONTEÚDOS AMPLIADO

*Filipe Montez Coelho Madeira*

Tese apresentada à Universidade de Évora  
para obtenção do Grau de Doutor em Informática

ORIENTADOR (A/ES): *Rui Filipe Cerqueira Quaresma*  
*Salvador Luís de Bethencourt Pinto de Abreu*

ÉVORA, JULHO 2013









# Prefácio

Este documento contém a dissertação intitulada “Estratégia Híbrida de Recomendações num Gestor de Conteúdos Ampliado”, entregue em novembro de 2012 no âmbito do Programa de Doutoramento em Informática do autor, Filipe Montez Coelho Madeira<sup>1</sup>, na Universidade de Évora, em Portugal. O autor é Licenciado em Engenharia de Sistemas e Informática<sup>2</sup> pela Universidade do Minho e Mestre em Engenharia Eletrotécnica e de Computadores pelo Instituto Superior Técnico<sup>3</sup>. Atualmente é Professor Adjunto no Departamento de Informática e Métodos Quantitativos da Escola Superior de Gestão e Tecnologia do Instituto Politécnico de Santarém.

Os orientadores deste trabalho são o Prof. Doutor Salvador Luís de Bethencourt Pinto de Abreu<sup>4</sup>, do Departamento de Informática da Universidade de Évora e o Prof. Doutor Rui Filipe Cerqueira Quaresma<sup>5</sup>, do Departamento de Gestão da Universidade de Évora.

---

<sup>1</sup> filipe.madeira@esg.ipsantarem.pt

<sup>2</sup> Conclusão em 1992.

<sup>3</sup> Conclusão em 1997.

<sup>4</sup> spa@di.uevora.pt

<sup>5</sup> quaresma@uevora.pt

# Agradecimentos

Ao longo deste trabalho foram várias as pessoas que me apoiaram, sobre diferentes formas, quer motivando, como lançando ideias, lendo e corrigindo alguns dos textos que fui produzindo, compreendendo e justificando as minhas ausências, contribuindo na experimentação e ouvindo-me...

Pela motivação e encorajamento, pelos momentos de que nos vimos privados, pelas coisas que deixámos de fazer, pela paciência que mostraram ao longo de muito tempo, quero agradecer à minha família, em particular à minha mulher, Xana e aos meus filhos, João e Miguel.

Aos meus amigos, com os quais partilhei algumas ideias e que contribuíram com sugestões e com o seu apoio.

Aos meus orientadores, que sempre me apoiaram e de forma inteligente me conduziram na investigação, sugerindo o que fazer e como o fazer. É grande a consideração pelo tempo que dedicaram a este trabalho e pela qualidade das suas contribuições.

À minha instituição, Instituto Politécnico de Santarém e em particular à Escola Superior de Gestão e Tecnologia, que me apoiou financeiramente, tendo facilitado a organização do meu tempo para esta investigação e compreendendo as minhas prioridades. O agradecimento engloba obviamente os seus colaboradores. Aos meus alunos, em particular aos que colaboraram diretamente nesta experimentação.

A todos, o meu OBRIGADO.

# Resumo

O objetivo principal desta dissertação é propor um modelo de recomendação de conteúdos de aprendizagem num ambiente formal, típico do Ensino Superior, sobre um gestor de conteúdos ampliado, onde os alunos avaliam e publicam conteúdos.

As principais contribuições deste trabalho são:

1. A adição de conteúdos pelos alunos é por eles bem aceite;
2. Modelo de recomendações híbrido, em cascata, com três filtragens baseadas em regras de precedência, duração de estudo e avaliação das atividades de aprendizagem;
3. Formulação de similaridade entre alunos, que valoriza os melhores alunos e o passado recente de conteúdos selecionados por cada aluno;
4. Implementação, experimentação e avaliação de um protótipo baseado no modelo proposto. A avaliação mostrou que o desenvolvimento deste tipo de sistemas permite aos alunos terem experiências únicas de aprendizagem com sequenciamentos de conteúdos adequados aos seus perfis.

Destacamos a contribuição para esta investigação da revisão de conceitos e literatura relacionada.

Palavras-Chave: sistemas de recomendação personalizados, filtragem colaborativa, gestor de conteúdos, aprendizagem formal, sequenciamento, perfil do aluno, tecnologia avançada de aprendizagem.

# Title

A Hybrid Recommender Strategy on an Expanded Content Manager

## Abstract

The main objective of this thesis is to propose a model for personalized recommendation of learning activities, directed to learners, in a formal learning context. We suggest that learners can publish some useful contents and that they should rate them.

The main contributions of this work are:

1. The addition of new content was well accepted, by learners;
2. Hybrid recommendations model in cascade, with three filtering techniques, based on precedence rules, duration of study and classification of learning activities;
3. New formulation of similarity between students, which gives value to the best students and recent past of content selected by each student.
4. A prototype has been implemented and real experimentation was carried out during two months. It showed that such systems help learners to diversify their learning paths and experiences, increase useful collaboration and support making decisions.

We also highlight the contribution of the revision of related work.

*Keywords:* personalized recommender systems, collaborative filtering, collaborative formal learning, content manager, sequencing, learner profile, technology enhanced learning.

# Índice

<b>LISTA DE FIGURAS.....</b>	<b>X</b>
<b>LISTA DE TABELAS.....</b>	<b>XII</b>
<b>GLOSSÁRIO .....</b>	<b>XIII</b>
<b>CAPÍTULO 1.....</b>	<b>1</b>
<b>INTRODUÇÃO .....</b>	<b>1</b>
<b>1.1 ENQUADRAMENTO .....</b>	<b>1</b>
<b>1.2 OBJETIVO E CONTRIBUIÇÕES PREVISTAS .....</b>	<b>4</b>
<b>1.3 ESTRUTURA DA DISSERTAÇÃO.....</b>	<b>6</b>
<b>CAPÍTULO 2.....</b>	<b>7</b>
<b>TECNOLOGIAS E SISTEMAS DE SUPORTE À APRENDIZAGEM COLABORATIVA .....</b>	<b>7</b>
<b>2.1 O PAPEL DAS TECNOLOGIAS NO ENSINO.....</b>	<b>8</b>
2.1.1 <i>Recursos Educativos e Repositórios .....</i>	<i>14</i>
2.1.2 <i>Sistemas de Gestão de Aprendizagem.....</i>	<i>18</i>
2.1.3 <i>Redes de Aprendizagem .....</i>	<i>23</i>
2.1.4 <i>Web 2.0 no Ensino.....</i>	<i>25</i>
2.1.5 <i>Mobilidade no Ensino .....</i>	<i>36</i>
2.1.6 <i>Aprendizagem na “Nuvem” .....</i>	<i>37</i>
<b>2.2 SISTEMAS ADAPTATIVOS.....</b>	<b>41</b>
2.2.1 <i>Sequenciação e Navegação de Conteúdos.....</i>	<i>42</i>
2.2.2 <i>Modelos Adaptativos aplicados ao Ensino .....</i>	<i>45</i>

<b>CAPÍTULO 3</b> .....	<b>53</b>
<b>TEMAS E TRABALHOS RELACIONADOS</b> .....	<b>53</b>
<b>3.1 SISTEMAS DE RECOMENDAÇÃO</b> .....	<b>53</b>
3.1.1 <i>Primeiros Sistemas</i> .....	53
3.1.2 <i>Conceitos relevantes de outras Áreas</i> .....	56
3.1.3 <i>Conceitos e Formulação</i> .....	59
3.1.4 <i>Domínios de Aplicação</i> .....	63
3.1.5 <i>Motivações</i> .....	63
3.1.6 <i>Funções</i> .....	64
3.1.7 <i>Dados</i> .....	66
<b>3.2 CLASSIFICAÇÃO DOS SISTEMAS DE RECOMENDAÇÃO</b> .....	<b>68</b>
3.2.1 <i>Filtragem Colaborativa</i> .....	70
3.2.2 <i>Filtragem Baseada em Conteúdos</i> .....	84
3.2.3 <i>Limitações das diferentes abordagens</i> .....	93
3.2.4 <i>Outros Tipos de Sistemas de Recomendação</i> .....	98
3.2.5 <i>Explicações em Sistemas de Recomendação</i> .....	102
3.2.6 <i>Novos Desenvolvimentos</i> .....	105
<b>3.3 SISTEMAS DE RECOMENDAÇÃO APLICADOS AO ENSINO</b> .....	<b>107</b>
3.3.1 <i>Domínio de Aplicação</i> .....	108
3.3.2 <i>Funções</i> .....	109
3.3.3 <i>Técnicas de Recomendação</i> .....	111
3.3.4 <i>Exemplos</i> .....	111
<b>3.4 AVALIAÇÃO DOS SISTEMAS DE RECOMENDAÇÃO</b> .....	<b>114</b>
3.4.1 <i>Dimensão Técnica</i> .....	115
3.4.2 <i>Outras Dimensões da Avaliação</i> .....	117
3.4.3 <i>Avaliação dos Sistemas de Recomendação Aplicados ao Ensino</i> .....	120
<b>CAPÍTULO 4</b> .....	<b>123</b>
<b>O MODELO PROPOSTO</b> .....	<b>123</b>
<b>4.1 O PROBLEMA</b> .....	<b>123</b>
<b>4.2 METODOLOGIA</b> .....	<b>128</b>
<b>4.3 GESTOR DE CONTEÚDOS AMPLIADO</b> .....	<b>131</b>
<b>4.4 PERSONALIZAÇÃO DE RECOMENDAÇÕES</b> .....	<b>134</b>

4.4.1	<i>Processo de Recomendação</i> .....	135
4.4.2	<i>Perfis</i> .....	141
4.4.3	<i>Exemplo de Execução</i> .....	143
4.5	<b>ARQUITETURA DA SOLUÇÃO</b> .....	144
4.6	<b>CONSIDERAÇÕES FINAIS SOBRE O MODELO</b> .....	145
<b>CAPÍTULO 5</b>	.....	<b>153</b>
<b>AVALIAÇÃO DO MODELO</b>	.....	<b>153</b>
5.1	<b>IMPLEMENTAÇÃO DO SISTEMA</b> .....	153
5.2	<b>EXPERIMENTAÇÃO</b> .....	157
5.3	<b>AVALIAÇÃO</b> .....	160
5.3.1	<i>Dimensão Técnica</i> .....	160
5.3.2	<i>Outras Dimensões</i> .....	164
5.4	<b>DISCUSSÃO SOBRE OS RESULTADOS</b> .....	166
<b>CAPÍTULO 6</b>	.....	<b>171</b>
<b>CONCLUSÕES E TRABALHO FUTURO</b>	.....	<b>171</b>
6.1	<b>CONCLUSÕES</b> .....	172
6.2	<b>TRABALHO FUTURO</b> .....	175
<b>BIBLIOGRAFIA</b>	.....	<b>177</b>
<b>APÊNDICES</b>	.....	<b>197</b>
<b>APÊNDICE 1 - MODELO DE ESPAÇO VETORIAL COM A PONDERAÇÃO TF-IDF</b>	.....	<b>198</b>
<b>APÊNDICE 2 - MODELO ROCCHIO</b>	.....	<b>199</b>
<b>APÊNDICE 3 – CÁLCULO DA SIMILARIDADE</b>	.....	<b>200</b>
<b>APÊNDICE 4 – CÁLCULO DA ESTIMATIVA DA CLASSIFICAÇÃO</b>	.....	<b>203</b>
<b>APÊNDICE 5 – MÉTRICAS DE AVALIAÇÃO</b>	.....	<b>205</b>
<b>APÊNDICE 6 – QUESTIONÁRIO DE AVALIAÇÃO</b>	.....	<b>210</b>

# Lista de Figuras

Figura 1 - Componentes de um PLE .....	21
Figura 2 - Ferramentas de um PLE.....	22
Figura 3 - O Professor em Rede .....	23
Figura 4 – Efeitos das Regras na Navegação numa Árvore de Atividades (IMS-SS)....	43
Figura 5 - Arquitetura Genérica de Sistemas Hipermedia Adaptativos de Educação ....	48
Figura 6 - Níveis de abstração do processo de Sequenciamento em Sistemas Adaptativos.....	49
Figura 7 - Recomendações personalizadas no <i>site</i> Amazon.com.....	60
Figura 8 - Processo Genérico de Recomendação .....	62
Figura 9 - Avaliações de itens no sítio Amazon.com .....	67
Figura 10 - Uso de 'tags' no sítio Amazon.com.....	68
Figura 11 - Filtragem Colaborativa .....	71
Figura 12 - Filtragem Baseada em Conteúdos.....	84
Figura 13 - Filtragem "Recommended for You" no Amazon.co.....	85
Figura 14 - Item e Perfil do Utilizador .....	88
Figura 15 – Uso da opção “Fix this recommendation” no sítio Amanon.com.....	103
Figura 16 - Uso de 'tags' no <i>Website</i> MovieLens .....	104
Figura 17 - Exemplo do uso de ‘tags’ .....	104
Figura 18 - Factos Relevantes .....	125
Figura 19 - Do Problema às Hipóteses .....	127
Figura 20 - Modelo de Ampliação dos Conteúdos .....	132
Figura 21 - Fases da Publicação de Conteúdos .....	133
Figura 22 - Estratégia Híbrida de Recomendações .....	136

Figura 23 - Painel Perfil do Conteúdo .....	155
Figura 24 - Painel Lista de Recomendações.....	156
Figura 25 - Painel Perfil do Aluno .....	156
Figura 26 - Painel de Edição da Recomendação .....	157
Figura 27- Evolução da MAE (todas as recomendações).....	162
Figura 28 - Evolução da MAE (somente as recomendações 'non cold-start') .....	163

## Lista de Tabelas

Tabela 1 - Pontos fortes e fracos dos LMS.....	20
Tabela 2 - Exemplo de Matriz Utilizador x Item com classificações binárias .....	61
Tabela 3 - Exemplo de Matriz Utilizador x Item com classificações numéricas .....	62
Tabela 4- Classificação dos possíveis resultados de uma recomendação .....	116
Tabela 5 - Lista dos Conteúdos selecionados - Perfis de alunos .....	143
Tabela 6 - Estimação x Seleção das Recomendações.....	161
Tabela 7 - Estimação x Avaliação das Recomendações.....	161

# Glossário

API (Application Programming Interfaces): Livraria de desenvolvimento	16
BC: Baseada em Conteúdos	69
COI (Community of Interest): Comunidade de interesse	25
COP (Community of Practice): Comunidade de prática	24
EEES: Espaço Europeu do Ensino Superior	10
FC: Filtragem Colaborativa	54
IE: Instituição de Ensino	9
IEEE: Institute of Electrical and Electronics Engineers	14
IES: Instituição de Ensino Superior	4
IF (Information Filtering): Área científica que actua sobre a pesquisa de informação	56
IR (Information Retrieval): Área científica sobre a recuperação de informação	46
K-NN (k-nearest neighbor): número k de vizinhos mais próximos	74
LMS (Learning Management System): Sistema de gestão de aprendizagem	19
LO (Learning Object): Objeto de Aprendizagem	14
LOR (Learning Objects Repository): Repositório de objetos de aprendizagem	18
LSI (Latent Semantic Indexing): Indexação semântica latente	58
OER (Open Educational Resource): Recurso educativos aberto	16
PLE (Personal Learning Environment): Ambiente de aprendizagem pessoal	20
PLN (Personal Learning Network): Rede pessoal de aprendizagem	21
RSS (Really Simple Syndication): Mecanismo de sindicância Web	17
SCORM (Sharable Content Object Reference Model): Modelo referencial de partilha de conteúdos	15
SR: Sistema de Recomendação	53
SRBC: Sistemas de Recomendação Baseados em Conteúdos	86
SRFC - Sistema de Recomendação Baseado na Filtragem Colaborativa	73
SVD (Singular Value Decomposition): Decomposição de valor singular	58
TDM (Term-Document Matrix): Matriz de palavras x documentos	58
TIC: Tecnologias de Informação e da Comunicação	9
VSM (Vector Space Model): Modelo de espaço vetorial	57



# Capítulo 1

## Introdução

Este capítulo faz uma introdução ao contexto em que se insere o trabalho e refere os principais aspetos que estiveram na sua origem. Alguns conceitos e referências mencionados neste capítulo serão descritos e apresentados com maior detalhe nos capítulos 2 e 3.

O enquadramento do tema desta dissertação é feito na secção inicial. Na secção seguinte encontram-se os objetivos gerais e específicos associados às questões que formulam o problema que motivou este trabalho. A secção 1.3 descreve a organização dos restantes capítulos deste documento.

### 1.1 Enquadramento

As inovações tecnológicas e a consistente investigação e experimentação de novos métodos e técnicas conduzem a aprendizagem para novos cenários onde a abundância de recursos, o espaço, o tempo e a forma assumem diferentes significados e desenham novos modelos de aprendizagem (Johnson, Adams, & Cummins, 2012).

Com a Internet e com o enorme incremento da digitalização, livros, revistas e jornais eletrónicos têm vindo a substituir os tradicionais formatos em papel. A disponibilização

abundante de recursos educativos, alguns deles de acesso livre, torna-se cada vez mais uma realidade. Muitos dos documentos eletrónicos são hoje oferecidos em diversos dispositivos, integrando informações com diferentes formatos (voz, vídeo, mapa, hiperligações, ...), tornando-os mais valiosos, motivantes e com grande potencial de inovação (OLCOS, 2007).

Com os novos cenários oferecidos pelas inovações tecnológicas, a aprendizagem pode ocorrer em qualquer lugar e a qualquer momento. De facto, a computação em nuvem (*cloud*) facilita o acesso aos recursos (no tempo, no espaço e por múltiplos tipos de dispositivos terminais) e as aplicações e os serviços móveis permitem que as pessoas possam trabalhar, aprender e “estudar em todo o lado e a qualquer hora” (Lehner & Nösekabel, 2002, p. 103).

Com as aplicações sociais, as pessoas possuem maiores redes de relacionamentos, mais fáceis de criar e manter. Os próprios conteúdos eletrónicos são editáveis, anotados, comentados, divididos em secções que podem ser partilhados pelos parceiros das redes sociais de cada um. A aprendizagem em rede fica facilitada (Johnson et al., 2012).

Com a contribuição dos avanços tecnológicos, assiste-se, na área do ensino, a uma tendência de centralização do processo de aprendizagem no próprio aluno. Mais e melhor controlo, pró atividade, dinamismo, reflexão, articulação e flexibilidade são alguns dos aspetos que saem reforçados desta centralização do processo de aprendizagem. Neste modelo, o conhecimento é criado ou construído pelo próprio e não como resultado, essencialmente, da sua transmissão (Seitzinger, 2006), devendo o mesmo, para tal, gerir e controlar a sua própria aprendizagem. Neste ambiente assente na colaboração, na participação social (como fator motivador) e na interatividade entre os vários agentes, a aprendizagem resulta de um processo mais iterativo e evolutivo. Neste modelo centrado no aluno, a participação social, em contexto de grupo e a colaboração surgem como elementos centrais nesta aprendizagem, designada construtivista (Sheng, Siau, & Nah, 2010).

A centralização da aprendizagem no aluno modifica igualmente o papel do professor e das organizações de ensino. Professores e alunos interagem mais, assumem relacionamentos mais próximos, o que lhes permite um trabalho mais multidisciplinar e

colaborativo. Para o professor exige-se que integre as novas tecnologias na sua prática pedagógica e se envolva de forma mais direta na aprendizagem dos seus alunos. Deve ser mais facilitador e funcionar essencialmente como suporte ao processo de aprendizagem/ ensino. Este suporte deve acompanhar os alunos em todas as atividades (para que o aluno possa rever e corrigir as suas ações de forma iterativa), deve ser motivador e orientador (na resolução de problemas mais complexos deve sugerir uma construção de conhecimento por pequenos passos, por exemplo). Esta tendência é observável na dinâmica de mudança a que se assiste nas práticas do ensino, nomeadamente ao nível do Ensino Superior Europeu e em especial após a implementação das medidas do Processo de Bolonha. (Johnson et al., 2012).

A centralização da aprendizagem no aluno é um processo que vem realçar, contudo, as diferenças que deverão existir nas aprendizagens, ou seja, procuram-se aprendizagens personalizadas. Defendemos que este processo deve deixar de ser um problema “*one-size-fits-all*”. Diferentes alunos, com diferentes características, competências, disponibilidades e objetivos, procuram a aprendizagem mais adequada, para cada um deles (Johnson et al., 2012).

Em resumo, quer as inovações tecnológicas, quer os processos de aprendizagem centrados no aluno incentivam a uma personalização da aprendizagem. Para que tal possa acontecer, são necessários alguns requisitos. Propomos que a existência de diferentes conteúdos que contemplem abordagens pedagógicas ajustáveis ao perfil de interesses de cada aluno, assim como diferentes caminhos de aprendizagem (sequenciamento das suas atividades de aprendizagem) que permitam conduzir o aluno aos seus objetivos de aprendizagem, sejam alguns desses requisitos (Madeira, Quaresma, & Abreu, 2012a).

São inúmeros os fatores que influenciam o sequenciamento ótimo de atividades de aprendizagem, para cada aluno. A sua disponibilidade, motivação, a abordagem preferida, os seus conhecimentos prévios e o nível dos mesmos, são apenas alguns desses fatores (Gutiérrez & Pardo, 2007).

Neste contexto, novas tecnologias, novas práticas pedagógicas e novas ferramentas de suporte, que auxiliem o aluno na condução do seu percurso de aprendizagem são necessárias.

## 1.2 Objetivo e contribuições previstas

A preocupação central deste trabalho é a maximização da aprendizagem, num contexto formal, no Ensino Superior, tratando-se por isso de um objetivo de cariz global.

Por contexto formal, consideramos um qualquer curso, módulo ou unidade curricular, enquanto ofertas de ensino habitual das Escolas das Instituições de Ensino Superior (IES). Estas apresentam, normalmente, uma elevada estruturação, os cursos são bem definidos, suportados em currículos aprovados e possuem geralmente sistemas de acreditação que garantem a sua qualidade (Drachsler, Hummel, & Koper, 2009). Os seus ambientes de aprendizagem habituais envolvem interações diretas entre alunos e professores, na sua maior parte presencialmente. São muitas vezes complementadas com o recurso a tecnologias de suporte à aprendizagem, em ambientes de aprendizagem semi-presencial (denominados de *blended-learning* ou *b-learning*), onde é normal existir um conjunto de conteúdos preparados e/ ou sugeridos pelos professores que lecionam um dado módulo (ou unidade curricular) de um curso. Estes conteúdos são tipicamente publicados em sistemas de gestão da aprendizagem (dos quais a plataforma *Moodle* surge como uma das principais escolhas) ou em sítios criados e mantidos na Internet, pelos próprios professores. Estes cenários visam normalmente um específico grupo de alunos (a turma), num dado período de tempo (semestre ou ano letivo). A reutilização destes conteúdos faz-se muitas vezes por replicação e a sua atualização exige uma nova edição, alteração e publicação por parte dos professores. A alteração, melhoria ou inclusão de conteúdos pelos alunos, não existe na maioria das soluções em uso (Madeira et al., 2012a). Um complemento a esta caracterização e uma comparação entre o ensino formal e o ensino não formal surgem descritos na secção 4.1.

Tal como referimos na secção anterior, estamos convictos que a personalização da aprendizagem em torno do aluno não só é uma tendência como uma necessidade,

mesmo em ambiente de ensino formal. A procura de uma solução para este problema tornou-se a finalidade deste projeto.

De entre os vários requisitos necessários para se conseguir obter uma personalização do ensino, o nosso enfoque centrou-se na necessidade de uma maior disponibilização de conteúdos e de diferentes caminhos de aprendizagem, constituindo-se desde já como sendo os objetivos específicos da investigação (Madeira et al., 2012a). Pretende-se encontrar as respostas para as seguintes questões-chave (que deverão constituir as contribuições originais deste trabalho):

- Como incluir outras atividades de aprendizagem (conteúdos, referências para conteúdos ou atividades de aprendizagem), para além dos disponibilizados pelo professor nos habituais sistemas de gestão de aprendizagem, que visem os objetivos de aprendizagem delineados?
- Quais os conteúdos e quais os eventos de aprendizagem que melhor servem os propósitos e as necessidades de cada aluno, em cada momento da sua aprendizagem?

Como respostas a estas questões, formulamos como tese o desenvolvimento de um sistema de gestão de aprendizagem ampliado. Propomos como hipótese a testar para a primeira questão, um sistema de gestão de aprendizagem aberto à adição de outros conteúdos, para além dos que são habitualmente disponibilizados em ensino formal, pelos professores. Para dar resposta a um eventual excesso de conteúdos e para possibilitar ao aluno a seleção dos que lhe possam ser mais adequados, sugerimos a hipótese de usar uma estratégia de recomendações híbrida que combine técnicas de recomendação personalizadas com o perfil de cada aluno. Para efetuarmos a avaliação do modelo proposto desenvolvemos e testámos um protótipo e definimos os correspondentes critérios de avaliação.

## 1.3 Estrutura da dissertação

Em seguida, no capítulo 2, são apresentadas algumas tecnologias e sistemas de suporte à aprendizagem.

No capítulo 3, são apresentados alguns temas e trabalhos relacionados com o projeto desenvolvido, nomeadamente sobre os sistemas de recomendação, que constituem a nossa resposta para a pretendida personalização da aprendizagem, em particular no sequenciamento dos conteúdos de aprendizagem.

No capítulo 4 apresenta-se o modelo proposto, sobre o qual foi desenhado, implementado e avaliado um protótipo, numa situação real no Ensino Superior pelo período de dois meses de um semestre letivo, numa unidade curricular de um curso tecnológico.

No capítulo 5 damos destaque a essa experimentação.

Finalmente, no último capítulo são apresentadas as considerações finais e o trabalho futuro.

## Capítulo 2

# Tecnologias e Sistemas de Suporte à Aprendizagem Colaborativa

O segundo capítulo é dedicado ao estudo das tecnologias e sistemas de suporte à aprendizagem, procurando avaliar e perspetivar algumas opções futuras para o trabalho colaborativo e para a sua adequabilidade ao ensino visando igualmente responder aos interesses de cada aluno.

Na primeira secção efetuamos uma análise geral de alguns conceitos e desenvolvimentos recentes, associados a tópicos que interessam a esta investigação, tais como os conteúdos de aprendizagem, os sistemas que gerem esses conteúdos, os serviços e aplicações colaborativas e o impacto da mobilidade e da computação na nuvem no futuro da aprendizagem. Esta análise permitirá enquadrar as motivações das nossas propostas, designadamente na forma como a gestão de conteúdos poderá ser ampliada, à necessidade de adaptabilidade por partes dos sistemas de gestão de aprendizagem, ao reforço do papel da Internet e dos seus serviços enquanto elementos fundamentais e dinamizadores de uma maior colaboração entre os intervenientes nos processos de aprendizagem, bem como à crescente importância das redes de aprendizagem.

Na segunda secção abordamos os conceitos principais e alguns dos trabalhos relacionados com a adaptabilidade dos sistemas de informação de suporte ao ensino.

## 2.1 O Papel das Tecnologias no Ensino

Estamos a viver transformações fundamentais nas sociedades e nas economias. Durante a última década, o mundo tornou-se cada vez mais interligado. Hoje, a Internet e os seus serviços permitem às empresas, às pessoas e às próprias máquinas uma comunicação imediata. Esta “híper-conectividade” está a mudar de forma profunda os relacionamentos entre os indivíduos, entre os consumidores e as empresas, entre os cidadãos e os seus governos (Dutta & Bilbao-Osorio, 2012). São inúmeros os desafios e as oportunidades, bem como os riscos (direitos individuais, privacidade, segurança, cibercrime, acesso e disponibilidade à informação, entre outros). A convergência entre as tecnologias da informação e as tecnologias da comunicação é crescente na *cloud*, nas redes de interligação e nos dispositivos. Os benefícios para o utilizador são prometedores: poder usar um qualquer dispositivo, a qualquer hora e em qualquer lugar para aceder aos serviços ou à informação pretendidos.

Também na educação as transformações têm vindo a ocorrer. Desde o início dos anos 80 que muitos países têm vindo a investir em tecnologia no suporte ao ensino, designadamente dispositivos, serviços, aplicações e mais recentemente em conteúdos digitais. Segundo (Dutta & Bilbao-Osorio, 2012), poucas certezas existem sobre o impacto desses investimentos na qualidade da aprendizagem e, mais especificamente, sobre quais os usos particulares das tecnologias que melhor resultam num aumento do desempenho dos estudantes. No entanto, a sua adoção tem sido crescente no passado recente e perspectiva-se ainda mais intensa nos próximos anos.

De acordo com o Projeto *Horizon* (Johnson et al., 2012), as tendências chave no âmbito das tecnologias emergentes capazes de provocar impacto no ES, constantes do relatório de 2012, destacam:

- A abundância de recursos educativos e as redes de relacionamentos acessíveis pela Internet estão a contribuir para uma mudança do papel do professor e das Instituições de Ensino (IE);
- A reinvenção do computador está a privilegiar a interatividade com a resposta ao toque e num futuro próximo com gestos, voz ou movimentos;
- Os paradigmas da aprendizagem estão a mudar para incluir aprendizagem via Internet, em modelos híbridos e fortemente colaborativos, envolvendo dinâmicas de grupos suportadas em aplicações e serviços colaborativos;
- O aluno dispõe cada vez mais de tecnologia própria (dispositivos e aplicações) sofisticada;
- Professores e alunos adotam novas tecnologias para obterem uma melhor colaboração e orientam o seu trabalho conjunto procurando definir soluções para problemas reais;
- Disponibilização de conteúdos vídeo e áudio constituem um forte suporte ao ensino presencial, tanto na preparação das aulas como no estudo posterior;
- Cada vez mais o aluno pretende aprender e estudar em todo o lado e a qualquer hora, ao seu próprio ritmo e dentro da sua disponibilidade, passando a assumir uma maior responsabilidade pela sua aprendizagem, ou seja, a aprendizagem tende a ser cada vez mais centrada no aluno;
- As tecnologias, aplicações e serviços que usamos serão cada vez mais baseadas na *cloud*, sendo cada vez mais irrelevante o local onde o trabalho fica armazenado e se beneficia a disponibilidade e a utilização de múltiplos dispositivos para acesso à informação.

No mesmo relatório (Johnson et al., 2012), são enunciadas várias tecnologias a ter em consideração no ES nos próximos anos:

- Num espaço temporal de mais curto termo (1 ano):
  - O desenvolvimento de aplicações para dispositivos móveis como os *smartphones* e os *tablet* estão a merecer a atenção das IES mais inovadoras na utilização das Tecnologias de Informação e da Comunicação (TIC) para suporte ao ensino;
- No médio termo (até 3 anos):

- A aprendizagem suportada em jogos trará uma maior motivação aos alunos no seu processo de aprendizagem e a utilização de ferramentas e técnicas analíticas poderão ajudar a adequar o processo de aprendizagem, tornando-o dinâmico e mais personalizado;
- Num horizonte temporal de 5 anos:
  - Deverão começar a surgir dispositivos “inteligentes” interligados pela Internet que permitirão a troca de informações entre si e com os utilizadores, facilitando o processo de aprendizagem em inúmeras situações e espaços (laboratórios, salas de aulas);
  - A computação gestual é outra tecnologia prometedora que permitirá o uso de aplicações que tiram proveito de dispositivos que usam os gestos faciais, movimentos, voz e o contacto para implementarem as suas funcionalidades.

Dentro do espaço educação, o próprio ES não é alheio a estas grandes mudanças. A par dos desenvolvimentos tecnológicos as mudanças têm igualmente acontecido na própria organização do ES. Na Europa, a Convenção de Lisboa em 1997 desencadeou uma transformação de extraordinária amplitude em todo o Ensino Superior Europeu, tendo tido o seu ponto alto na Declaração de Bolonha, em 1999. Um dos principais objetivos dessa transformação visa a criação do Espaço Europeu do Ensino Superior (União Europeia, 2010). Em Portugal, nestes últimos anos, um conjunto alargado de ações e de legislação têm conduzido todo esse processo de reforma/ transformação. Embora com ritmos diferentes, desde o passado recente todas as IES portuguesas têm vindo a passar por desenvolvimentos com grande significado para a sua organização e funcionamento, dos quais se destacam:

- A adequação dos cursos ao estabelecido no Processo de Bolonha trouxe grandes mudanças na organização curricular, com a adoção do Sistema Europeu de Créditos Curriculares (ECTS - baseado na globalidade do trabalho de formação do estudante, possibilitando a sua acumulação e a transferência a níveis nacional e internacional) e a implementação de diplomas e suplementos dos graus académicos em várias línguas (pelo menos duas), descritos no Dec. Lei nº 42/2005 e no Dec. Lei nº 74/2006;

- A alteração do seu regime jurídico descritos no Dec. Lei nº 62/2007 permitiu o desenvolvimento de novos modelos de gestão e de financiamento;
- O alargamento da base social de recrutamento dos estudantes (com especial relevo para o acesso a alunos com mais de 23 anos e com experiência profissional, de acordo com o Dec. Lei nº 64/2006) e o aumento da oferta formativa (cursos de especialização tecnológica, de acordo com o Dec. Lei nº 88/2006);
- Maior relevância para os aspetos da qualidade e da gestão de desempenho, visando o estabelecimento de padrões de referência no desempenho das IES e para os resultados académicos, num contexto global, concordantes com o Dec. Lei nº 38/2007.

Em Maio de 1998 em Sorbonne foi emitida declaração conjunta sobre a “Harmonização da Arquitetura do Sistema Europeu do Ensino Superior” (União Europeia, 1998) que estabeleceu novos desafios, trouxe novas necessidades e expectativas às IES, e veio dinamizar:

- Uma maior mobilidade internacional de estudantes (que pretendem manter uma visão coerente da sua informação);
- Uma maior cooperação entre instituições, nacionais ou estrangeiras, por exemplo na realização de ciclos de estudos em conjunto;
- Mais investigação, em rede e internacional;
- O aumento da utilização da componente de ensino à distância.

Por todos os aspetos, fatores e tendências já referidos, melhor se percebe a grande pressão existente quer nos professores, quer nas suas instituições no sentido da adoção das inovadoras tecnologias. Essa adoção envolve as práticas pedagógicas, reforçando a necessidade do uso de conteúdos permanentemente atualizados (baseados nos mais inovadores suportes tecnológicos) e dos serviços mais recentes (por exemplo, a forma como os professores e alunos se relacionam e como as instituições comunicam com os seus alunos, funcionários e professores recorrem geralmente a aplicações e serviços disponibilizados na Internet), o desenho de conteúdos pedagógicos para os diversos

formatos e suportes, novas metodologias de avaliação e variados canais de distribuição para os conteúdos, entre outros aspetos.

Com a Internet, a disponibilização abundante de recursos educativos tornou-se uma realidade. Com as aplicações sociais, as redes de relacionamentos ficaram maiores e mais fáceis de criar e manter. Com a *cloud*, tornou-se mais fácil aceder aos recursos, no tempo, no espaço e utilizando múltiplos dispositivos terminais (Johnson et al., 2012). A Internet também veio impulsionar o ensino à distância, que está a assumir uma importância crescente nas IES, quer como complemento do ensino presencial (em cenários habitualmente denominados de “*blended-learning*” ou “*b-learning*”), quer como oferta formativa adicional num modelo de ensino não presencial (“*e-learning*”). Todos estes fatores estão a contribuir para um rápido aparecimento de novas e inovadoras ferramentas tecnológicas, aplicações e serviços Internet, no suporte ao ensino.

As mudanças na educação têm vindo, igualmente, a reforçar a importância do construtivismo, enquanto modelo aprendizagem. Neste, o conhecimento é criado ou construído ativamente pelo próprio aluno (e não como resultado, essencialmente, da sua transmissão ou transferência passiva), através das suas interações com o meio. Neste modelo, a aprendizagem resulta de um processo iterativo, evolutivo, suportado pela participação social em contexto de grupo. Trata-se de uma visão em que o conhecimento é fruto de uma construção social e recorre a um modelo de sociedade onde a aprendizagem é uma necessidade constante, em que para além das competências tradicionalmente consideradas como essenciais, também se torna necessário o uso e domínio das TIC, que facilitam e possibilitam o trabalho em colaboração (Sheng et al., 2010). Para além da colaboração, que é um elemento central da aprendizagem construtivista, existem outros elementos igualmente considerados fundamentais, tais como (Seitzinger, 2006):

- Aprendizagem baseada na resolução de problemas, questões, casos ou mesmo projetos (exige informação e recursos relevantes e interessantes para o aluno, de preferência baseados em situações reais, de suporte à resolução, etc.);

- Centralização no aluno, fomentando o controlo, a pró atividade, dinamismo, reflexão, articulação e flexibilidade por parte deste (os formadores surgem mais como facilitadores e como suporte a esse processo de aprendizagem);
- Colaboração, com destaque para a resolução de problemas em grupo (com o auxílio desejável de ferramentas de construção de conhecimento e de partilha de informação em grupo);
- Participação social, favorecida pela motivação de alunos e professores e influenciada pela quantidade e qualidade das suas interações;
- Interatividade, envolvendo não só os professores e outros alunos, como também os materiais, o processo de aprendizagem adotado pelo aluno e o ambiente computacional e tecnológico envolvido (é relevante ser-se hábil no uso das ferramentas tecnológicas);
- Suporte permanente à aprendizagem, visando o acompanhamento dos alunos em todas as atividades (para que o aluno possa rever e corrigir as suas ações), devendo ser motivador e orientador (adotando uma construção de conhecimento por pequenos passos na resolução de problemas mais complexos, por exemplo);
- Existência de ferramentas para expor o conhecimento nas várias etapas.

Com a contribuição dos avanços tecnológicos têm surgido inúmeras iniciativas tendo em vista a abertura do ES a cada vez mais pessoas no mundo. Exemplos dessas iniciativas passam pela criação de recursos educacionais abertos, repositórios de conteúdos, interligação destes repositórios em grandes escalas, cursos de acesso livre, novos serviços e aplicações para a Internet, entre outros.

A crescente interação social propiciada pela Internet está igualmente a beneficiar a aprendizagem e o ensino. De facto, o reconhecimento do elevado interesse numa maior e melhor interação fez surgir novos serviços suportados na Internet, dinamizadores e ampliadores dos conceitos de redes de aprendizagem pessoais, de comunidades de prática ou de interesse. Nestes serviços o conceito de aprendizagem colaborativa sai reforçado, pois cada membro constrói o seu conhecimento, partilha-o e enriquece-o em comunidade.

Também as recentes aplicações sociais (resultantes da 2ª geração da *Web*, também designada por *Web Social* ou *Web 2.0*) estão a reforçar o papel da colaboração e a revolucionar as práticas relacionadas com a teoria construtivista na aprendizagem, enormemente facilitadas pelas tecnologias associadas à computação móvel e à *cloud*.

Em resumo, podemos referir que as TIC e a Internet estão a revolucionar inúmeras áreas da nossa sociedade, incluindo os contextos de aprendizagem nas IES. Ao longo das próximas secções destacaremos algumas dessas áreas, tais como a produção, armazenamento e distribuição de recursos educativos abertos (secção 2.1.1) e a adequação dos sistemas de gestão de aprendizagem de suporte a inovadores processos de ensino/ aprendizagem tanto para as instituições como para os próprios alunos e professores (secção 2.1.2). A influência dos recentes paradigmas tecnológicos de mobilidade (secção 2.1.5) e de computação na nuvem (secção 2.1.6) conduzem o desenvolvimento de inovadores serviços e aplicações baseados nos princípios da *Web 2.0*, onde as redes sociais assumem a forma de redes de aprendizagem (secção 2.1.3) e as aplicações e serviços sociais são usados para obtenção do conhecimento (secção 2.1.4).

## 2.1.1 Recursos Educativos e Repositórios

A designação “objeto de aprendizagem” (LO, do inglês: *Learning Object*) foi atribuída a Wayne Hodgins em 1994. Existem muitas definições em inúmeros artigos sobre os objetos de aprendizagem. O *Institute of Electrical and Electronics Engineers* (IEEE) considera que um LO é descrito recorrendo ao uso de meta-dados e tem a seguinte definição: “*any entity, digital or non-digital, which can be used, re-used or referenced during technology supported learning*” (2002). Beck (2010) caracteriza um LO da seguinte forma:

- Pequenas unidades de aprendizagem – duração entre 2 e 15 minutos;
- Autónimo – independente;
- Reutilizável – em diversos contextos e para diferentes fins;
- Agregável – podem ser agrupados;

- Classificados com meta-dados – informação descritiva para mais fácil pesquisa.

Existem alguns consórcios envolvidos no desenvolvimento das especificações destes LO e dos seus meta-dados, como o projeto *Instructional Management System/ Global Learning Consortium* – IMS/ GLC, o *Educational Modelling Language* - EML, a iniciativa *Sharable Content Object Reference Model* – SCORM, vários grupos do IEEE, etc.. Para além da representação dos conteúdos, estas organizações, projetos ou grupos têm vindo a desenvolver e a melhorar outras especificações que normalmente definem formatos e procedimentos com objetivos distintos (mas relacionados), como sejam a representação da entidade aluno, das competências, dos objetivos das aprendizagens, das avaliações, da agregação e sequenciamento de conteúdos e da troca de todas estas informações entre plataformas de suporte à aprendizagem (Chew, 2003).

As normas SCORM têm tido algum destaque. Foram desenvolvidas tendo como objetivo a criação de LO com as seguintes características (Gonzalez-Barbone & Anido-Rifon, 2010):

- Reutilização – conteúdo deve ser independente do contexto de aprendizagem;
- Durabilidade – adaptação às alterações tecnológicas sem necessidade de redesenhar, reconfigurar ou recodificar (não requerem modificação devido a modificações ou atualizações dos programas aplicativos);
- Interoperabilidade – os materiais de aprendizagem devem poder ser usados por diferentes ferramentas ou plataformas (separar os conteúdos das plataformas de aprendizagem), quer de *hardware* quer de *software*;
- Acessibilidade – procurar que a disponibilização dos conteúdos possa ocorrer para diferentes “localizações”, por exemplo;
- Manutenibilidade – alterações dos LO sem esforço, sem redesenho, reconfiguração ou recodificação;
- Adaptabilidade – possa satisfazer diferentes requisitos de utilizadores ou instituições.

A norma SCORM “*Content Model*” descreve os componentes que constituem uma unidade de aprendizagem e como estes são organizados. A norma SCORM que

descreve os meta-dados baseou-se na norma IEEE *Learning Object Meta-Data* (LOM) e define como é feita a agregação de conteúdos, os ficheiros que o compõem, que informação deve existir para facilitar a pesquisa, indexação e o seu acesso. Opcionalmente poderá haver informação sobre a sequenciação dos conteúdos agrupados.

Várias iniciativas, como o projeto *Open e-Learning Content Observatory Services* (OLCOS), cofinanciado pela Comissão Europeia no programa *e-Learning*, propõem a necessidade de introduzir mudanças e inovações nas práticas educacionais, promovem a aprendizagem ao longo da vida para toda a sociedade e dão ênfase à oferta de recursos educativos abertos (OER, do inglês: *Open Educational Resources*), que deverão pertencer à humanidade. A oferta deste tipo de recursos deve compreender o desenvolvimento, armazenamento, acesso, reutilização e preservação de conteúdos de ensino/ aprendizagem. O conceito OER assenta na ideia de que o conhecimento é um bem público e de que a tecnologia em geral e a Internet em particular fornecem uma extraordinária oportunidade para se partilhar, usar e reutilizar o conhecimento (OLCOS, 2007). Como resultado desse projeto são propostos os seguintes princípios sobre os recursos educativos:

- Acesso livre e gratuito dos conteúdos (incluindo os seus meta-dados) para IE, fornecedores de conteúdos, alunos e professores;
- Licenciamento livre de LO, que possibilite reutilização, modificação e nova submissão (desde que usando os mesmos LO com o mesmo licenciamento);
- Desenho de conteúdos usando normas que facilitem a livre reutilização;
- Uso de aplicações e de livrarias de desenvolvimento (API, do inglês: *Application Programming Interfaces*) com código fonte disponível (*“Open Software”*) e livre autorização no acesso a serviços *Web* para os conteúdos educacionais.

Por conteúdo aberto, entende-se o conteúdo que está licenciado de um modo que os utilizadores que possuem permissões possam efetuar mais usos do que os habituais permitidos pela lei e sem custos. O sítio *OpenContent* apresentou uma definição

abrangente para o conteúdo livre baseada, nos 4Rs: ”... *free to Reuse, Revise, Remix, Redistribute*” (Wiley, 2011).

Para a Organização para a Cooperação e Desenvolvimento Económico - OCDE (2007) os OER são "materiais digitalizados abertos oferecidos gratuitamente para educadores e estudantes usarem e reutilizarem para o ensino, aprendizagem e investigação". Para Maddrell (2007), a própria reutilização deverá incluir a possibilidade de edição e partilha por parte do estudante, usando um tipo de licenciamento “liberal” (do tipo “*share alike*”, em que são livres as modificações, ou extensões feitas sobre o recurso, assim como o serão em novas cópias ou modificações), um formato que permita uma fácil partilha e pesquisa na Internet e para o qual possa ser possível adotar o mecanismo de sindicância *Web* (RSS, do inglês: *Really Simple Syndication*).

O número de projetos envolvendo a criação e disseminação de recursos educativos por toda a humanidade através da Internet está em expansão. Este movimento teve um relevante impulso com o programa *OpenCourseWare*, apresentado em 2001 pelo Presidente Charles Vest do *Massachusetts Institute of Technology* (MIT). O objetivo desse projeto passa pela disponibilização gratuita na Internet de recursos de aprendizagem sobre 1800 cursos (com possibilidade de reutilização) e envolve mais de 250 IES de todo o mundo. Outros projetos, como o *Open Learning Initiative* da *Carnegie Mellon University* e a *Next Generation Learning*, atingiram protagonismo e relevância neste âmbito. A oferta global de cursos via Internet é também uma realidade e com alguns casos de sucesso, envolvendo algumas das mais prestigiadas IE do mundo, tais como os projetos *Udacity*<sup>6</sup> (<http://www.udacity.com/>), *edx*<sup>7</sup> (<https://www.edx.org/>) e *coursera*<sup>8</sup> (<https://www.coursera.org/>).

---

<sup>6</sup> Participação da Stanford University

<sup>7</sup> Sócios fundadores: Harvard University e MIT - Massachusetts Institute of Technology

<sup>8</sup> Em novembro de 2012, possuía 33 instituições de ensino superior associadas: Berklee College of Music, Brown University, California Institute of Technology, Columbia University, Duke University, École Polytechnique Fédérale de Lausanne, Emory University, Georgia Institute of Technology, Hebrew University of Jerusalem, Johns Hopkins University, Mount Sinai School of Medicine, Ohio State University, Princeton University, Rice University, Stanford University, The Hong Kong University of Science and Technology, The University of British Columbia, University of California, Irvine, University of California, San Francisco, University of Edinburgh, University of Florida, University of Illinois at Urbana-Champaign, University of London International Programmes, University of Maryland, College Park, University of Melbourne, University of Michigan, University of Pennsylvania, University of Pittsburgh, University of Toronto, University of Virginia, University of Washington, Vanderbilt University, Wesleyan University

De acesso livre ou não, os recursos educativos estão a ser armazenados em repositórios (LOR, do inglês: *Learning Objects Repository*), permitindo a sua partilha e reutilização (Gonçalves, Pereira, & Cota, 2010). Estes repositórios assumem por vezes objetivos diferentes, uns mais orientados para comunicações científicas, outros para disponibilização de materiais aos estudantes. As IES poderão necessitar de ambos (Rothery, Andrew & Bell, 2006).

A nível nacional, nos anos mais recentes, têm sido promovidos repositórios de acesso livre, como por exemplo o Repositório Científico de Acesso Aberto de Portugal – RCAAP, que tem como objetivo a recolha, agregação e indexação dos conteúdos científicos em acesso aberto, ou acesso livre, existentes nos repositórios institucionais das entidades nacionais de ES e organizações de investigação e desenvolvimento.

De uma forma geral, estes repositórios podem definir-se como “caixas de depósito digitais que armazenam coleções de recursos digitais num formato de LO: i.e. recursos concebidos para ser integrados, agregados e sequenciados de um modo eficiente para produzir unidades de aprendizagem que sejam significativas para os estudantes” (Margaryan, Milligan, & Douglas, 2007).

Visando uma partilha global, estes repositórios deverão evoluir no sentido de se integrarem com outros repositórios, a uma escala nacional e internacional.

## 2.1.2 Sistemas de Gestão de Aprendizagem

Um sistema de gestão de aprendizagem (LMS, do inglês: *Learning Management System*) consiste num sistema desenhado para suportar a aprendizagem e o ensino, permitindo às IES e aos seus professores gerir e controlar a aprendizagem dos estudantes.

Um LMS usa normalmente a Internet como infraestrutura de comunicação e fornece um conjunto de ferramentas para suporte à comunicação assíncrona (divulgação de notícias, fóruns de discussão, ...), síncrona (videoconferência, conversação em tempo real), publicação de conteúdos, gestão de utilizadores e de grupos e suporte à avaliação

(questionários, publicação e receção agendada de trabalhos, testes de avaliação em tempo real, inquéritos, publicação de notas, ...). A maioria suporta o modelo de referência SCORM, designadamente para descrever e importar cursos entre plataformas e para descrever os próprios conteúdos.

Existem vários sistemas, uns de cariz mais comercial, outros de utilização livre, tais como o *Moodle*, *WebCT*, *First Class*, *Blackboard*. São vários os estudos que comparam a utilização dos vários LMS. Em Portugal, a preferência destes sistemas vai para o *Moodle*, de forma destacada ([http://www.ed-rom.com/?pt=moodle\\_blackboard](http://www.ed-rom.com/?pt=moodle_blackboard), consultado em 21.09.2011).

Recentemente, sobre os LMS têm sido acrescentadas novas funcionalidades, que incluem blogues, *wikis*, RSS, entre outras.

Interessa-nos realçar duas limitações de entre as principais, habituais nos LMS, pelo seu relevo para esta investigação:

- Organização baseada em períodos semestrais (tipicamente de 15 semanas), em cursos e respetivas unidades curriculares;
- Centralização no docente, responsável pela criação do curso, publicação de conteúdos, formação de grupos, sendo ele quem normalmente inicia as conversações (com os estudantes).

Numa análise a vários LMS, foram identificados vários pontos fracos e fortes, apresentados na tabela 1 (Mott , 2010).

Um dos pontos fracos assinalados diz respeito à sua estruturação em torno do professor. Conforme já referido, a personalização e a adequação da aprendizagem pretende-se cada vez mais em torno do aluno. Esta tendência vem reforçar a necessidade de existência de ferramentas que auxiliem o aluno na condução do seu percurso de aprendizagem. Os ambientes de aprendizagem pessoal (PLE, do inglês: *Personal Learning Environments*), constituem uma das respostas a este desafio. Estes ambientes estão a ganhar particular relevo, tendo surgido como uma evolução natural dos portefólios digitais (ferramentas

que permitem a organização, gestão e partilha de documentos e trabalhos produzidos durante a aprendizagem).

**Tabela 1 - Pontos fortes e fracos dos LMS**

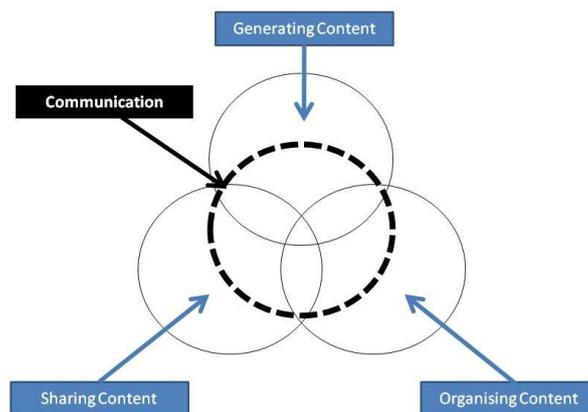
<b>Pontos Fortes</b>	<b>Pontos Fracos</b>
Simple, consistente e estruturado	Cursos desaparecem no tempo (final do semestre)
Integração com os Sistemas de Informação Académicos	Centrado no professor (e não no aluno)
Acesso privado e seguro	Cursos “isolados” dificultam o efeito de partilha rede
Formação simples e acessível	Dificuldade para o aluno gerir as suas experiências de aprendizagem (que ocorrem dentro e fora dos cursos)
Forte integração de ferramentas	Ferramentas pouco flexíveis, não modulares
Bom suporte à estruturação e gestão de conteúdos	Interoperabilidade dificultada

Wheeler (2010b) referiu no seu blogue que os PLEs são “ambientes pessoais, criados, usados e mantidos por cada individuo ao longo da sua aprendizagem durante toda a sua vida”. Compreendem normalmente ferramentas *Web* de código aberto e livre (sociais, na sua maioria e suportadas na *cloud*) e as redes pessoais de aprendizagem (PLN, do inglês: *Personal Learning Networks*). A escolha das ferramentas que compõem um PLE é feita, normalmente, por cada aluno, de acordo com o seu interesse e conhecimento. Embora alguns conteúdos possam ser integráveis recorrendo a tecnologias como RSS, a completa integração das ferramentas adotadas surge como um dos pontos fracos destes sistemas (Mott, 2010).

As ferramentas de suporte a um PLE são usadas pelos estudantes para que estes possam definir e acompanhar os seus objetivos, desenvolver e partilhar as suas ideias, gerir os

seus conteúdos e os seus processos de aprendizagem, comunicar com os restantes intervenientes (estudantes, professores, ...), bem como controlar os seus próprios resultados (de avaliação, por exemplo).

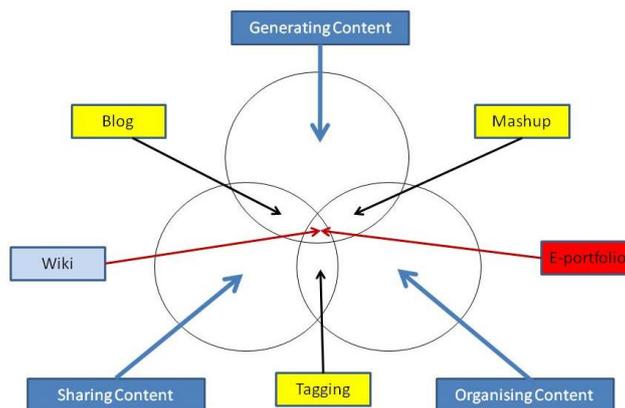
Os três principais componentes de um PLE (ver figura 1) compreendem a geração, a organização e a partilha de conteúdos. Uma quarta componente, de comunicação, que inclui o diálogo, partilha e discussão (em modos síncrono e assíncrono), interage com as restantes componentes.



Fonte: <http://steve-wheeler.blogspot.pt/2010/07/physiology-of-ple.html>

**Figura 1 - Componentes de um PLE**

A implementação de um PLE (ver figura 2) inclui normalmente mais do que um subsistema e recorre a aplicações *desktop* e/ou *Web* (ferramentas como blogues, portfólio eletrónico, *wiki*, *tagging*, *mashup*, entre outras) e por vezes a serviços *Web* (Wheeler, 2010a).

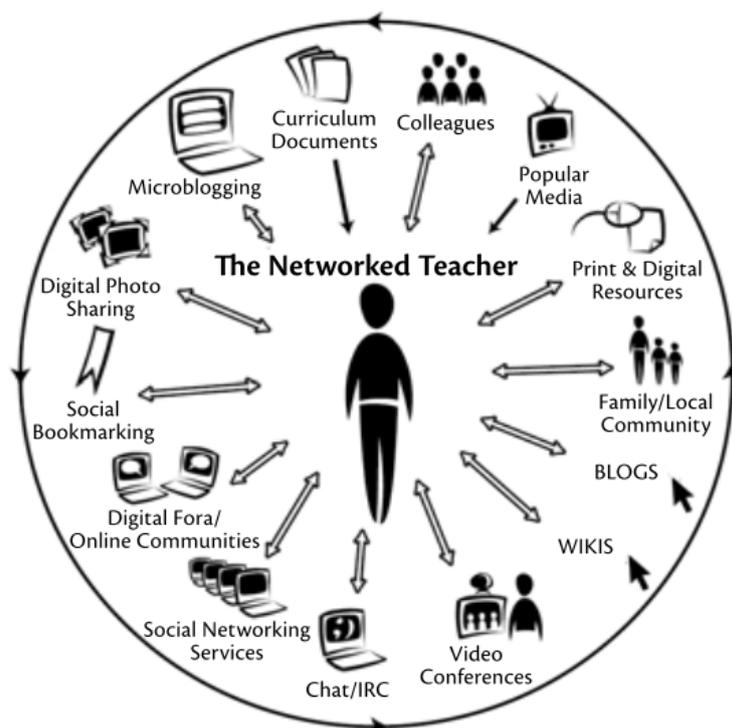


Fonte: <http://steve-wheeler.blogspot.pt/2010/07/physiology-of-ple.html>

**Figura 2 - Ferramentas de um PLE**

Algumas implementações integram numa mesma plataforma, aplicações de gestão, portefólios eletrónicos, redes sociais e LMS (Oliveira & Moreira, 2010). Também algumas aplicações que permitem a criação e gestão de redes sociais foram desenvolvidas com o propósito de suportar as funcionalidades dos PLE, tais como o *Mahara ePortfolio system* (<https://mahara.org/>) ou o *Elgg* (<http://www.elgg.org/index.php>).

A utilização de um PLE é igualmente defendida como sendo muito útil para os próprios professores (Couros, 2010), uma vez que eles próprios são estudantes, por natureza da sua profissão (ver figura 3).



Fonte: (Couros, 2010)

**Figura 3 - O Professor em Rede**

Atualmente, estes sistemas ainda possuem alguma complexidade, essencialmente devido à necessidade de integração de diferentes informações provenientes de várias ferramentas.

### 2.1.3 Redes de Aprendizagem

A criação de redes de indivíduos que interagem com o propósito de obter algum novo conhecimento sempre existiu. O que as TIC e a Internet trouxeram foi uma enorme simplificação à sua criação e manutenção.

A influência do comportamento e das contribuições de outros utilizadores, sejam eles alunos ou professores, na aprendizagem tem vindo a aumentar. Esta tendência tem impulsionado o surgimento de redes de aprendizagem, que ligam alunos (normalmente distribuídos por diferentes espaços geográficos) e fornecedores (professores, instituições, outras pessoas, ...) em certos domínios de aprendizagem (Koper & Tattersall, 2004).

As PLN são redes constituídas por pessoas a quem recorremos quando necessitamos de resposta a uma questão (normalmente num curto espaço de tempo), quando necessitamos de ajuda para resolver um problema ou ainda quando pretendemos partilhar com alguém, algo que lemos ou soubemos e que consideramos interessante. Através da sua PLN um estudante pode obter inúmeros conhecimentos. Neste contexto, saber quem possui um dado conhecimento ou como o mesmo pode ser obtido passa a ser tão importante como possuir esse conhecimento.

Não só o conceito associado às redes de aprendizagem é centrado no aluno como o seu desenvolvimento se inicia com a participação do aluno. Ao contrário da maioria do ensino promovido pelas instituições, onde a estrutura da formação, os seus conteúdos e os caminhos de aprendizagem estão pré-definidos, nas redes de aprendizagem torna-se possível publicar os próprios conteúdos, aceder a outros conteúdos, alterá-los, partilhá-los, avaliá-los e, desta forma, identificar caminhos de aprendizagem mais atrativos. Nas redes de aprendizagem, os alunos podem atuar com diferentes papéis (como professores, alunos ou fornecedores de conteúdos) e em simultâneo. A crescente relevância destas redes deriva igualmente dos pontos em comum e da sua integração com as aplicações sociais (*Web 2.0*), apresentadas mais adiante, nesta mesma secção. De facto, muitos dos conteúdos de aprendizagem informais estão armazenados nos serviços e aplicações da *Web 2.0*.

É nossa opinião que as redes sociais de aprendizagem poderão desempenhar um papel importante na sequenciação estratégica das atividades que compõem os eventos educativos. Nesse âmbito, cada aluno poderá recolher informação útil da sua rede social de aprendizagem que irá usar para estabelecer a sequência de atividades mais adaptada aos seus interesses e propósitos de aprendizagem.

A importância destas redes, formais ou informais, foi reconhecida pela própria União Europeia com a criação de vários projetos tais como o *TENcompetence* (<http://www.tencompetence.org/>).

As comunidades de prática (COP, do inglês: *Communities of Practice*) designam as redes formadas por grupos de pessoas que se unem em torno de um mesmo tópico ou de

um dado interesse comum (Li et al., 2009). Essas pessoas trabalham juntas para melhorar o que fazem, ou para resolver um dado problema que surja no seu dia-a-dia. Nestas comunidades a interação ocorre de forma mais ou menos regular.

Outros tipos de comunidades têm igualmente surgido. Nas comunidades de interesse (COI, do inglês: *Communities of Interest*) e ao contrário das COP, onde os seus membros são normalmente peritos sobre um dado tema e trabalham sobre o principal assunto que está na origem do desenvolvimento da comunidade, os seus membros apenas possuem interesse sobre o respetivo tópico, não sendo necessariamente peritos sobre o mesmo. O uso de COI em IES, usando plataformas de redes sociais, foi defendido como meio de comunicação, colaboração (potenciando a partilha e a geração de conhecimento em colaboração) e suporte aos trabalhos dos investigadores (Chow & Chmura, 2010).

### 2.1.4 Web 2.0 no Ensino

As ferramentas ditas sociais (também associadas à 2ª geração de aplicações *Web*), embora recentes, têm tido um grande impacto na vida das pessoas, suscitando muita curiosidade, criando novas formas de trabalho, de comunicação, de obtenção e partilha de informação e de entretenimento. A utilização destes recursos (disponíveis na *Web 2.0*) tem igualmente permitido a criação de ambientes de aprendizagens, na sua maioria informais, usados para obtenção de conhecimento através do acesso e da partilha de informações e de saberes.

A *Web 2.0* resultou da evolução da designada “*Read Web*” para a “*Read-Write Web*” e tornou a Internet a plataforma onde os conteúdos são criados, partilhados, transformados e retransmitidos (Downes, 2005). O uso destas ferramentas tem fomentado e dado crescente significado e relevância ao conceito de aprendizagem colaborativa.

Os serviços e aplicações *Web 2.0* têm vindo a substituir ou a retirar relevância aos LMS nas IES. De facto, LMS como *WebCT*, *First Class*, ou o *Moodle* foram pensados e são essencialmente usados para gerir conteúdos e não para promover comunidades de

aprendizagem ou colaboração (na maioria das vezes, nos LMS a interação ocorre de forma forçada, normalmente imposta pelo professor e não por iniciativa do aluno).

De facto, cada vez mais, a aprendizagem ocorre entre pessoas, em colaboração, usando tecnologias como blogues, redes sociais, *wikis*,... (Davidson & Waddington, 2010). Curiosamente, em várias IES, algumas destas ferramentas sociais não estão disponíveis ou o seu uso encontra-se vedado!

Apesar do forte impacto sobre as pessoas e sobre os seus hábitos, gerado por estas recentes ferramentas sociais, a comunidade académica, em geral e os seus professores, em particular, nem sempre as adota e quando o faz, fá-lo de forma superficial. A relutância dos professores em usar as ferramentas sociais decorre de vários fatores tais como o desconhecimento sobre a sua existência, sobre as suas funcionalidades e sobre o modo de as usar. Outros fatores como a falta de suporte administrativo e técnico nas IES sobre essas ferramentas, falta de tempo para experimentar, dúvidas sobre a propriedade intelectual dos conteúdos partilhados com o uso destas ferramentas e ainda a ideia de que estas tecnologias poderão ser substituídas por outras, na próxima "mudança" tecnológica, desviam muitos professores da sua adoção (Oliveira & Moreira, 2010).

Apesar das "dúvidas" que impedem uma maior adoção, o número de experiências com o uso de aplicações *Web 2.0* no ensino/ aprendizagem tem vindo a crescer, muito por iniciativa de professores e alunos e raramente proveniente de iniciativas estratégicas das IES.

Diferentes aplicações emergem destas aplicações e serviços. Assim, para além da promoção da aprendizagem social e da participação ativa, sugeridas pelo construtivismo, as ferramentas sociais introduzem igualmente facilidades com os seus serviços *Web* e as suas API, de acesso livre, permitindo aos investigadores montar complexos protótipos que permitem testar e validar as hipóteses da sua investigação, em pouco tempo (Ullrich et al., 2008).

Acompanhar a evolução e o aparecimento de novas ferramentas são tarefas relevantes do investigador que se interessa pela sua eventual aplicação ao ensino. Selecionar as

tecnologias e como as usar adequadamente de acordo com os objetivos pretendidos (para o ensino/ aprendizagem), requer entre outras coisas, o conhecimento adequado das mesmas e do seu funcionamento. Deverá exigir, por isso, cuidada investigação antes de qualquer aplicação real.

Em seguida, são brevemente apresentadas algumas das atuais aplicações sociais da geração *Web 2.0*, incluindo uma breve descrição das suas potencialidades e aplicações sobre o ensino/ aprendizagem.

### ***Twitter***

*Twitter* é uma ferramenta de *micro-blogging*, que permite aos utilizadores publicar pequenos textos (com tamanhos até 140 caracteres). A publicação ocorre de forma cronológica e permite o acesso aos textos dos contactos seleccionados. É uma ferramenta muito interativa, que alcança muito mais que os colegas ou amigos de um dado utilizador (pois facilita o fluxo de informação para todos os utilizadores, exceto quando existem utilizadores bloqueados), pelo que se tornou uma excelente ferramenta para a comunicação.

Usado para partilha de ideias, ligações (a outros endereços) e artigos, por especialistas, autores, celebridades, gestores de marca e de campanha que assim, fazem chegar informação aos seus utilizadores/ leitores.

É igualmente uma ferramenta com excelentes resultados na obtenção de ajuda e na troca de opiniões.

A pequena dimensão dos seus textos exige que o seu autor seja conciso e direto. A natureza informal e rápida de comunicação incentiva as ligações entre as pessoas, à sua partilha de pensamentos e de opiniões.

Não oferece funcionalidades de gestão/ controlo, como arquivo ou pesquisa.

A ética da sua utilização sugere que os utilizadores que seguem as conversações (leitores) de um outro devam retribuir com a partilha das suas experiências.

Como as conversações são públicas, as pessoas podem aceder aos seus textos, seleccionar as ligações que existam (para outros artigos, vídeos ou fotos), encaminhá-las para outros utilizadores ou mesmo acrescentar alguma informação.

Já existem várias experiências do seu uso na aprendizagem e delas resultou a convicção de que esta ferramenta pode ser um bom complemento à típica formação em sala de aula e aos programas assíncronos de formação não presencial. Facilita igualmente a integração dos novos alunos e permite manter o enfoque no intervalo entre eventos formais de formação.

Em resumo, o *twitter* é uma ferramenta que facilita a construção e manutenção de comunidades, em especial nas PLN (Lalonde, 2011), permitindo rápidas atualizações e comentários, induzindo momentos de reflexão e de conversação com cariz informal (Bozarth, 2010a).

## Redes Sociais

Atualmente, o *Facebook* é a principal aplicação de redes sociais (Shih, 2011). É uma ferramenta que agrega várias formas de informação, tais como mensagens, fotos, vídeos, eventos, discussões e ligações. Nesta aplicação, os utilizadores interagem com “amigos” selecionados e participam em grupos com outros utilizadores.

É uma ferramenta muito colaborativa, que permite muito facilmente (sem conhecimentos técnicos específicos, de programação de páginas *Web*, de edição de vídeo ou fotos, etc...) publicar conteúdos *Web* para comunidades (grupos) de utilizadores.

O *Facebook* é uma ferramenta informal e de fácil utilização, que abrange atualmente uma vasta audiência, incluindo pessoas com menor literacia.

A sua utilização está, contudo, conotada com algum desperdício de tempo, pois é frequente os seus utilizadores distraírem-se com informações publicadas de pouco interesse ou usarem-na apenas como forma de entretenimento (jogos).

Como ferramenta de aprendizagem, permite ao formador manter-se em contacto frequente, criar sentido de comunidade, hospedar todos os conteúdos de um dado curso (módulo ou disciplina), potenciar a partilha de conhecimentos e de ideias. Tal como nos sistemas de gestão de conteúdos, permite publicar e assim divulgar eventos, notas, documentos, vídeos e apresentações, enviar mensagens individuais ou em grupo. A promoção da conversação surge como um fator de melhoria do relacionamento entre formador e formando. Também o sistema de sindicância do *Facebook* permite a alunos e a professores receberem as alterações/ atualizações sem necessidade de proceder repetidamente ao processo de autenticação (situação que é normalmente exigida nos LMS).

Como o *Facebook* oferece algumas das funcionalidades compatíveis com as oferecidas pelos LMS (publicar apresentações, notas, vídeos, documentos e agendamento de

eventos, ...) e uma vez que os estudantes já o utilizam, a sua adoção em contexto de ensino poderá estar facilitada.

Tal como o *twitter*, pode ser usado no intervalo entre os eventos formais de formação, como complemento ao processo habitual de aprendizagem.

*LinkedIn* é outra aplicação social, associada à criação de comunidades de profissionais. Enquanto ferramenta de suporte à aprendizagem não é muito utilizada, sendo mais uma fonte de ligação entre pessoas, numa perspetiva essencialmente profissional (relacionamentos fornecedor-cliente, contactos de variados tipos, suporte à gestão de carreiras através da divulgação e obtenção de currículos e de perfis individuais) (Bozarth, 2010b).

Para além destas aplicações, proliferam na Internet ofertas de aplicações que permitem a implementação de redes sociais, com mais ou menos funcionalidades, de acesso gratuito ou não gratuito. Um desses produtos é o *Ning* ([www.ning.com](http://www.ning.com)), que permite a criação de redes sociais (individuais, para escolas, para negócios) e onde já existem alguns exemplos de aplicação no âmbito do ensino/ aprendizagem.

Alguns LMS também já oferecem ou estão a desenvolver e integrar funcionalidades de suporte à criação e exploração de redes sociais, como complemento às habituais funcionalidades de gestão e organização de conteúdos.

## **Blogue**

Um blogue (*blog* - contração do termo “*Weblog*”) é um sítio na *Web* cuja estrutura permite a atualização rápida a partir de acréscimos de artigos (“*posts*”). Estes são, em geral organizados de forma cronológica inversa, tendo como foco a temática proposta do blogue, podendo ser escritos por um número variável de pessoas (de acordo com a política do blogue).

É uma ferramenta que permite a criação de uma página *Web* com aspeto profissional e de uma forma muito fácil, sem necessidade de suporte técnico.

Um blogue típico combina texto, imagens e ligações para outros blogues, páginas da *Web* ou documentos relacionados com a temática do mesmo.

Muitos blogues fornecem comentários ou notícias sobre um assunto em particular, enquanto outros funcionam mais como diários.

A capacidade dos leitores deixarem comentários e dessa forma, poderem interagir com o autor e com os outros leitores é uma funcionalidade importante de muitos blogues.

Na maioria das vezes, está disponível a possibilidade de publicar o artigo por agendamento (à posteriori).

Podem ser obtidas métricas sobre o uso do blogue (tais como o número de visualizações no tempo).

Também podem ser protegidos por palavra passe, bem como oferecer notificação aquando da sua atualização, por correio eletrónico.

A maior parte das ferramentas que suportam estes blogues oferecem RSS que facilita a receção das atualizações por parte dos seus leitores.

Oferecem também a funcionalidade de arquivo (normalmente com uma periodicidade mensal) e são pesquisáveis.

Em termos de ensino, são normalmente usados para publicar conteúdos, calendarizar eventos e ações, publicar questões para discussão e ligações para outros conteúdos de suporte aos cursos.

Quando comparado com outras ferramentas como o *twitter* ou o *Facebook*, o blogue é menos interativo e menos propício a interações um-para-um ou à interação casual.

Contudo, oferece um espaço útil para reflexão, para conversação do tipo pública e para partilha de conhecimento.

Convidam a textos grandes (maiores que no *twitter* ou no *Facebook*, por exemplo) pelo que exigem mais tempo de manutenção.

São vistos pelos formandos/ alunos como mais formais.

Podem ser perspetivados como um complemento à formação tradicional e à utilização do *twitter*, sendo por vezes usados em conjunto com este para desenvolver rapidamente uma comunidade (Bozarth, 2010c).

## **Wiki**

*Wiki* consiste numa página *Web* interativa, sobre a qual, qualquer pessoa autorizada poderá aceder e alterar o seu conteúdo. Tipicamente usam texto, mas podem igualmente alojar fotos e objetos multimédia.

Fáceis de usar, permitem a edição e alteração pelos utilizadores (ou apenas, pelos que estão autorizados, já que podem estar protegidos por senha para leitura e/ ou alteração).

Normalmente está igualmente disponível a funcionalidade de notificação do seu dono, após a sua alteração.

São uma ferramenta muito útil para trabalho colaborativo, especialmente quando envolvem utilizadores dispersos geograficamente.

Para além da sua utilização no suporte à aprendizagem de um curso ou módulo, podem ser usados para divulgação de boas práticas, entre outros tipos de informação. Revelam-se ainda úteis na publicação de manuais e de materiais de forma atualizada. Como fazem o registo das alterações, são também úteis no acompanhamento de projetos (Bozarth, 2010d).

## Outras ferramentas

Muitas outras ferramentas estão a surgir, pelo que o seu impacto em termos de utilização e adaptação ao ensino/ aprendizagem ainda não são possíveis de prever.

Em seguida, são apresentadas apenas algumas dessas recentes ferramentas sociais, através de uma breve caracterização e descrição de funcionalidades (Bozarth, 2010e):

- *Google Docs* permite a publicação, edição e partilha de documentos de texto, folhas de cálculo, apresentações, desenhos e formulários com gestão de versões dos documentos publicados;
- *YouTube* permite a publicação e distribuição de vídeos, usando diversos dispositivos; através da criação de um canal um formador pode estabelecer permissões para visualização; através de uma referência *html* é possível integrar um dado vídeo num blogue, numa página *Web* ou adicioná-la como uma ligação no *Facebook* ou num artigo do *twitter*; aos vídeos publicados poderão ser adicionados comentários;
- *TeacherTube* é uma extensão do *YouTube*, desenhada para partilha de recursos educacionais; para além dos vídeos, permite a publicação de áudio, fotos e documentos e disponibiliza ainda espaço para blogues e fóruns de discussão; a integração com o *Facebook* facilita a publicação dos vídeos e dos comentários feitos no *TeacherTube* diretamente para o *Facebook*;
- “*Social Bookmarking*” é um sistema de *bookmarks* (também conhecido como favoritos ou marcadores) online de livre acesso, que tem por finalidade disponibilizar os favoritos na Internet, facilitando o seu acesso e partilha com utilizadores da Internet (de realçar que não se trata de um sistema de partilha de ficheiros, apenas de endereços);
- “*Social Tagging*” ou “*Folksonomia*” permite que os próprios utilizadores classifiquem os recursos favoritos com palavras-chave (“etiquetas”); esta classificação facilita a posterior recuperação da informação; a pesquisa pode ser feita sobre as etiquetas do próprio utilizador ou dos outros utilizadores; permite que professor e alunos possam divulgar e partilhar endereços sobre certos

tópicos de interesse para a aprendizagem; um dos serviços populares que implementa este conceito é o del.icious.us (<http://www.delicious.com/>);

- *Skype* é um serviço de interação em tempo real que permite chamadas gratuitas através da Internet, chamadas em conferência com ou sem vídeo, mensagens instantâneas e pesquisa sobre os nomes dos arquivos transferidos; pretende também disponibilizar partilha de um quadro branco virtual; esta solução constitui uma alternativa para os alunos que não possam assistir presencialmente (por motivos de doença, por exemplo) a uma aula;
- *SlideShare* permite a publicação e partilha de apresentações e de ficheiros;
- *VoiceThread* é uma ferramenta *Web* colaborativa que partilha apresentações em tempo real, e permite a inclusão de comentários em múltiplos formatos (voz, texto, vídeo);
- *UStream* permite a difusão gratuita de vídeos em tempo real desde um computador, *smartphone* ou *iPhone*; permite ainda a classificação dos vídeos e adição de comentários;
- *Mashup* é um conceito que pretende concentrar numa aplicação *Web* mais que uma fonte; com a ferramenta *Facebook Connect* é possível aceder a múltiplos sítios *Web* (por exemplo, *TeacherTube* ou *Skype*) a partir da conta do *Facebook*; *Posterous* permite a publicação de vários tipos de informação (artigos, imagens, vídeos) simultaneamente em vários serviços (por exemplo: *twitter*, *Facebook*, *Flickr*, *YouTube*);
- Salas de aula virtuais, que possibilitam conferências através da *Web* (produtos comerciais: *WebEx*, *lluminate*, *Adobe Connect*; produtos gratuitos: *WiZiQ*, *TinyChat* ou *Dimdim*);
- Serviços para envio, receção, armazenamento e partilha de ficheiros permitem uma troca eficaz de documentos e trabalhos digitais de grande dimensão, de forma fácil entre grupos de utilizadores (produtos como o *dropbox*<sup>9</sup> ou o *sendspace*<sup>10</sup> já são bastante usados no contexto académico).

---

<sup>9</sup> <https://www.dropbox.com/>

<sup>10</sup> <http://www.sendspace.com/>

## Exemplos do uso da *Web 2.0* na Aprendizagem

A avaliação do impacto da implementação das inovações *Web 2.0* nas práticas de ensino/ aprendizagem tem sido igualmente alvo de vários estudos e trabalhos de investigação.

Os resultados obtidos são positivos e sugerem que a sua adoção e implementação deve ser estruturada e pensada tendo em conta fatores como o perfil e as experiências dos estudantes e dos professores no uso dessas aplicações e ferramentas (Redecker, 2009).

A utilização assíncrona de “*Webcast*” (sessões de áudio e vídeo de formação e informação transmitidas via *Web*) na aprendizagem demonstrou bons resultados (se desenhado de forma apropriada para os objetivos pretendidos, tendo em conta aspetos como a seleção de conteúdos, apresentação e aspetos de ordem pedagógica) e poderá constituir-se como uma boa ferramenta complementar à aprendizagem (Giannakos & Vlamos, 2010).

Oravec (2002) realçou o potencial do blogue enquanto ferramenta que encoraja à reflexão e à colaboração (através dos endereços partilhados para outras informações e recursos). Destaca ainda o papel do blogue na melhoria da capacidade crítica do aluno.

As experiências com os *wikis* no suporte à aprendizagem são inúmeras. Na Universidade Politécnica de Valencia, tem sido testado o seu uso como suporte ao trabalho colaborativo dos alunos, num curso de Engenharia Informática (García, 2009). A aplicação desta ferramenta no suporte à aprendizagem tem vindo a ser testada, com sucesso, não só em IE como no seio das organizações comerciais (num contexto diferente do ES), como forma de partilha e reutilização do conhecimento transmitido e/ou gerado (Baptista, 2010).

Muitos outros estudos incluem experiências com ou sem avaliação, envolvem comunidades de diferentes dimensões, incidem sobre diferentes tecnologias emergentes e envolvem a publicação de conteúdos áudio, vídeo e imagens na Internet (*casting*), até à utilização de blogues, *wikis* e redes sociais. A maioria desses trabalhos procura avaliar

o impacto no suporte ao trabalho colaborativo dos alunos (Cain, 2008; Chow & Chmura, 2010; Guedes & Almeida, 2010; Seitzinger, 2006; Wheeler & Wheeler, 2007).

### 2.1.5 Mobilidade no Ensino

Uma das principais vantagens da tecnologia móvel é a mobilidade. A generalização das tecnologias de redes sem fios, das redes móveis e os próprios dispositivos portáteis está a contribuir para que o ensino/ aprendizagem se possa fazer através de divulgação de conteúdos e de informação de um modo cada vez mais independente do tempo e do espaço (Johnson et al., 2012). Como é óbvio, a mobilidade abrange igualmente outras áreas para além do ensino e da aprendizagem.

Com estas tecnologias, reduzem-se as limitações de tempo e de espaço no acesso à informação crítica, na comunicação e na possível partilha do conhecimento. Os intervenientes do processo de aprendizagem ficam mais livres, para poderem escolher quando e onde poderão partilhar e obter conhecimentos.

A sua aplicação abrange novas perspetivas sobre o modo, o local e o tempo de como a aprendizagem pode ser realizada, quando comparada com a realidade atual, podendo a mesma ocorrer em novas situações como quando estamos em viagem, passeio, ou visita (Sarker & Wells, 2003).

A aprendizagem apoiada pela mobilidade tem recebido muita atenção por parte de investigadores. Alguns desses trabalhos envolvem o desenho de sistemas de aprendizagem móvel (Botha, Herselman, & van Greunen, 2010), a análise do uso e dos benefícios de projetos efetuados no âmbito do ensino usando tecnologia móvel (Eschenbrenner & Nah, 2007), assim como avaliam o seu impacto no suporte ao ensino/ aprendizagem (Sheng et al., 2010; Smordal, Gregory, & Langseth, 2002).

Segundo Sheng et al. (2010), o conceito de “educação móvel” (“*mobile education*”), procura a maximização dos valores da educação, através dos seguintes objetivos

principais, que deverão orientar o desenvolvimento de soluções móveis (aplicações, dispositivos, ...) orientadas para o ensino/ aprendizagem:

- Maximizar a conveniência do ensino (por exemplo, com uma maior flexibilidade os alunos vão poder de forma mais conveniente efetuar os seus trabalhos em grupo e interagir mais vezes e mais facilmente com os seus professores);
- Maximizar a eficiência na aprendizagem (por exemplo, tornar a aprendizagem mais expedita através de respostas mais rápidas);
- Maximizar eficácia na aprendizagem (por exemplo, obter melhores resultados com o acesso a materiais em qualquer lugar e a qualquer hora);
- Maximizar a usabilidade (dispositivos e aplicações devem permitir uso e navegação facilitados);
- Maximizar a segurança da informação do aluno e professor (a transferência e armazenamento de informação para dispositivos móveis deve estar assegurada usando as técnicas e mecanismos de segurança adequados);
- Maximizar a privacidade individual (proteger alunos e professores da sua privacidade temporal e espacial, ou seja, quando e onde);
- Minimizar o custo da educação (os custos com as comunicações não deverão inviabilizar a sua ampla adoção);
- Assegurar honestidade académica (como evitar a transmissão de informações sobre uma avaliação que está a decorrer ou como anular o plágio, são alguns dos problemas que estas tecnologias agudizam).

De realçar que estas soluções móveis (como outras) deverão procurar adequar-se às características individuais de cada aluno e professor, nomeadamente no que diz respeito às suas preferências e competências em termos de tecnologias.

### **2.1.6 Aprendizagem na “Nuvem”**

O recente paradigma da computação na nuvem traz igualmente benefícios e desafios ao ensino e à aprendizagem. Importa, portanto, descrever e caracterizar este conceito, para depois analisar o seu impacto e aplicação na aprendizagem.

## ***Cloud Computing***

O conceito de computação em nuvem (“*Cloud Computing*”) resulta de um modelo criado para permitir o acesso permanente (aumento de disponibilidade) através da rede, a um conjunto partilhado de recursos computacionais configuráveis (por exemplo, redes, servidores, armazenamento, aplicações e serviços), de forma rápida, com um mínimo de esforço de gestão ou de interação com o prestador do serviço.

Neste conceito, poderemos aferir cinco características essenciais, três modelos de serviço e quatro modelos de implementação (Mell & Grance, 2011). As características essenciais são:

- Recursos usados em função da necessidade: A alocação de mais ou menos recursos (tais como as capacidades de processamento ou armazenamento) é feita automaticamente sem a necessidade de intervenção humana com algum serviço do fornecedor; o sistema de pagamentos está indexado normalmente à sua utilização;
- Amplo acesso: Os recursos estão disponíveis através da rede Internet e são acedidos através de mecanismos que usam normas facilitando o uso de plataformas heterogéneas (por exemplo, portáteis, telefones celulares, laptops, etc.);
- Lista de recursos: Os recursos são organizados para acomodar um número variável de utilizadores, usando para isso diferentes recursos físicos e virtuais que são dinamicamente atribuídos em função da “procura” dos utilizadores; a localização dos recursos (país, cidade, centro de dados, ...) não é normalmente conhecida da maioria dos utilizadores;
- Elasticidade: A alocação de recursos deve ser rápida e dinâmica, admitindo subidas ou descidas significativas, durante intervalos de tempo variáveis (por exemplo, dias ou meses); para o cliente, os recursos disponíveis perspectivam-se numa quantidade ilimitada e acessível em qualquer momento;
- Serviço monitorizado: Controlo automático e otimização da utilização dos recursos, com métricas que tornam a utilização do serviço transparente (por

exemplo, armazenamento usado, processamento associado, largura de banda disponibilizada e contas de utilizadores ativos).

Os três modelos principais de serviços, habitualmente referidos na literatura, são os seguintes:

- *Software* como Serviço (SaaS, do inglês: *Software as a Service*): Uso de aplicações que funcionam numa infraestrutura alojada na *cloud* e que são disponibilizadas como sendo um serviço; as aplicações são acessíveis a partir de vários dispositivos cliente através de um interface “leve” como um navegador *Web* (por exemplo, acesso ao e-mail baseado na *Web*); salvo pequenas configurações e parametrizações ao nível da aplicação, o utilizador não administra nem controla as infraestruturas da *cloud* (rede, servidores, sistemas operativos, armazenamento, ou mesmo a própria aplicação); são exemplos o *Google Docs* e o *Microsoft SharePoint Online* (este é um dos modelos com mais abrangência e mercado, em termos globais);
- Plataforma como Serviço (PaaS, do inglês: *Platform as a Service*): Fornece uma plataforma de desenvolvimento de aplicações como um serviço, usando linguagens de programação e ferramentas de suporte do fornecedor do serviço da *cloud*; envolve habitualmente API e ferramentas de bases de dados; o cliente tem controlo sobre as aplicações desenvolvidas e, eventualmente, sobre alguns parâmetros de configuração do ambiente de hospedagem dessas aplicações; *Windows Azure*, *Google App Engine* e *Amazon EC2* são alguns exemplos;
- Infraestrutura como Serviço (IaaS, do inglês: *Infrastructure as a Service*): Disponibilização de uma porção dos recursos da infraestrutura (processamento, armazenamento, redes ou outros recursos); o cliente fica com a capacidade de controlar e configurar os recursos solicitados.

O ambiente de implementação, também sugere quatro modelos distintos:

- Privado: Toda a infraestrutura de *cloud* fica associada a uma só organização; a sua gestão pode ser feita pela própria organização ou por um fornecedor e pode residir ou não nas instalações dessa organização;

- **Comunidade:** A infraestrutura da *cloud* é partilhada por várias organizações e suporta uma comunidade específica que partilha as mesmas preocupações; pode ser administrada pelas organizações aderentes à comunidade ou pelo fornecedor de serviço ou ainda por um outro parceiro; normalmente esta opção é mais dispendiosa do que usar uma *cloud* pública, mas oferece um maior nível de privacidade e segurança;
- **Público:** A infraestrutura da *cloud* é disponibilizada ao público em geral, onde os recursos são oferecidos e vendidos de acordo com os requisitos dos utilizadores;
- **Híbrido:** A infraestrutura da *cloud* é uma composição de duas ou mais configurações (privada, comunidade, ou pública) que permanecem como entidades únicas, integradas por tecnologias (de preferência usando normas), permitindo portabilidade de dados e de aplicações (por exemplo, para balanceamento de carga entre as *clouds* e aumento da disponibilidade para aplicações ou dados críticos).

## **Instituições de Ensino na *Cloud***

Para as IE provavelmente uma primeira e interessante oportunidade em termos das vantagens associadas à *cloud* será a hospedagem de aplicações e o seu acesso através de um navegador (“*browser*”). Neste cenário, tanto dados como aplicações residirão na *cloud*.

Uma das principais motivações poderá ser a do custo, com poupanças ao nível da aquisição e manutenção do *hardware*, *software* e das despesas com o pessoal (técnico) para instalar, manter e disponibilizar as aplicações e serviços que as IE geralmente oferecem à sua comunidade.

De realçar que muitos dos serviços atualmente existentes nas próprias instituições estão muitas vezes subaproveitados.

Podem igualmente existir situações de sobrecarga momentânea ou sazonal no acesso a alguns serviços, que poderão mais facilmente ser minimizadas com a elasticidade oferecida pela *cloud* (através da sua distribuição de carga por múltiplos servidores).

A migração para a *cloud* poderá incidir somente sobre alguns serviços, deixando para mais tarde a mudança de outros ou dos restantes serviços (pode por exemplo passar a usar uma solução de *cloud* para o *email* e só mais tarde se incluírem as aplicações de edição de texto e de folha de cálculo).

Para dinamizar a implementação das soluções *cloud*, os seus principais fornecedores disponibilizam as suas soluções para as IE com preços bastante mais baixos que os de mercado, com o intuito de incentivar os estudantes na utilização das suas soluções (procurando que estes as continuem a usar quando deixarem o sistema de ensino).

A primeira aplicação *cloud* que as IE (incluindo em Portugal) estão a adotar é o correio eletrónico, com benefícios claros em termos das ações e recursos necessários para lidar com o “*spam*”, atualizações de *software* e alocação de espaço de armazenamento.

## 2.2 Sistemas Adaptativos

Com a adaptabilidade pretende-se que os sistemas possam ter respostas diferentes em função dos utilizadores.

Em termos de sistemas de apoio à aprendizagem, a adaptabilidade poderá ser conseguida com uma seleção adaptativa de conteúdos, um suporte a uma navegação igualmente adaptativa ou a apresentação de conteúdos ser ela própria adaptativa.

Para além da importância dos conteúdos de aprendizagem, da forma como eles são estruturados, representados, agrupados e distribuídos no processo de aprendizagem, é igualmente relevante a ordem pela qual os mesmos são explorados pelos alunos. Essa ordem pode decorrer de processos diferentes, tais como a sequenciação, a navegação e a apresentação.

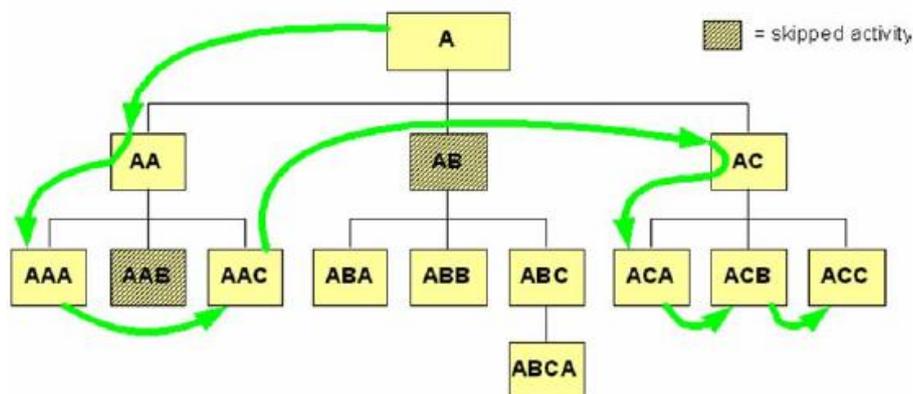
Desta forma, introduziremos na secção seguinte, alguns conceitos e trabalhos relacionados com a sequenciação e a navegação de conteúdos educativos.

## 2.2.1 Sequenciação e Navegação de Conteúdos

A sequenciação é normalmente associada ao processo responsável pela ordem em que os conteúdos de aprendizagem são apresentados aos alunos. Já o processo que permite ao aluno mover-se de um conteúdo de aprendizagem para outro é designado por navegação (Gutiérrez & Pardo, 2007).

As normas SCORM *Sequencing and Navigation*–SN (Advanced Distributed Learning, 2004) e IMS *Simple Sequencing*–SS (IMS Global Learning Consortium, 2003a) constituem dois trabalhos relevantes de organizações de normalização, que visam a normalização da representação e codificação do sequenciamento dos objetos de aprendizagem e dos eventos de navegação a suportar pelos LMS. Em ambos os trabalhos, a codificação do sequenciamento é baseada numa árvore de atividades. Incluem a especificação de pré-requisitos (atividades a terminar antes que se possam iniciar outras), caminhos alternativos de atividades de aprendizagem, regras que determinam as próximas escolhas ou caminhos possíveis. Suportam mensagens de interatividade com os alunos, controlos de navegação permitidos em cada etapa, dados e elementos associadas à avaliação (como a ponderação dos vários elementos), etc.. Neste tipo de soluções, em que a navegação e o sequenciamento de atividades são condicionados geralmente por regras, existe uma relevante complexidade no desenho dos eventos educativos, pois a determinação completa destas regras de sequenciamento sobre a árvore de atividades torna a definição de sequenciamentos sobre um curso muito difícil (Wan, Zhao, & Luo, 2006).

A norma IMS-SS estabelece um método para a definição da sequência das atividades de aprendizagem que inclui regras que descrevem o fluxo (ou ramificação) de atividades de acordo com os resultados da interação do estudante com essas atividades (ver figura 4). Apresenta contudo algumas limitações em termos de âmbito e de funcionalidade.



Fonte: (IMS Global Learning Consortium, 2003a)

**Figura 4 – Efeitos das Regras na Navegação numa Árvore de Atividades (IMS-SS)**

A especificação IMS *Learning Design*-LD oferece igualmente algumas ferramentas úteis que podem ser usadas para abordar o problema do sequenciamento de atividades, embora não tenha sido concebida especificamente para resolver aquela questão (IMS Global Learning Consortium, 2003b).

A norma SCORM-SN foi baseada na IMS-SS e é por isso muito similar a esta, no que diz respeito à especificação do sequenciamento e da navegação de atividades de aprendizagem.

Para além dos grupos e entidades de normalização, também alguns investigadores têm apresentado propostas alternativas para modelização dos processos de aprendizagem, geralmente vocacionadas para modelos adaptativos em “*e-Learning*”.

A proposta *UML Guide* usa os diagramas de estado do UML para modelização da adaptabilidade da navegação do utilizador num sistema hipermedia adaptativo. Neste modelo, os diagramas de estado são usados para visualizar os mapas de navegação, os nós representam os documentos e as setas as ligações entre eles (Dolog & NejdI, 2003).

Foi igualmente proposto a adição de alguma semântica a grafos para permitir a representação de diferentes sequências de conteúdos e a sua adequação às características individuais de cada aluno. Os nós dos grafos representam as unidades de aprendizagem que se interligam por arestas que possuem pré e pós condições associadas. Estas

condições vão determinar quais as unidades que poderão ser disponibilizadas em cada etapa, em função do histórico do aluno (Gutiérrez, Pardo, & Kloos, 2006).

Segundo Madjarov e Betari (2008), num sistema adaptativo, a sequenciação das unidades de aprendizagem quando centrada no aluno poderá ser realizada de várias formas:

- Seleção aleatória do LO até o aluno mostrar capacidade de resolução;
- Escolha do próximo LO baseado em ações ou nas respostas a questões colocadas pelo sistema de suporte, dos alunos;
- Seleção do LO com base no perfil do aluno;
- Pesquisa dos LO que melhor vão ao encontro do objetivo de aprendizagem tendo em conta o conjunto de conhecimentos e capacidades do aluno.

Para o aluno, alguns dos principais fatores que poderão influenciar essa sequenciação são (Gutiérrez & Pardo, 2007):

- Disponibilidade (para realizar ou não todas as atividades, incluindo as complementares ou de consolidação);
- Motivação (poderá influenciar a realização de certas atividades);
- Abordagem preferida (haverá alunos que preferem iniciar com exemplos antes de abordar os aspetos mais gerais e conceptuais, enquanto outros abordam mais facilmente os exemplos se tiverem tido, previamente, contacto com os conceitos gerais);
- Conhecimento prévio (que poderá fazer com que o aluno opte por não realizar uma dada atividade que se mostre redundante face aos seus conhecimentos prévios).

O processo de sequenciamento pode ser assente em modelos estáticos ou adaptativos. Nos primeiros, a adaptabilidade poderá ser prevista no desenho do curso (ou do evento de aprendizagem) onde são estabelecidos diversos sequenciamentos (baseados em regras que os determinam) possíveis para os vários alunos. Nestes modelos estáticos, normalmente não existem mudanças no tempo e não são incluídos novos conteúdos, o

que lhes confere uma validade limitada. Porque são normalmente definidos por um único professor, também não são isentos de erros. Uma outra limitação deriva do facto do professor poder desconhecer outros conteúdos, mais relevantes para um dado aluno ou grupo de alunos. Também um bom desenho de um curso para o presente poderá não ser o desenho mais adequado no futuro.

A interação social é um dos fatores que tem sido estudado na determinação do sequenciamento dinâmico das atividades de aprendizagem. O conhecimento do comportamento dos vários grupos sociais na vida real (grupos de estudantes, professores, ...) pode ser muito útil, possibilitando que os sistemas se ajustem aos interesses de cada utilizador. Dados associados a cada aluno, como medidas de progresso, de avaliação, do tempo necessário para explorar os conteúdos, a definição de etiquetas ('tags') sobre os conteúdos, são alguns exemplos de parâmetros que permitirão aos sistemas identificar sequenciamentos mais atrativos e eficazes aos alunos (sequenciamento social).

Alguns trabalhos exploraram estas ideias, através do conhecimento e registo do comportamento de outros utilizadores. Baseados nas atividades concluídas com sucesso (Koper, 2005) ou no comportamento de certos grupos de utilizadores (Iglesias, Martínez, Aler, & Fernández, 2004), novas atividades de aprendizagem são sugeridas pelos sistemas. O uso de anotações, contendo a indicação de quantos alunos já realizaram e quantos terminaram com sucesso uma dada atividade foi igualmente proposto num outro trabalho (Gutiérrez & Pardo, 2007).

## **2.2.2 Modelos Adaptativos aplicados ao Ensino**

Geralmente, os sistemas adaptativos aplicados ao ensino baseiam-se sobretudo nas competências pretendidas, nos perfis e necessidades dos alunos e na definição de regras e/ ou algoritmos que conduzem/ geram a adaptabilidade.

São vários os trabalhos que envolveram a adaptabilidade em sistemas de suporte ao ensino, em particular sobre páginas hipermedia. Os seus objetivos visam essencialmente tornar esses sistemas mais adequados às preferências e ao conhecimento específico de

cada aluno, esperando com isto, garantir aos alunos experiências mais motivadoras e satisfatórias.

Oppermann (1994, p. 456) refere que os sistemas hipermídia adaptativos para o ensino devem ser capazes de “adaptar as suas próprias características automaticamente de acordo com as necessidades dos utilizadores”.

A primeira tecnologia tem as suas origens na área de busca de informação (IR do inglês: *Information Retrieval*) e procura dar uma resposta adaptativa a uma pesquisa de um dado utilizador, através da seleção e priorização dos itens que lhe serão mais relevantes.

A navegação adaptativa poderá ser conseguida com uma manipulação das hiperligações disponíveis (esconder, reordenar, destacar, etc.) por forma a guiar o utilizador para os itens que lhe serão mais relevantes.

Com a apresentação adaptativa o conteúdo que é disponibilizado a cada utilizador deverá ser o mais relevante. A combinação destas diferentes formas é proposta em diversos trabalhos.

Os sistemas adaptativos são tipicamente de dois tipos: estáticos ou dinâmicos. Se pensarmos na área de aplicação ensino, os sistemas estáticos, característicos de um modelo “*one-size-fits-all*” produzem as mesmas experiências de aprendizagem a todos os alunos, independentemente dos seus conhecimentos, da sua experiência, das suas preferências e dos seus objetivos (Stewart, Cristea, Brailsford, & Ashman, 2005).

Com o desenho de sistemas dinâmicos, pretende-se que as experiências possam ser adequadas e exclusivas a cada aluno, possam evoluir no tempo, reconhecendo o histórico de experiências e os objetivos existentes em cada momento e para cada um.

Geralmente, os sistemas adaptativos baseiam-se sobretudo nas competências pretendidas, nos perfis e necessidades dos alunos e na definição de regras e/ ou algoritmos que conduzem/ geram a adaptabilidade. Henze e Nejdil (2004) apresentaram uma definição formal para estes sistemas, como sendo um quadruplo (DOCS, UM,

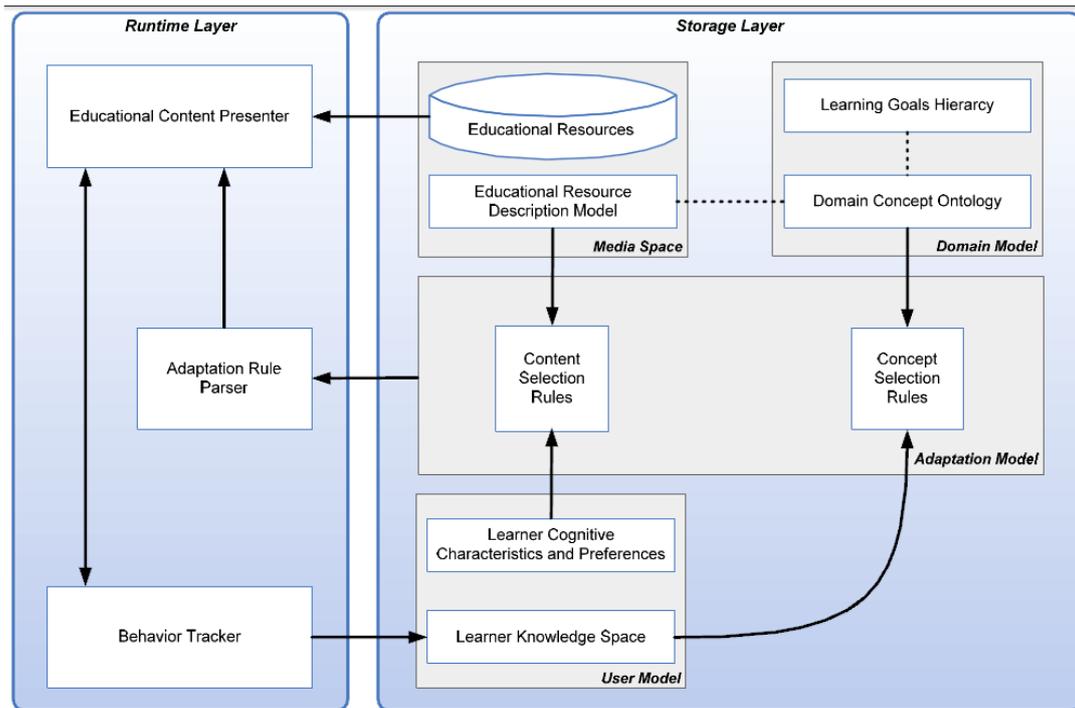
OBS, AC) formado pelos seguintes componentes, de acordo com as suas funções no sistema:

- DOCS: Espaço de Documentos;
- UM: Modelo do Utilizador;
- OBS: Observações;
- AC: Componente de Adaptabilidade.

No primeiro componente são tratadas as informações sobre os documentos e sobre os relacionamentos entre os mesmos. No modelo do utilizador são geridas as informações que permitem caracterizar utilizadores e grupos de utilizadores. Durante a execução o sistema regista as interações com os utilizadores. Baseado na organização dos documentos, nos dados sobre o utilizador registados no modelo do utilizador e nas observações, o sistema irá gerar a adaptabilidade pretendida, de acordo com os diferentes tipos de regras que possam ter sido definidas. As regras servem tipicamente dois propósitos: seleção de conceitos e seleção de conteúdos.

## **Modelo de Referência AHAM**

Um trabalho que se destacou na definição destes sistemas foi o modelo de referência AHAM - *Adaptive Hypermedia Application Model* (Bra, Houben, & Wu, 1999) que serviu de inspiração para diversas implementações, tais como o sistema AHA! (Bra et al., 2003). A arquitetura genérica AHAM ilustrada na figura 5 sugere vários modelos.



Fonte: (Karampiperis & Sampson, 2005)

**Figura 5 - Arquitetura Genérica de Sistemas Hipermedia Adaptativos de Educação**

O modelo domínio considera as hierarquias de objetivos de aprendizagem e os correspondentes conceitos associados a esses objetivos.

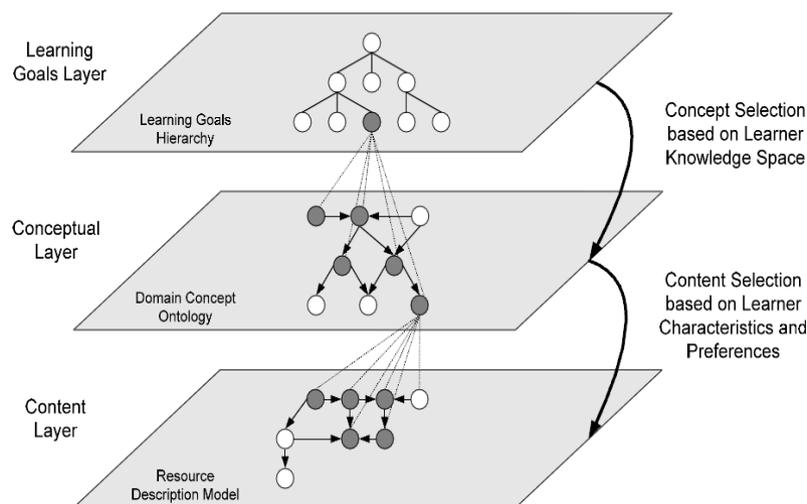
No modelo utilizador é implementado o estado do conhecimento e das preferências dos alunos (o estado do aluno resulta da análise dos conceitos adquiridos, de entre os definidos no modelo domínio, ou das características do grupo de alunos a que ele seja associado, onde para todos os alunos de um mesmo grupo se associam as mesmas características, as mesmas competências adquiridas, as mesmas competências a adquirir, etc.).

No gestor de conteúdos são guardados os conteúdos educativos, juntamente com a indicação das suas características e das relações (de dependência) entre eles. Para cada conteúdo são ainda especificados os conceitos associados.

É no modelo adaptativo que, com recurso às regras de seleção de conceitos e de conteúdos, são determinados os conceitos necessários assim como os correspondentes conteúdos a propor, a cada aluno.

## Sequenciamento em Sistemas Adaptativos

O sequenciamento de conteúdos neste tipo de sistemas adaptativos é baseado em dois processos principais, nomeadamente o processo de seleção de conceitos e o processo de seleção de conteúdos (ver figura 6).



Fonte: (Karampiperis & Sampson, 2005)

**Figura 6 - Níveis de abstração do processo de Sequenciamento em Sistemas Adaptativos**

No primeiro processo, um conjunto de objetivos é selecionado para cada aluno. Para cada objetivo, são determinados os conceitos relacionados, depois de aplicadas as regras de seleção de conceitos, que comparam os conceitos definidos no modelo domínio com o estado de conhecimento do aluno (conceitos registados no modelo utilizador). Esta lista de conceitos é depois filtrada tendo por base os conhecimentos que cada aluno já obteve. Essa lista de conceitos resultante indica os conceitos necessários para o aluno atingir os objetivos pretendidos (ou selecionados).

O processo de seleção de conteúdos determina todos os conteúdos associados a cada conceito da lista obtida no primeiro processo, após aplicação das regras de seleção de conteúdos existentes, que relacionam as características dos conteúdos com as características cognitivas e com as preferências dos alunos. No final, obtém-se um

caminho de aprendizagem personalizado, adequado aos objetivos de aprendizagem de cada aluno.

As abordagens para a definição das regras de seleção de conteúdos caem geralmente em duas categorias: definição direta pelo responsável do desenho do curso ou indireta, recorrendo a modelos pré-definidos pelo mesmo responsável. No primeiro, exige-se a definição das regras no processo de desenho, exigindo um conhecimento mais profundo de todos os parâmetros de adaptação existentes. No segundo caso, cada modelo já contém regras de seleção de conteúdos associadas, sendo reaproveitadas.

De realçar que o desenho deste tipo de sistemas, quando baseado em regras, pode ser muito complexo, uma vez que existe normalmente um grande número de dependências entre as características dos conteúdos e dos alunos o que causa um grande número de condições (por forma a que sejam incluídas todas as possíveis combinações). Esta grande complexidade (Wu & Bra, 2001) cria diversos problemas na definição das regras, nomeadamente:

- Inconsistência (conflito entre regras);
- Confluência (regras equivalentes);
- Insuficiência (ausência de regras necessárias).

## **Trabalhos Relacionados**

Outras abordagens têm sido propostas tendo como objetivo principal dotar os sistemas de adaptabilidade, tais como usar regras combinadas com algoritmos de otimização para geração de sequenciamento adaptativo de atividades (Luis De-Marcos, Martínez, Gutiérrez, & Gutiérrez, 2009), usar somente algoritmos sem quaisquer regras (Seki, Matsui, & Okamoto, 2003; Karampiperis & Sampson, 2005), ou propor as novas atividades de aprendizagem em função de dados das avaliações que os alunos vão obtendo em cada etapa da aprendizagem (Madjarov & Betari, 2008; Lin, Tseng, Weng, & Su, 2009).

Relacionado com outras áreas de investigação, outras soluções têm sido propostas mantendo o enfoque na adaptabilidade dos sistemas. A nossa proposta recaiu nos sistemas de recomendação que se baseiam em informações de alunos, de conteúdos e das interações entre ambos para propor aos alunos que conteúdos selecionar, de forma adaptativa. Por essa razão iremos, no próximo capítulo, abordar com razoável detalhe os principais conceitos associados a esses sistemas.



## Capítulo 3

### Temas e Trabalhos Relacionados

Neste capítulo daremos particular destaque aos sistemas de recomendação, uma vez que a nossa solução de adaptabilidade se baseou neste tipo de sistemas. Para além dos conceitos base, descrevemos os seus diferentes tipos e a sua aplicação aos processos de aprendizagem. Na última secção serão considerados os diversos fatores e critérios que deverão assistir à sua avaliação, nas suas diferentes dimensões e em concreto, quando aplicados ao ensino.

#### 3.1 Sistemas de Recomendação

Nesta secção iniciamos a abordagem aos Sistemas de Recomendação (SR), à sua proximidade aos sistemas de recuperação e de filtragem de informações, conceitos, domínios de aplicação, motivações, funções e dados necessários a esses sistemas.

##### 3.1.1 Primeiros Sistemas

No início dos anos 90, com a expansão e crescimento da utilização da Internet, o crescente volume de informação veio criar problemas e exigir esforços adicionais nas tarefas de pesquisa e seleção da informação pretendida, aos seus utilizadores. Nalgumas aplicações existem centenas de milhares de produtos (como é o caso dos livros da

Amazon.com) acessíveis aos utilizadores/ consumidores. Não só a quantidade passou a ser um problema, como o próprio utilizador passou a ser mais exigente, desejando ter respostas, se possível, adequadas aos seus interesses.

Como resposta a estas questões surgiram os primeiros SR. A ideia que está na base de um SR é simples e próxima da prática. De facto, também no seu dia-a-dia, as pessoas tomam as suas decisões suportadas nas sugestões de outras pessoas, colegas, amigos ou familiares (Mahmood & Ricci, 2009). Quando decidimos ler um livro por que alguém conhecido, que já o leu, nos sugeriu que o fizéssemos, ou quando vamos ao cinema ver um filme baseado nas sugestões de alguma crítica de jornal, ou quando alguém contrata um funcionário devido às boas referências que recebeu dos seus outros empregadores, estamos, no concreto, a usar a mesma ideia.

Em termos gerais, os SR procuram gerar recomendações para cada utilizador, usando a informação agregada que recolhem da interação dos utilizadores com esses sistemas. As recomendações vão no sentido de adequar as respostas aos interesses de cada utilizador.

Os primeiros exemplos provêm dos anos 90. A designação “Filtragem Colaborativa” (FC) foi introduzida no primeiro SR comercial, denominado *Tapestry* (Goldberg, Nichols, Oki, & Terry, 1992). Sendo manual, este SR foi desenvolvido para grupos de trabalho, onde cada utilizador podia pesquisar conteúdos (tais como *emails*) baseando-se nas opiniões ou ações de outros utilizadores (“quero todas as mensagens que um dado utilizador reencaminhou”). Ao concluir o acesso a cada item (no final da leitura de cada artigo), solicitava-se a cada utilizador que efetuasse uma avaliação sobre o mesmo.

O sistema *GroupLens* (Resnick, Iacovou, Suchak, Bergstrom, & Riedl, 1994) usava as avaliações produzidas pelos seus leitores sobre um serviço de notícias (“*usenet news*”) para gerar e disseminar automaticamente as estimativas sobre o interesse de leitura dos artigos ainda não lidos, pelos leitores similares. Baseava-se na ideia de que os utilizadores de um dado grupo com interesses similares no passado teriam interesses similares no futuro. Os testes com este sistema demonstraram resultados interessantes, tendo-se verificado que um muito maior número de leitores acedia aos artigos com maiores estimativas de avaliação, assim como se verificou uma maior fidelidade ao sistema (um significativo número de leitores manteve-se no sistema por mais tempo).

Nos primeiros SR, as soluções abrangiam normalmente um reduzido número de utilizadores e tinham como objetivos não só gerar recomendações, mas também disseminá-las. Como exemplos desses primeiros sistemas, temos o *Ringo* (Shardanand & Maes, 1995) que recomendava músicos e o *Bellcore* (Hill, Stead, Rosenstein, & Furnas, 1995), que enviava recomendações de filmes por correio eletrónico aos seus fãs.

As primeiras aplicações com grande impacto e que contribuíram de forma relevante para o grande impulso dos SR foram a Amazon.com, com as sugestões sobre livros e a Netflix.com, na área dos filmes. Baseados nos históricos de compras, de navegação e no artigo ativo, estes sistemas recomendam outros artigos para o utilizador poder analisar e comprar.

E foi, precisamente, impulsionados pela busca de maiores vendas que os SR, a partir do final dos anos 90, beneficiaram de inúmeras investigações, desenvolvimentos e implementações, em especial, no domínio do negócio eletrónico. Com os SR os utilizadores (neste contexto, consumidores) passaram a obter conselhos personalizados para os produtos a adquirir. Para as empresas, estes sistemas representavam uma forma de dar a conhecer aos consumidores novos produtos (e com isso, aumentarem as suas vendas).

Entretanto, para além de inúmeros artigos de investigação, foram igualmente escritos livros especificamente sobre o tema (Ricci, Rokach, Shapira, & Kantor, 2010; Jannach, Zanker, Felfernig, & Friedrich, 2010) e surgiram conferências científicas dedicadas exclusivamente a este tópico (“*ACM Recommender Systems Conference*”).

De destacar o concurso anual lançado pela Netflix.com, em 2006, com um prémio de 1 milhão de dólares para o primeiro investigador que proponha um algoritmo de recomendação para filmes que melhore, em 10%, os resultados do algoritmo usado.

A investigação iniciada com os algoritmos de FC permitiu o desenvolvimento de outras abordagens com diferentes algoritmos, algumas das quais referidas mais adiante, neste documento. Com a adoção de outras técnicas foi possível compreender que os SR baseados numa mesma componente de recomendação não têm uma utilização genérica,

ou seja, não constituem uma solução “*one-size-fits-all*”. De facto, os SR deverão ser desenhados especificamente de acordo com os objetivos pretendidos, com as tarefas ou funções adequadas para a componente de recomendação, tendo em conta as necessidades de informação associadas e, fundamentalmente, o respetivo domínio de aplicação.

Os SR são hoje uma área de investigação de elevado dinamismo, onde se cruzam interesses de diversas áreas (Melville & Sindhvani, 2010), tais como certas subdisciplinas da estatística, aprendizagem de máquina, mineração de dados e de sistemas de recuperação (IR) e de filtragem de informação (IF, do inglês: *Information Filtering*).

Apresentaremos em seguida, de forma sucinta, alguns conceitos de áreas que se apresentam relevantes para os SR.

### 3.1.2 Conceitos relevantes de outras Áreas

Os sistemas de indexação e recuperação de informação armazenam, indexam e pesquisam conteúdos com base na informação que lhes é associada. Embora distintos, ambos os sistemas, IR e IF, cooperam para ajudar as pessoas a obter a informação de que necessitam. Segundo Belkin e Croft (1992) são “os dois lados de uma mesma moeda” (p. 9). Ambos avaliam e classificam dados semiestruturados ou não estruturados (textos) por ordem de relevância.

Nos sistemas IR, a seleção faz-se sobre um conjunto de documentos relativamente estático, enquanto nos sistemas IF a pesquisa inclui também dados dinâmicos (*emails*, multimédia, entre outros).

Nos sistemas IR as pesquisas representam necessidades pontuais, momentâneas, de um dado utilizador, enquanto nos sistemas IF as pesquisas procuram responder a interesses de maior duração, associados às características existentes nos perfis de um utilizador ou de um grupo de utilizadores e que, por isso, tendem a ser repetíveis. A inclusão, nos perfis dos utilizadores, de informações sobre os itens que não lhes interessam (itens

negativos, que não pretendem receber), permite que nas suas respostas, os sistemas IF não só incluam os itens positivos como também excluam os negativos. Os sistemas IF dão ainda particular destaque à validade e oportunidade temporal dos itens resultantes das pesquisas, assim como à privacidade dos seus utilizadores, aspetos que não são normalmente considerados pelos sistemas IR (Belkin & Croft, 1992).

Estes sistemas recorrem a variadíssimos métodos e algoritmos. Uma das técnicas mais simples é a pesquisa baseada em palavras-chave. As respostas, para este tipo de pesquisas, devolvem os itens que contêm as palavras constantes na pesquisa. Esta técnica possui algumas limitações, tais como a homonímia (palavras com grafia e pronúncia iguais, porém diferentes significados em diferentes contextos; a homonímia é por vezes usada indistintamente com a palavra polissemia) e a sinonímia (várias palavras com grafia diferente mas com o mesmo significado), que conduzem muitas vezes a resultados inesperados ou indesejáveis. A inclusão dos operadores booleanos (“E”, “OU”, “NÃO”) neste género de pesquisas, não só mantém os problemas referidos, como dificulta a criação da pesquisa pelo utilizador vulgar. Alguns dos atuais sistemas tais como o Altavista<sup>11</sup> e o Lycos<sup>12</sup>, entre muitos outros, usam esta abordagem. A inclusão de tesouros, também conhecidos como dicionários de ideias afins, foi explorada em várias soluções procurando minimizar estes problemas, associados ao vocabulário.

Procurando respostas mais eficazes aos problemas referidos da sinonímia e polissemia, foram aplicadas técnicas mais sofisticadas, tais como o modelo de espaço vetorial e a indexação semântica latente.

O modelo de espaço vetorial (VSM em inglês: *Vector Space Model*) baseia-se na ocorrência estatística de termos (ou palavras) e adquiriu significativo relevo neste tipo de sistemas (Salton & McGill, 1986). Usa uma matriz de palavras por documentos (TDM, do inglês: *Term-Document Matrix*) em que a interseção nos dá a frequência das palavras em cada documento. Com essa matriz constroem-se vetores representativos dos documentos (um vetor para cada documento). A aplicação da medida do cosseno entre dois vetores permite determinar da similaridade entre os documentos (um ângulo

---

<sup>11</sup> [www.altavista.com](http://www.altavista.com)

<sup>12</sup> [www.lycos.com](http://www.lycos.com)

menor, significa um maior cosseno e uma maior similaridade entre dois vetores, neste caso, documentos). Normalmente, a aplicação deste método inclui adicionalmente a ponderação *tfidf*, que calcula o produto das duas estatísticas, designadamente a *tf* (*Term Frequency*) e a *idf* (*Inverse Document Frequency*). O seu cálculo permite obter uma estimativa da importância de uma dada palavra num documento ou numa coleção de documentos. A primeira medida estatística, *tf*, mede a frequência dos termos num documento e a segunda, *idf*, indica-nos se um termo é comum ou raro em todos os documentos. Com esta segunda estatística procura-se reduzir o peso dos termos que surgem em todos os documentos, evitando que os termos raros sejam menos relevantes. Para além da aplicação da medida *tfidf* e para evitar que os documentos maiores tenham preferência sobre os mais pequenos, os vetores resultantes podem ser normalizados usando a fórmula do cosseno (ver formulação em apêndice 1).

A indexação semântica latente (LSI, do inglês: *Latent Semantic Indexing*) designa o método de indexação e recuperação de informações que utiliza o processo matemático de factorização matricial. Este método é usado para identificar padrões nos relacionamentos entre termos e conceitos presentes nos textos. Assenta na ideia de que as palavras que são usadas nos mesmos contextos devem possuir significados similares e que por isso surgirão em porções de textos similares. Tal como o modelo de espaço vetorial, recorre a matrizes de palavras-documentos. Para redução do número de colunas das matrizes a considerar, procurando preservar a similaridade entre as linhas, é usada a técnica de decomposição de valor singular (SVD, do inglês: *Singular Value Decomposition*). Esta técnica, face à técnica apresentada anteriormente, do modelo de espaço vetorial, apresenta como vantagens usar vetores mais reduzidos e a filtragem não se restringir a uma análise lexical, uma vez que a informação é organizada em estruturas semânticas (ou conceptuais), que permitem melhores respostas às pesquisas. De realçar que o problema da redução da dimensionalidade é muito relevante nos SR, devido à existência de dados esparsos, conforme será referido mais adiante neste documento.

Outras técnicas, tais como o método “*spreading activation*” e o uso de redes semânticas, surgem igualmente nas principais referências (Crestani, 1997).

As técnicas de *feedback* de relevância (“*relevance feedback*”) consideram a relevância (ou não) obtida sobre os resultados das pesquisas, pelos respetivos utilizadores, na

realização de novas pesquisas. Tipicamente, um dado utilizador ao receber os resultados de uma pesquisa indica quais deles são relevantes e quais não são. Esta informação permitirá atualizar o perfil desse utilizador e assim influenciar as próximas pesquisas (que consideram o seu perfil atual, sempre que novas pesquisas são efetuadas). Este princípio é explorado pelo método *Rocchio* (ver formulação em apêndice 2). Neste método é proposta a criação de um novo perfil do utilizador baseado num perfil anterior e nos vetores representativos dos documentos relevantes e não relevantes da pesquisa anterior (Rocchio, 1971). No âmbito dos SR é usado nas abordagens baseadas em conteúdo, nomeadamente no processo de aprendizagem dos perfis de utilizadores.

Estes sistemas, IR e IF, apesar dos grandes desenvolvimentos recentes, continuam a ter algumas limitações, essencialmente porque os seus resultados continuam a ser, normalmente, listas grandes (ou mesmo enormes), de difícil análise e tratamento. Por outro lado, neste tipo de pesquisas os resultados produzidos não procuram ter em consideração os interesses, necessidades e gostos dos utilizadores, pois não são personalizados. Uma das razões para esta ausência de personalização nos sistemas originais, de IR e IF, deriva do facto de não serem consideradas as técnicas de filtragem social, baseando-se apenas nos conteúdos dos documentos. São precisamente estas técnicas, de filtragem social, que usam os relacionamentos das pessoas, as suas avaliações e opiniões, a base dos SR.

### 3.1.3 Conceitos e Formulação

Segundo Melville e Sindhvani (2010) “o objetivo de um SR é gerar recomendações relevantes de itens ou produtos para um conjunto de utilizadores que neles possam estar interessados” (p. 1).

As recomendações recaem normalmente sobre um dado tipo de item e usam uma ou mais técnicas de recomendação. Devem também ser personalizadas, ou seja, devem ser consideradas úteis e desejadas pelo utilizador destinatário (designado geralmente por utilizador ativo). Baseiam-se essencialmente no comportamento de outros utilizadores e no conhecimento das preferências e/ ou necessidades de cada um. Usam metodologias que permitem gerar recomendações resultantes de informação que vai sendo agregada a

partir da interação dos utilizadores com o sistema. Produzem respostas com mensagens do tipo: "quem comprou este artigo, também comprou os seguintes..." e incluem normalmente classificações e/ ou 'tags' sobre os itens que pretendem recomendar (ver o exemplo seguinte).

The screenshot displays a product page for the book "Recommender Systems: An Introduction" by Dietmar Jannach, Markus Zanker, Alexander Felfernig, and Gerhard Friedrich. The page includes a "Customers who viewed this item..." section with a book cover and a "Review" section. Below this, there is an "Also viewed these items..." section featuring three recommended books: "Recommender Systems Handbook", "Algorithms of the Intelligent Web", and "Programming Collective Intelligence: Building Smart Web 2.0 Applications". Each book has a "More like this" button.

Figura 7 - Recomendações personalizadas no site Amazon.com

Estes sistemas constituem uma importante ajuda quando o número de itens existente é demasiado grande para ser explorável ou acedido facilmente. Em muitos sistemas, não só o número de itens é grande, como alguns deles podem ser alternativos entre si.

Um dos SR de maior sucesso é o que assiste a pesquisa de livros na loja Amazon.com, com respostas personalizadas para cada cliente. Esta personalização permite que diferentes clientes ou grupos de clientes recebam diferentes sugestões. De referir, no entanto, que em certos SR as recomendações podem não ser personalizadas. Outros sistemas oferecem simultaneamente recomendações personalizadas e não personalizadas. Uma resposta não personalizada poderá ser a lista de itens (livros, CDs, etc.) mais selecionados ou comprados, já que essa lista será igual para qualquer utilizador. Estes sistemas, ao não exigir e ao não ter que processar os dados necessários à personalização, possuem normalmente uma menor complexidade.

Em termos de investigação, a área dos SR tornou-se independente a meio da década de 90. Numa das suas iniciais formulações, o problema da recomendação é reduzido à tarefa de predição da avaliação de um item ainda não avaliado pelo utilizador ativo.

Tipicamente são calculadas todas as estimativas de avaliação para todos os itens ainda não avaliados por esse utilizador e os itens de maior valor estimado são lhe apresentados como recomendações. Adomavicius e Tuzhilin (2005) propuseram a seguinte formulação:

$$\forall c \in C, s'_c = \arg_{s \in S} \max u(c, s) \quad (1)$$

Em que:

$C$ : conjunto de todos utilizadores;

$S$ : conjunto de todos os itens que podem ser recomendados;

$u$ : função utilidade que mede a utilidade do item  $s$  para o utilizador  $c$ :

$u: C \times S \rightarrow R$ , onde  $R$  é um conjunto de valores totalmente ordenado e para cada utilizador  $c$  pertencente a  $C$  pretende-se escolher o artigo  $s'$  pertencente a  $S$  que maximiza a utilidade para esse utilizador.

A avaliação consiste num triplo (utilizador, item, avaliação) e o conjunto de todos os triplos forma uma matriz esparsa designada por matriz de avaliações ou matriz utilizador-item (ver Tabela 2). De notar que a matriz diz-se esparsa porque normalmente a maioria dos elementos da matriz está vazia, uma vez que cada utilizador apenas avalia um pequeno conjunto dos itens disponíveis.

**Tabela 2 - Exemplo de Matriz Utilizador x Item com classificações binárias**

	Shrek	Snow White	Spider-man	Super-man
Alice	Like	Like		Dislike
Bob		Like	Dislike	Like
Chris		Dislike	Like	
Tony	Like		Dislike	?

Fonte: (Su & Khoshgoftaar, 2009)

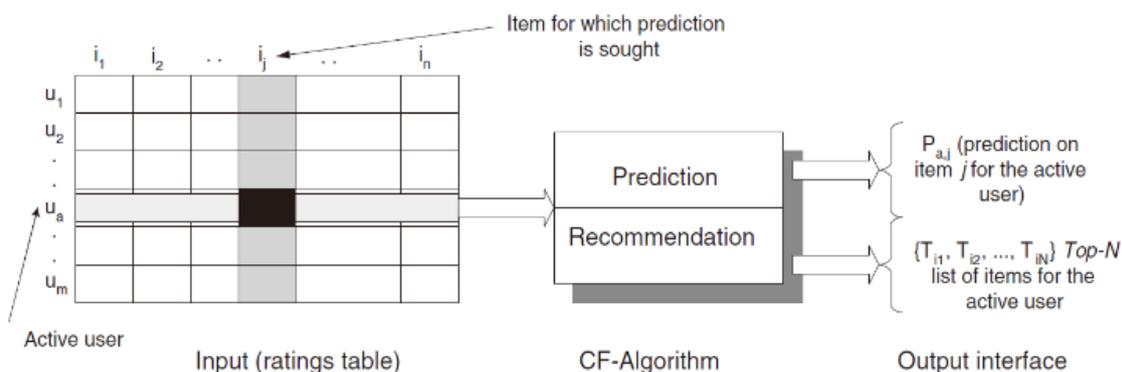
Na tabela 2, as células marcadas com ‘?’ indicam que o utilizador não avaliou o item e as células vazias indicam que o utilizador não seleccionou o item. As recomendações incidem precisamente sobre os itens ainda não seleccionados.

De acordo com o tipo de avaliação solicitada, a matriz referida poderá ter diferentes valores. Veja-se um outro exemplo para avaliações entre 1 e 5, na tabela seguinte:

Tabela 3 - Exemplo de Matriz Utilizador x Item com classificações numéricas

	$I_1$	$I_2$	$I_3$	$I_4$
$U_1$	4	?	5	
$U_2$	4	2	1	2
$U_3$	3			
$U_4$	4	4		?
$U_5$	2			5

É sobre os dados da matriz utilizador-item que é aplicado o algoritmo de recomendação. Regra geral, esse algoritmo irá estimar a classificação para o item a recomendar ou irá criar uma lista com os itens mais recomendados ordenada pela estimativa de avaliação para o utilizador ativo (ver figura 8).



Fonte: (Sarwar B., Karypis, Konstan, & Riedl, 2001)

**Figura 8 - Processo Genérico de Recomendação**

Para concluir esta breve apresentação sobre os conceitos base associados a este tema, falta-nos explicar alguns dos termos relacionados usados ao longo deste documento: ao referirmos as classificações que os SR produzem ou que os utilizadores registam, estamos igualmente a falar de avaliações, pelo que ambos os termos são usados de forma indistinta; estimativa, predição ou previsão da avaliação, são igualmente usados com o mesmo significado; o termo de utilizador ativo pretende descrever o utilizador que está a interagir com o SR; a designação de item, em concreto, terá o significado que o domínio da aplicação considerar, ou seja, poderá significar um livro, uma música, uma notícia, um conteúdo educativo, etc.

### 3.1.4 Domínios de Aplicação

Embora sejam recentes, atualmente os SR já surgem integrados em muitas aplicações de diversos domínios. Esses domínios foram agrupados nas seguintes classes (Ricci et al., 2010), tendo em conta as aplicações mais comuns, onde esses sistemas são encontrados:

- Entretenimento – recomendações para filmes, músicas e programas de televisão;
- Conteúdos – jornais personalizados, recomendações de documentos, páginas *Web*, ensino à distância, filtros de correio eletrónico;
- Negócio eletrónico – recomendações para consumidores de produtos, tais como livros, câmaras fotográficas e vídeo, computadores, impressoras, etc.;
- Serviços – recomendações de viagens, de especialistas de diversas áreas, de casas para alugar, etc.

Mais recentemente, certos SR têm aproveitado o potencial das redes sociais para, também aí, desenvolverem as suas recomendações.

De reforçar que a caracterização do domínio de aplicação, dos seus requisitos, limites e objetivos influenciam o desenho do SR, designadamente nas técnicas de recomendação a adotar e no desenho do interface com o utilizador.

### 3.1.5 Motivações

Apesar da grande complexidade de certas implementações dos SR, os seus implementadores possuem variadíssimas motivações, algumas delas extremamente lucrativas ou mesmo cruciais para a sua atividade. As principais motivações são (Ricci et al., 2010):

- Aumentar o número de itens vendidos / acedidos – particularmente relevante nas lojas comerciais, a recomendação de itens adicionais, geralmente similares, que poderão ser do interesse de cada utilizador, pretende conduzir o utilizador a

aceder a informações e potencialmente a adquirir itens (quando aplicável) que, de outra forma, nem teria sequer pensado em consultar e/ ou adquirir (se não lhe tivessem sido propostos);

- Propiciar maior diversidade de itens – para além dos itens determinados como adequados aos interesses de cada utilizador, resultantes da pesquisa habitual, a sugestão complementar de outros itens, propicia uma maior diversidade de itens divulgados;
- Melhorar a satisfação do utilizador – a combinação de um sistema que associa recomendações fiáveis e ajustadas aos interesses do utilizador a um interface bem desenhado, certamente levará o utilizador a reutilizar o sistema;
- Aumentar a fidelidade do utilizador – o utilizador reconhece e valoriza um sistema que considera as transações anteriores, as suas anteriores escolhas e classificações e onde o refinamento do modelo de utilizador permitirá uma crescente otimização nas futuras interações;
- Melhor conhecimento dos interesses do utilizador – propiciará a oferta de outros bens ou serviços.

De realçar que a implementação dos SR deve ter em linha de conta, não só as motivações dos fornecedores (dos itens) como também os interesses e requisitos dos próprios utilizadores, evitando que os interesses dos primeiros se sobreponham aos dos segundos.

### 3.1.6 Funções

Em vários artigos de referência sobre SR (Herlocker, Konstan, Terveen, & Riedl, 2004; Ricci et al., 2010), foram identificadas as seguintes funções principais que estes sistemas deverão oferecer e implementar:

- Recomendar alguns itens adequados - resulta uma lista com sugestões de itens (exemplo: sugerir lista de páginas *Web* a visitar);
- Recomendar todos os itens adequados - resulta uma lista com todos os itens relevantes (exemplo: sugerir lista completa de referências sobre um tópico);

- Efetuar anotações em contexto – propiciar recomendações enquanto o utilizador está a fazer outras tarefas ou simplesmente a navegar, relacionadas com o contexto dessa navegação (exemplo: incluir a recomendação de um item relacionado com um dado domínio numa página contendo informações de outro domínio, tal como recomendar o acesso a uma página *Web* de um dado alojamento, por exemplo quando o utilizador consulta uma página sobre uma dada cidade);
- Recomendar uma sequência - em vez de gerar uma só recomendação, propor uma lista ordenada de itens a seleccionar (exemplo: propor uma lista de músicas);
- Recomendar durante a navegação - na navegação entre páginas *Web* efetuar sugestões (exemplo: propor compras de artigos similares ao que consta da página ativa ou seleccionada);
- Funções de demonstração da credibilidade do SR - disponibilizar funcionalidades que permitam ao utilizador testar as respostas do SR, procurando que o utilizador adquira bons níveis de confiança com o sistema, especialmente na fase inicial;
- Recomendar um grupo de itens – propor várias recomendações de alguma forma relacionadas com a principal (por exemplo, num SR que proponha um dado destino, poderá associar recomendações relacionadas com alojamento, transporte, diversões, etc. (Ricci, Cavada, Mirzadeh, & Venturini, 2006));
- Editar e melhorar o perfil de utilizador – tarefa essencial que permitirá ao utilizador editar os seus interesses e necessidades, que refletem o seu perfil; deverá estar sempre disponível, para que o utilizador o faça sempre que entender;
- Contribuição autónoma – permitir que utilizadores possam exprimir os seus interesses e avaliações, mesmo que estes não tenham qualquer interesse em obter recomendações, ou que apenas tenham esse interesse pontualmente;
- Influenciar outros utilizadores – a possibilidade de avaliar os itens de forma a influenciar as recomendações trata-se de uma funcionalidade que deverá ser equacionada e analisada sob o ponto de vista ético e do próprio interesse do fornecedor.

### 3.1.7 Dados

Os SR baseiam-se essencialmente em dados sobre os itens a recomendar, sobre os utilizadores que recebem as recomendações e sobre as transações, provenientes das relações estabelecidas entre itens e utilizadores. A estrutura e quantidade de dados sobre cada um destes elementos irão depender da técnica ou técnicas de recomendação adotadas.

A informação a considerar sobre os itens pode depender do formato do item (se é textual ou não, por exemplo) e do seu valor ou utilidade.

A informação sobre os utilizadores deve considerar essencialmente quais os seus objetivos na utilização do SR e quais das suas características são relevantes para esses objetivos. De realçar que a definição de um modelo do utilizador, contendo informações que permitam conhecer as suas necessidades e interesses, é exigível para que o SR possa propor recomendações personalizadas. Informações sobre os relacionamentos com outros utilizadores poderão igualmente ser úteis para aferir sobre as similaridades entre eles, dependendo das técnicas de recomendação e similaridade adotadas.

As informações sobre as transações pretendem representar a interação dos utilizadores com o SR. As informações a registar dependem do(s) algoritmo(s) de recomendações adotado(s). Geralmente incluem informações que resultam da utilização do SR (como a classificação sobre o item recém selecionado). Alguns sistemas, mais interativos ou conversacionais, usam adicionalmente ações do tipo pergunta-resposta para otimizar a sua estratégia de recomendação. Nos SR, as classificações constituem a forma habitual de documentar as transações e são obtidas de forma explícita ou implícita.

De forma explícita assumem normalmente a forma de classificações ou de ‘tags’. As classificações mais usuais têm as seguintes formas (Schafer, Frankowski, Herlocker, & Sen, 2007):

- Escala numérica discreta (com símbolos que são implementados nessa escala, por exemplo de 1 a 5 estrelas)

- Ordinais (por exemplo: “concordo plenamente, concordo, neutro, discordo, discordo totalmente);
- Binárias (por exemplo: bom ou mau; relevante ou não relevante; gosto ou não gosto);
- Unárias (representando a existência, ou não, de um relacionamento do utilizador com um dado item);

Para além destas classificações, vários SR disponibilizam um espaço para informação menos estruturada, por exemplo sob a forma comentários, para cada utilizador documentar a sua experiência com um dado item.

Na figura seguinte são ilustradas alguns exemplos de informações resultantes da interação dos utilizadores no *Website* Amazon.com, e que incluem uma avaliação numérica (1 a 5 estrelas), uma avaliação unária (“*Like*”) e o registo de comentários (“*review*”).



**Figura 9 - Avaliações de itens no sítio Amazon.com**

O uso de ‘*tags*’ é outra forma comum de evidenciar algum tipo de *feedback* sobre um dado item (por exemplo, seleccionar a ‘*tag*’ “longo” sobre um dado filme). Veja-se a imagem seguinte onde o utilizador é convidado a participar na votação de ‘*tags*’ já existentes, ou a sugerir novas ‘*tags*’, para descrever os atributos de um livro.

**Suggested Tags from Similar Products** [\(What's this?\)](#)

Be the first one to add a relevant tag (keyword that's strongly related to this product).

**Check a corresponding box or enter your own tags in the field below.**

- |   |   |  |
|---|---|--|
| <input type="checkbox"/> <a href="#">algorithms</a> (55)              | <input type="checkbox"/> <a href="#">python</a> (53)                | <input type="checkbox"/> <a href="#">internet</a> (15)   |
| <input type="checkbox"/> <a href="#">collective intelligence</a> (84) | <input type="checkbox"/> <a href="#">programming</a> (37)           | <input type="checkbox"/> <a href="#">information</a> (8) |
| <input type="checkbox"/> <a href="#">data mining</a> (98)             | <input type="checkbox"/> <a href="#">data</a> (19)                  |  |
| <input type="checkbox"/> <a href="#">machine learning</a> (62)        | <input type="checkbox"/> <a href="#">information retrieval</a> (18) |  |

Your tags:

(Press the 'T' key twice to quickly access the "Tag this product" window.)

**Figura 10 - Uso de 'tags' no sítio Amazon.com**

As informações ditas implícitas não requerem a intervenção explícita dos utilizadores e baseiam-se essencialmente nas suas ações, usadas para inferir as suas opiniões (como exemplos: a seleção de um dado item poderá inferir sobre o interesse do utilizador nesse item; o tempo despendido na navegação de um dado tipo de item poderá ser usado como indicador da sua preferência por esse tipo de item). As informações implícitas são obtidas normalmente através de um processo designado por aprendizagem automática do perfil do utilizador. Vejamos alguns exemplos: quais os itens que um dado utilizador selecionou; quantas vezes o utilizador selecionou um dado item ou página; que itens foram adquiridos; quais as ações realizadas sobre uma dada página *Web* (guardar, imprimir, selecionar uma página ou adicionar uma 'tag' a um item).

Também as redes sociais e redes de aprendizagem poderão complementar a tarefa de obtenção de perfis de modo implícito. Por exemplo, o perfil de um dado utilizador pode ser obtido ou complementado a partir dos gostos e interesses dos utilizadores da sua rede social.

## 3.2 Classificação dos Sistemas de Recomendação

Os SR podem ser caracterizados de várias formas, desde o domínio onde são aplicados, o conhecimento que usam, ou os algoritmos de recomendação (dita a forma como a

predição ou estimativa da utilidade da recomendação é obtida) que aplicam. A sua diversidade é tal que vulgarmente se diz que cada SR é único.

São vários os autores (Burke, 2002; 2007; Ricci et al., 2010; Ekstrand, Riedl, & Konstan, 2011; Melville & Sindhvani, 2010; Adomavicius & Tuzhilin, 2005) que apresentam e justificam diversas taxonomias para os SR. Uma das principais classificações e também das mais simples considera apenas as seguintes duas categorias principais para as recomendações:

- Baseadas em filtragem cognitiva (ou baseada em conteúdos - BC);
- Baseadas na filtragem colaborativa (ou social - FC).

A combinação destas técnicas, eventualmente com outras não colaborativas, cria soluções designadas por híbridas.

São ainda referidos outros tipos de SR que na sua maioria, podem ser considerados como especializações destes dois tipos principais. São exemplos os sistemas demográficos, os sistemas baseados em utilidade e os sistemas baseados em conhecimento (Burke, 2002), que mais à frente serão apresentados de forma sucinta.

Na FC, as recomendações de itens para um utilizador são baseadas nas avaliações que outros utilizadores fizeram.

Na filtragem BC, as recomendações de itens para um utilizador incidem sobre itens cujos conteúdos são similares aos conteúdos de outros itens que esse utilizador já selecionou, ou sobre itens cujos conteúdos são concordantes com os atributos que descrevem o perfil desse utilizador.

Ao longo das próximas 4 secções serão apresentadas as duas principais categorias de SR, já referidas, designadamente Filtragem Colaborativa e Filtragem Baseada em Conteúdos, as limitações comparativas das diferentes categorias e ainda outras categorias, por vezes consideradas especializações das duas principais.

Sobre a Filtragem Colaborativa abordaremos duas categorias diferentes, pelos algoritmos que usam, designadamente as que se baseiam em vizinhança ou em modelo. Quando baseadas em vizinhança, é comum distinguirem-se ainda pela abordagem à similaridade, que pode ser entre utilizadores ou entre itens.

Nas duas últimas secções daremos ainda destaque à inclusão de explicações nos SR e aos recentes desenvolvimentos inovadores no âmbito destas soluções.

### **3.2.1 Filtragem Colaborativa**

A FC é a técnica de recomendação mais popular, estando presente em inúmeras aplicações de vendas na Internet, algumas de grande escala e em diversos domínios de aplicação (livros, filmes, notícias, músicas, etc.).

A FC é um processo que filtra e avalia itens usando as opiniões de outras pessoas. Baseia-se nas avaliações que outros utilizadores fizeram aos itens (explícita ou implicitamente) e na assunção de que os utilizadores com interesses (comportamentos, escolhas, etc.) similares (em termos de gostos, preferências, situações, ...) no passado terão similares interesses no futuro (“diz-me o que é popular entre os meus pares”). A ideia principal é a de que a avaliação que um utilizador dará a um novo item será similar à que outro utilizador deu, se ambos os utilizadores classificaram, no passado, outros itens de forma similar.

O processo (ou componente) de recomendação tem como objetivo produzir uma recomendação para um item solicitado com uma estimativa da sua avaliação ou uma lista de itens com as correspondentes estimativas de avaliações, por ordem decrescente de relevância, baseando-se nas opiniões dos outros utilizadores (ver figura seguinte).



Fonte: (Jannach, Zanker, Felfernig, & Friedrich, 2010)

**Figura 11 - Filtragem Colaborativa**

São vários os autores (Adomavicius & Tuzhilin, 2005; Breese, Heckerman, & Kadie, 1998) que distinguem dois grupos de algoritmos usados na FC:

- Baseados em vizinhança;
- Baseados em modelo.

A FC baseada na vizinhança é igualmente associada às designações ‘*memory-based*’ (Breese et al., 1998) ou baseado em heurísticas (Adomavicius & Tuzhilin, 2005).

Nos métodos ‘*memory-based*’, todas ou parte das avaliações que os utilizadores fizeram sobre os itens e que estão armazenadas no sistema, são usadas diretamente para estimar as avaliações dos itens não seleccionados (também referidos por novos itens).

Uma limitação desta abordagem, que aplica estes métodos a todos os utilizadores e a todos os itens, tem a ver com o facto de a mesma poder vir a ser computacionalmente dispendiosa, podendo mesmo tornar-se impraticável para grandes volumes de dados.

Uma das soluções, passa por processos de redução dos dados a considerar nesse processamento. Neste caso, poderá representar diminuir a quantidade de dados dos utilizadores e/ ou dos itens.

Existem várias propostas e técnicas associadas a este processo de redução dos dados. A redução de dados ao nível dos utilizadores pode, por exemplo, ser feita escolhendo uma amostra aleatória destes ou descartando os utilizadores com menos avaliações feitas. Para os itens a redução pode ser feita eliminando os itens menos populares. Contudo, é de destacar que estas soluções redutoras de dados têm a desvantagem de poder diminuir consideravelmente a qualidade das recomendações geradas. Por exemplo, na FC, ao limitar as avaliações disponíveis, estamos a afetar o cálculo da similaridade entre utilizadores, o que irá implicar uma obtenção de diferentes valores de previsão de avaliações.

Para além do volume de dados existem outros aspetos relevantes a considerar na FC. Um deles diz respeito aos utilizadores que tenham várias preferências não relacionadas entre si (por exemplo, música e desporto). Para estes casos, o algoritmo habitual de FC poderá ter dificuldades em encontrar utilizadores cujos interesses sejam iguais (seguindo o mesmo exemplo, encontrar outros utilizadores que gostem simultaneamente de música e desporto). Uma solução será considerar apenas um subconjunto de interesses do utilizador em cada cálculo (pesquisa).

Ao contrário dos sistemas “*memory-based*” onde as avaliações são usadas diretamente para o cálculo das estimativas, nos métodos baseados em modelos (“*model-based*”) as avaliações feitas pelos utilizadores são usadas para se inferir um modelo preditivo. Através de certas características dos utilizadores e dos itens, o sistema procura determinar classes de utilizadores e categoria de itens, que são usadas, posteriormente, para estimar as classificações dos novos itens.

Como já foi referido, esta abordagem considera as avaliações que outros utilizadores fizeram aos itens que irão ser (ou não) propostos ao utilizador ativo. Uma questão fundamental tem a ver com o grau de importância de cada avaliação. Será que as avaliações a um dado item por vários utilizadores deverão ser consideradas iguais (com igual peso)? Essas avaliações poderão ser de utilizadores com interesses muito próximos dos do utilizador ativo, mas também poderão incluir algumas avaliações de outros utilizadores bastante diferentes. Para dar resposta a este problema foi considerado que as avaliações dos itens usados deveriam ser ponderadas, usando para tal valores ou pesos resultantes do cálculo das similaridades entre os diversos utilizadores ou os

diversos itens, conforme a abordagem a adotar. De um modo geral, a similaridade pretende refletir a distância ou correlação entre dois utilizadores ou dois itens.

Desta forma, entre os métodos ‘*memory-based*’, existem duas diferentes abordagens relativamente ao tipo de similaridade adotada:

- Similaridade entre Utilizadores (‘*user-based*’);
- Similaridade entre Itens (‘*item-based*’).

Nas secções seguintes serão detalhas as diferentes técnicas abordadas habitualmente pelos SR baseados na FC (SRFC).

## **Filtragem Colaborativa baseada em Memória**

Em termos de funcionamento a técnica de FC ‘*memory-based*’, no essencial, já foi descrita. No ponto seguinte iremos abordar as principais diferenças que decorrem dos dois tipos de cálculo de similaridade, designadamente a similaridade entre utilizadores ou entre itens.

### **Filtragem Colaborativa ‘*user-based*’**

Esta abordagem, referida igualmente por FC ‘*user-based*’, usa as avaliações de utilizadores similares (ou vizinhos), que possuem padrões de avaliação semelhantes, para estimar a avaliação dos itens. *GroupLens* (Konstan et al., 1997), *Bellcore* (Hill, Stead, Rosenstein, & Furnas, 1995) e *Ringo* (Shardanand & Maes, 1995) são alguns exemplos dos primeiros sistemas que usaram esta abordagem. Os utilizadores similares (ou vizinhos mais próximos) de um dado utilizador são tipicamente outros utilizadores que também avaliaram os mesmos itens que este avaliou (dizem-se por isso, mais correlacionados).

O número  $k$ , de vizinhos mais próximos (K-NN, do inglês: “*k-nearest neighbor*”) a considerar, assim como o critério adotado para os selecionar são dois fatores com grande impacto na qualidade do SR ou melhor, das suas recomendações. Um número demasiado elevado pode acarretar grandes necessidades de espaço para armazenar todas

as similaridades entre cada par de utilizadores, bem como pode tornar o cálculo da predição demasiado lento. Diferentes estudos propuseram alternativas para a determinação do número de vizinhos a considerar:

- Um número absoluto entre 20 e 50 (Herlocker, Konstan, & Riedl, 2002);
- Uma percentagem de utilizadores de entre todos os vizinhos (Herlocker et al., 2002);
- Um número calculado dinamicamente em função dos dados disponíveis no SR (Lathia, Hailes, & Capra, 2009).

Tal como já foi referido, para além do número de vizinhos, é igualmente importante os critérios que determinam a sua seleção. Uma das formas mais simples poderá ser baseada numa escolha aleatória. Esta solução tem a vantagem de não requerer cálculos de similaridade entre todos os utilizadores, o que poderá melhorar significativamente o desempenho do sistema. Tem a desvantagem de poder causar uma baixa fiabilidade nas recomendações, pois a escolha poderá recair sobre utilizadores menos correlacionados (Hill, Stead, Rosenstein, & Furnas, 1995). A forma habitual, sempre que tal seja computacionalmente possível, será calcular a similaridade entre todos e selecionar os mais similares entre si, em número definido pelo processo que determina esse cálculo.

Na abordagem ‘*user-based*’, o valor da similaridade obtido representa a proximidade das avaliações entre o utilizador ativo e um outro utilizador. Esse valor será usado como fator de ponderação (ou peso) a aplicar sobre as avaliações dadas por esse utilizador. Desta forma, as avaliações de um dado utilizador, mais fortemente ligado, serão mais relevantes para o utilizador ativo. Na sua formulação, para evitar que os valores obtidos estejam fora dos limites permitidos, o resultado final costuma ainda ser normalizado.

Os principais métodos usados para calcular a similaridade entre dois utilizadores incluem o uso do coeficiente de correlação de *Pearson* sobre as suas avaliações (opção usada no SR *GroupLens*) ou baseando o cálculo no cosseno do ângulo de dois vetores representativos das avaliações desses mesmos dois utilizadores (ver formulações em apêndice 3).

O resultado do apuramento das similaridades entre utilizadores é normalmente representado numa matriz simétrica utilizador-utilizador, em que os valores mais elevados representam maiores similaridades.

De realçar que o cálculo das similaridades é um dos aspetos mais críticos do SR, influenciando, por um lado a fiabilidade dos resultados e por outro, o seu desempenho (conforme já referido).

Foram propostas e testadas outras medidas para o cálculo da similaridade dos utilizadores, tais como o coeficiente de correlação de *Spearman*, a correlação de *Kendall* ou a similaridade do cosseno ajustada, entre outras (Herlocker J. L., Konstan, Borchers, & Riedl, 1999; Su & Khoshgoftaar, 2009).

O processo de recomendação só fica concluído com o cálculo da estimativa da classificação de cada item, para o utilizador ativo.

Uma das formulações iniciais, mais simples, não considera os pesos das similaridades entre utilizadores ou itens. Propõe como resultado a média das classificações registadas na matriz de avaliações.

No entanto, nesta abordagem (FC ‘*user-based*’), a formulação usual é a “soma ponderada das avaliações dos outros utilizadores”, que considera a ponderação das similaridades (ver apêndice 4). Nesta formulação, para o cálculo da estimativa de avaliação de um dado item para o utilizador ativo são consideradas todas as avaliações que todos os outros utilizadores fizeram a esse item, sendo cada uma dessas avaliações ponderada com o valor obtido do cálculo da similaridade entre o utilizador ativo e o utilizador que produziu essa avaliação. Uma variante desta abordagem, normalmente usada quando o número de utilizadores é demasiado grande, considera somente os *k* utilizadores mais próximos (‘*k-nearest-neighbours*’), ou seja com maiores similaridades com o utilizador ativo. Neste cenário, a formulação usual somente considera as avaliações a um dado item produzidas por esses utilizadores (mais próximos do utilizador ativo), no cálculo da estimativa de avaliação desse item para o utilizador ativo.

Devido a certas limitações dos algoritmos base da FC ‘*user-based*’, foram propostas algumas extensões.

Uma limitação destes algoritmos é causada pelos dados esparsos, habituais da matriz de avaliações. De facto, a verificação de que alguns algoritmos não possuem boas respostas quando existem poucas avaliações, levou à apresentação de algumas sugestões.

Herlocker et al. (1999) propuseram a redução do peso da similaridade para os utilizadores com menos que 50 itens em comum.

Breese et al. (1998) sugeriram o uso de um valor negativo, a atribuir por defeito, às avaliações inexistentes (aumentando assim o número de avaliações a considerar no cálculo) e propuseram a técnica “*Inverse User Frequency*” (que se baseia na técnica *idf*). Esta técnica retira influência aos itens com maior número de avaliações e dá maior relevância aos itens menos frequentemente avaliados. Num caso extremo, se todos os utilizadores tiverem avaliado um dado item, o fator de frequência será zero. O valor dessa frequência é usado para multiplicar pela avaliação original, sendo esta avaliação, depois de transformada, aplicada à formulação original de cálculo da similaridade. No mesmo trabalho foi igualmente sugerida a aplicação de um fator de amplificação, que permite atribuir uma maior importância aos vizinhos mais próximos do utilizador ativo. Este fator influencia o valor da similaridade como seu expoente (esse fator quando é superior a 1 atribuirá maior importância aos vizinhos mais próximos, onde existe um maior valor de similaridade).

Su et al. (2008) apresentaram uma solução baseada em várias técnicas de aprendizagem de máquina (ML, do inglês: “*Machine Learning*”) que permite o preenchimento das avaliações inexistentes da matriz, a partir dos dados existentes.

Finalmente interessa referir que estes sistemas ‘*user-based*’ são boas soluções quando existe uma forte correlação de interesses entre os utilizadores.

## **Filtragem Colaborativa ‘*item-based*’**

Conforme já foi referido, uma das principais limitações da abordagem anterior, ‘*user-based*’, reside na dificuldade da computação da similaridade entre milhões de utilizadores.

Como alternativa foi desenvolvida a opção de se usar a similaridade entre itens. Neste caso, as similaridades estabelecem-se entre os itens que o utilizador ativo já avaliou e os restantes itens (Deshpande & Karypis, 2004; Linden, Smith, & York, 2003). Esta opção reduz significativamente a necessidade de computação, para o cálculo das similaridades, especialmente em soluções onde o número de itens seja significativamente inferior ao número de utilizadores. De facto, na maioria das soluções, cada utilizador avalia normalmente um conjunto pequeno de itens e as similaridades a obter são só relativamente a esse conjunto de itens. Por outro lado, a maioria das soluções que usam esta abordagem implementam uma matriz de similaridades item-item, que é mantida em processamento ‘*offline*’. De realçar que, tal como já foi referido, também na abordagem ‘*user-based*’ poderá ser usada uma matriz de similaridades ‘utilizador-utilizador’ pré-processada em ‘*offline*’. Contudo, as novas avaliações afetam mais os valores das similaridades entre utilizadores do que entre itens, pelo que a similaridade entre itens se mostra uma opção mais estável e mais facilmente escalável (Sarwar, Karypis, Konstan, & Riedl, 2001).

Dois itens serão tanto mais similares entre si quanto maior for o número de utilizadores que avaliarem esses dois itens da mesma forma. Esta abordagem ‘*item-based*’ é uma das técnicas usadas pelo sítio Amazon.com para recomendar livros ou CDs aos seus clientes.

Neste cálculo, da similaridade entre itens, como as diferenças entre as escalas de avaliação de diferentes utilizadores são normalmente maiores que as diferenças nas avaliações que um mesmo utilizador faz a vários itens, pode ser mais adequado comparar as avaliações em função da média do utilizador e não em função da média de avaliações do item. A formulação da similaridade cosseno ajustada (ver apêndice 3) é uma alternativa à opção do coeficiente de correlação de *Pearson* que compara as avaliações centradas na média do utilizador ativo. O resultado do apuramento das similaridades entre itens é normalmente representado numa matriz simétrica item-item, onde os valores mais elevados representam maiores similaridades. Em alternativa a

considerar todos os itens similares aos que o utilizador ativo avaliou, poderão ser considerados apenas os  $k$ -vizinhos (itens) mais próximos de cada item. Para tal, considera-se para cada item (representado numa coluna da matriz item-item) os  $k$  maiores valores e colocam-se a zero todos os outros, nessa mesma coluna. De realçar que um dado item não poderá pertencer aos seus  $k$ -vizinhos mais próximos, pelo que na mesma matriz a célula correspondente (que intersecta o item com ele próprio) terá igualmente o valor zero.

Para estimar a avaliação do par utilizador  $x$  item, nesta abordagem, ‘*item-based*’, é normal considerar a formulação da “média simples ponderada”, apresentada no apêndice 4, em que o cálculo da estimativa de avaliação de um dado item para o utilizador ativo considera todas as avaliações a outros itens que esse utilizador efetuou, ponderadas pelo valor obtido do cálculo da similaridade entre esse item e cada um dos outros itens que o utilizador avaliou. Tal como já referido anteriormente, em alternativa a considerar todos os itens similares ao item ativo, poderão ser considerados apenas os  $k$ -vizinhos (itens) mais próximos de cada item.

Um algoritmo recente e muito referenciado que usa este tipo de abordagem (FC ‘*item-based*’) é o resultante da proposta *Slope One* (Lemire & Maclachlan, 2005).

Por fim, relativamente à FC ‘*memory-based*’ é de referir que os diversos componentes, com as suas funções distintas (cálculo das similaridades, normalização das avaliações, seleção dos vizinhos, cálculo da estimativa de avaliação), influenciam a qualidade das respostas que o SR obtém. Existem várias alternativas para cada um dos componentes, pelo que o desenho destes sistemas deverá considerar a análise das diversas opções, incluindo o âmbito das recomendações.

## **Filtragem Colaborativa baseada em Modelos**

Em alternativa ao uso direto da matriz de avaliações, foram desenvolvidas várias técnicas de recomendação baseada em modelos. Nesta abordagem as recomendações são baseadas em modelos previamente construídos. A ideia principal consiste na captação do comportamento (ou padrão) de avaliação dos utilizadores (baseado no histórico de avaliações) e, partindo daí, induzir modelos preditivos. Os dados existentes,

são processados em modo ‘*offline*’ (tal como realizado no cálculo das matrizes de similaridades, especialmente as matrizes item-item), por forma a obter um modelo (decorrente do processo de aprendizagem implementado) que será usado no momento da solicitação das recomendações, ou seja em ‘*online*’. Pretende-se com esta abordagem, por exemplo, estimar a avaliação de um dado filme para um utilizador por indução, a partir do gosto que esse utilizador já demonstrou sobre diversos géneros de filmes.

Nesta abordagem, as principais técnicas recorrem a métodos probabilísticos, técnicas de factorização matricial e prospeção de dados com base em regras de associação (em inglês: “*association rule mining*”).

Recorrendo à teoria das probabilidades, Billsus e Pazzani (1998) propuseram que o cálculo da estimativa de avaliação do item a recomendar seja resolvido como se fosse um problema de classificação. Genericamente, um problema de classificação pode ser descrito como a tarefa de atribuir um objeto a uma de várias categorias (ou classes) predefinidas. Tipicamente, num problema de classificação são usados dados conhecidos (de treino) para prever o que vai ocorrer noutros casos. Cabe ao “classificador”, implementar essa tarefa. O termo “classificador” refere-se à função matemática responsável pela classificação dos dados em categorias (ou classes). Um classificador ótimo escolhe a classe mais provável. Um dos mais referenciados neste tipo de problemas é o classificador de *Bayes*.

Um exemplo poderá ser a classificação dos *emails* recebidos, reconhecendo-os como mensagens válidas ou mensagens publicitárias, não desejadas. Para automatizar esta tarefa, uma função poderá, com base em *emails* guardados (conhecidos também como o conjunto de dados de treino), analisar as palavras da mensagem e do seu cabeçalho e decidir sobre o tipo de mensagem. Essa função determina o modelo de classificação.

Em termos genéricos, o classificador *bayesiano* é usado para estimar a probabilidade de uma dada página  $p_j$  pertencer a uma certa classe  $C_i$  (exemplos de classes: com ou sem interesse; 5 classes provenientes de uma escala de classificações de 1 a 5, etc.), dado um conjunto de  $n$  termos,  $k_1$  a  $k_n$ , existentes nessa página (item ou documento). O algoritmo calcula para cada página a probabilidade relativa a cada classe, sendo a página atribuída

à classe para a qual apresente maior valor probabilístico. Esta técnica produz resultados fiáveis rapidamente quando aplicados a grandes volumes de dados.

Por exemplo, um SR que recomende restaurantes pode ser implementado por um classificador que classifique os restaurantes em duas classes (bom e mau), baseado num conjunto de características que descrevam os restaurantes.

No contexto dos SR, num problema de classificação, as avaliações possíveis serão as classes e as características serão os itens avaliados pelo utilizador ativo. De forma simplista, o método consiste em calcular as probabilidades condicionais para cada classe (se tal avaliação for possível), dadas as outras avaliações que o utilizador já realizou e seleccionar a probabilidade mais elevada como a previsão da avaliação para o item pretendido. Vejamos como exemplo um utilizador que avaliou, numa escala de 1 a 5, vários itens ( $i$ ) da seguinte forma:  $i_1=5$ ;  $i_3=4$ ;  $i_4=1$ . Pretende-se prever a avaliação do item 2,  $i_2$ , para esse mesmo utilizador (ativo). A ideia será calcular a probabilidade condicionada para cada possível avaliação (de 1 a 5) dadas as avaliações que ele fez aos itens 1, 3 e 4, ou seja, calcular  $P(i_2=1|X)$ ,  $P(i_2=2|X)$ , ...,  $P(i_2=5|X)$ , em que  $X=(i_1=5; i_3=4; i_4=1)$ . O maior valor obtido dessas 5 probabilidades será proposto para previsão de classificação do item 2.

Assumindo a independência entre os atributos (nesta caso, as avaliações dos utilizadores), são normalmente usados classificadores naïve de *Bayes*. Esta abordagem, na sua forma mais simples e com as habituais matrizes com poucas avaliações, não permite obter, frequentemente, boas classificações ou mesmo quaisquer classificações. Por isso mesmo, as propostas baseadas nos modelos probabilísticos normalmente agrupam os utilizadores similares (ou os itens) em ‘*clusters*’ por forma a minimizar os problemas dos dados esparsos e ao mesmo tempo reduzir a complexidade computacional (Breese et al., 1998; G.-R.Xue et al., 2005). Breese et al. (1998) propuseram igualmente um modelo de redes *bayesianas* para modelação das probabilidades condicionais das classes.

Para dar solução ao problema dos dados esparsos, algumas propostas recorrem às técnicas de redução de dimensionalidade, tais como SVD.

Os modelos de factorização matricial têm assumido algum protagonismo neste tipo de SR, quer nas escolhas pelos fornecedores de serviços, quer pelos investigadores. Esta abordagem consiste essencialmente na otimização alternada das variáveis latentes ou escondidas (usando para tal técnicas de factorização sobre a matriz de avaliações), dos utilizadores e itens até que um determinado nível de precisão seja atingido. Em termos gerais, os métodos de factorização matricial são usados para, a partir dos padrões de avaliação verificados na matriz de avaliações, derivar um conjunto de fatores (“escondidos” ou igualmente referidos como latentes) que caracterizem utilizadores e itens. Contudo, os fatores poderão não ter uma interpretação fácil ou direta (sendo por isso, por conceito, não interpretáveis). O problema de recomendação de um dado item para o utilizador ativo baseia-se então, na obtenção da similaridade destes (item ou utilizador) relativamente aos fatores latentes, derivados.

Por exemplo, numa matriz de avaliações de filmes um dos fatores derivado poderá corresponder ao género do filme.

Um tipo de problemas comum a ambas as abordagens colaborativas, ‘*memory-based*’ ou ‘*model-based*’ diz respeito à interpretação da matriz de avaliações, designadamente sobre as células vazias ou com ausência de avaliação (‘?’). De facto, em inúmeras soluções, as preferências implícitas são mais frequentes que as avaliações explícitas. Por exemplo, numa loja é vulgar registar detalhadamente os dados das transações de compra efetuadas, mas não é nada vulgar solicitar a um cliente que indique quais os produtos pelos quais nunca terá interesse. Num SR de programas de televisão será simples registar implicitamente os programas vistos, mas usualmente não fica nada registado sobre os programas que não o foram. No sentido de dar resposta a este problema, Pan e Scholz (2009) propuseram uma solução ‘*model-based*’, sobre o modelo de factorização matricial em que os pares utilizador-item inexistentes são considerados valores negativos e integram a formulação com uma ponderação específica.

Algumas técnicas de factorização matricial tais como a SVD ou a análise de componentes principais (PCA, do inglês: *Principal Component Analysis*) foram aplicadas em várias propostas na área dos SR (Sarwar B. M., Karypis, Konstan, & Riedl, 2000; Canny, 2002).

Alguns estudos (Melville & Sindhvani, 2010) sobre sistemas suportados nestas técnicas de factorização matricial procuraram respostas para constatações pertinentes, tais como: a verificação de que os itens mais populares possuem avaliações médias mais elevadas e de que certas avaliações, registadas por exemplo há algum tempo atrás, deverão ser descartadas ou consideradas menos relevantes.

Um bom resumo sobre os tópicos recentes, alguns deles avançados, da aplicação das técnicas ‘*model based*’ em SR poderá ser encontrado em Koren et al. (2009).

A identificação de padrões de relacionamentos sob a forma de regras (“*association rule mining*”) é outra das técnicas propostas neste tipo de abordagem, FC ‘*model-based*’ (Sarwar et al., 2000). Uma regra poderá definir ações conjuntas que envolvem diferentes itens (por exemplo, se um cliente compra um livro escolar de uma disciplina de um dado ano, em 60% dos casos também compra auxiliares de ensino dessa disciplina e desse ano). Este tipo de regras pode ser explorado para propor recomendações colaborativas. A sua implementação passa, geralmente, por aplicar o algoritmo de ‘*data-mining*’ em modo ‘*offline*’ sobre a matriz de avaliações por forma a aprender um conjunto de regras (modelo), que depois serão usadas para propor as recomendações (exemplo de regra aprendida: “Se o utilizador X gostar dos itens 1 e 2 então provavelmente também gostará do item 5”). A aplicação de várias regras permitirá encontrar um conjunto de itens a propor. Geralmente serão recomendados os itens que apresentam um maior nível de confiança, ou seja onde o rácio entre as transações que contém todos os itens da regra de associação e as transações que só contém os itens que verificam a condição da regra é maior (do exemplo anterior: a confiança será obtida do rácio entre o número de utilizadores com avaliações positivas aos itens 1, 2 e 5 sobre o número de utilizadores com avaliações positivas somente aos itens 1, 2, excluído por isso o 5). Esta abordagem foi analisada e comparada com outros algoritmos tendo mostrada uma boa qualidade na recomendação de um SR de filmes (Billsus & Pazzani, 1998).

Existem outros trabalhos de relevo, que utilizaram as diversas técnicas para SR de FC ‘*model-based*’, tais como: Indexação Semântica Latente (Hofmann, 2003), Alocação de Dirichlet Latente (LDA, do inglês: “*Latent Dirichlet Allocation*”) (Blei, Ng, & Jordan, 2003), método de Entropia Máxima (Zitnick & Kanade, 2004), máquinas Boltzmann

(Salakhutdinov, Mnih, & Hinton, 2007), máquinas de vetores de suporte (SVM, do inglês: “*Support Vector Machine*”) (Grear, Fortuna, Mladenic, & Grobelnik, 2006) e o método de factorização SVD (Paterek, 2007; Takács, Pilászy, Németh, & Tikk, 2008), entre outros.

## Filtragem ‘Memory-based’ vs ‘Model-based’

Embora alguns trabalhos tenham demonstrado que os algoritmos baseados em modelos podem ter melhores desempenhos no cálculo das estimativas de avaliação para os itens (Koren, 2008), esse aspeto não deve ser o único a considerar para garantir aos utilizadores um elevado nível de satisfação no uso dos SR (Good et al., 1999; Drachsler, Hummel, & Koper, 2009; Dix, Finlay, Abowd, & Beale, 2003), uma vez que existem outros fatores a considerar na avaliação dos SR.

Um outro fator considerado importante pelos utilizadores é a capacidade dos sistemas em propor itens inesperados e ao mesmo tempo interessantes aos utilizadores (o suporte à serendipidade, em inglês: ‘*serendipity*’). Para este fator, ambas as abordagens (‘*memory*’ ou ‘*model*’) poderão ter respostas, mas não necessariamente iguais (por exemplo, no sistema de FC ‘*user-based*’ um item inesperado poderá ser proposto simplesmente porque um dos vizinhos mais próximos o avaliou muito positivamente, situação que será difícil induzir a partir de um qualquer modelo), pelo que também aqui a opção por uma ou por outra influenciará as respostas do SR.

Comparativamente com os métodos baseados em modelos, os métodos ‘*memory-based*’, apresentam algumas vantagens (Ricci et al., 2010):

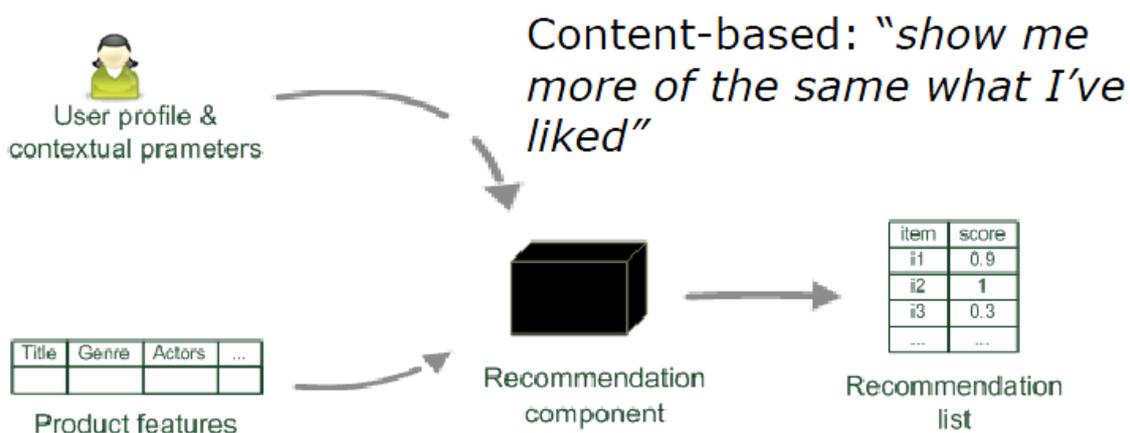
- Simplicidade – mais intuitivos e com uma implementação mais simples;
- Justificabilidade – podem apresentar informações que expliquem e justifiquem a recomendação (por exemplo, apresentar a lista concreta de itens similares e as correspondentes classificações);
- Eficiência - não requer aprendizagem (processo necessário para a construção dos modelos e que é normalmente repetido periodicamente) e permite o cálculo das similaridades (de itens ou de utilizadores) em modo ‘*offline*’;

- Estabilidade – a adição de novos utilizadores, itens e classificações interfere pouco com o funcionamento do SR, uma vez que não exige recálculo de modelos.

### 3.2.2 Filtragem Baseada em Conteúdos

Um SR exclusivamente colaborativo utiliza a matriz de avaliações, diretamente ou indiretamente (induzir um modelo colaborativo). As previsões não consideram por isso as especificidades de cada utilizador nem de cada item. A filtragem baseada em conteúdos (BC) assenta na ideia de que melhores recomendações poderão ser propostas quando se usa o conhecimento que se pode ter sobre cada utilizador (por exemplo, o seu sexo, idade, estado civil, com ou sem filhos, rendimentos, etc.) e sobre cada item (por exemplo, o nome do diretor de um filme, o seu género, a sua nacionalidade, etc.).

Quando baseadas no conteúdo, as recomendações usam as características dos itens que foram selecionados anteriormente e do perfil de cada utilizador para aferir similaridades e propor sugestões (“mostra-me mais do que eu gosto, baseado naquilo que foram os meus gostos no passado”).



Fonte: (Jannach, Zanker, Felfernig, & Friedrich, 2010)

**Figura 12 - Filtragem Baseada em Conteúdos**

No exemplo da figura seguinte é ilustrada a opção “*Recommended for you*” do sítio Amazon.com, em que, baseando-se nos itens adquiridos por um utilizador, são propostos itens similares.

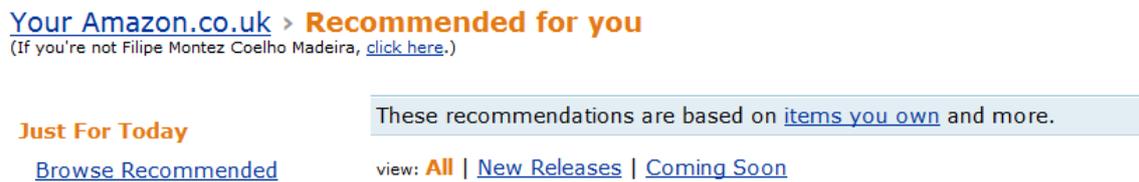


Figura 13 - Filtragem "Recommended for You" no Amazon.co

A ideia geral é a de identificar as características comuns dos itens que receberam classificações positivas de um dado utilizador e com base nessa informação, recomendar outros itens (novos) que partilham as mesmas características. Por exemplo, se um dado utilizador classificou com boa avaliação um dado filme do género comédia, então o SR passará a recomendar filmes desse mesmo género a esse mesmo utilizador.

Ao contrário da FC ‘*item-based*’, em que a similaridade dos itens é deduzida a partir das avaliações que os utilizadores produziram, aqui é determinada por dados extraídos implicitamente ou solicitados explicitamente sobre os próprios itens.

O essencial desta técnica consiste na forma como é realizada a correspondência dos atributos do perfil do utilizador  $c_i$  (que correspondem às suas preferências e interesses), com os atributos que representam e descrevem cada item  $s_j$ , por forma a poder decidir sobre a sua recomendação a esse utilizador.

Em termos mais formais, a utilidade  $u(c_i, s_j)$  do item  $s_j$  para o utilizador  $c_i$  é estimada com base nas utilidades  $u(c_i, s_k)$  atribuídas pelo utilizador  $c_i$  aos itens  $s_k$ , similares ao item  $s_j$ .

$$c_i = (c_{i1}; c_{i2}; \dots; c_{im}) \text{ e}$$

$$s_j = (s_{j1}; s_{j2}; \dots; s_{jn});$$

Em que:

$c_i$  representa o utilizador  $i$  e os elementos de  $c_{i1}$  a  $c_{im}$  representam as  $m$  características do utilizador  $i$ ;

$s_j$  representa o item  $j$  e os elementos de  $s_{j1}$  a  $s_{jn}$  representam as  $n$  características do item  $j$ ;

as características poderão ser interpretadas como palavras-chave que descrevem o utilizador e o item.

Estes sistemas usam algumas das técnicas desenvolvidas no âmbito dos sistemas IR e IF. Para esses sistemas foram desenvolvidas técnicas que exploram a informação que é derivada dos documentos (tipicamente textos, páginas *Web*, mensagens de fóruns, etc.) e de onde procuram extrair os itens mais interessantes aí existentes. Nos SR são considerados, para além de itens textuais, outros tipos de itens (itens multimédia e artigos típicos das lojas *online*, como livros, calculadoras, etc.) e perfis com informações sobre os utilizadores.

Em termos gerais, o desenho de Sistemas de Recomendação Baseados em Conteúdos (SRBC) deverá dar respostas às seguintes questões:

- Como obter e manter atualizados os perfis dos utilizadores?
- Como determinar quais os itens que são similares ou compatíveis com os interesses dos utilizadores?
- Que técnicas poderão ser usadas para extrair automaticamente as informações sobre os itens, minimizando o registo explícito, por norma manual?

## **Perfil do Utilizador**

A primeira questão está associada ao processo de aprendizagem dos perfis pelo SR. Este processo gere as características dos perfis dos utilizadores e a sua atualização, à medida que o utilizador vai interagindo com o sistema.

O perfil dos utilizadores é construído normalmente por processos de aprendizagem, que usam conjuntos de documentos representativos dos interesses (e eventualmente, dos desinteresses) dos utilizadores e que permitem definir protótipos representativos de classes ou categorias.

Geralmente as características que constituem os perfis são baseadas nas características dos itens que o mesmo seleciona ou avalia, assim como da informação de *feedback* que possa ser recolhida, de forma explícita ou implícita. O perfil de um dado utilizador, para além de poder ser atualizado pelo processo de aprendizagem, pode igualmente ser inicializado, através do preenchimento de um formulário inicial (por exemplo, o utilizador poderá indicar os dados necessários à sua caracterização básica, incluindo algumas das suas áreas de interesse). Contudo, uma vez que esta opção exige algum esforço ao utilizador, deverá ser evitada sempre que tal seja possível.

Normalmente, no processo de recomendação, a análise dos perfis dos utilizadores considera todo ou parte (por exemplo, considerando apenas os itens para os quais o utilizador forneceu informações explicitamente) do histórico de interações dos utilizadores com o sistema (por exemplo: a compra de um dado artigo pelo utilizador, a avaliação que este fez a esse artigo, ou mesmo os termos de uma dada pesquisa no sistema). Os dados históricos poderão ser usados de diferentes formas: mostrar ao utilizador os itens recentemente visitados, evitar que o sistema recomende um mesmo item, servir como argumento de entrada do processo de aprendizagem para melhorar o perfil do utilizador.

O processo de aprendizagem do perfil do utilizador também foi proposto como um problema de classificação. Através de alguns itens usados para treino, o classificador é dividido em diversas categorias (por exemplo: relevante ou não relevante). É depois usado um algoritmo de classificação que permitirá ao sistema modelar os interesses dos utilizadores e assim, perante um novo item decidir se o deve recomendar ou não. Normalmente o resultado deste processo poderá ser a probabilidade do utilizador gostar de um dado item, uma lista com os itens mais prováveis de serem bem aceites ou uma estimativa de valor do nível de interesse associado a cada item.

Com as sucessivas interações do utilizador com o SR o seu perfil vai sendo atualizado e enriquecido, naquilo a que se designa pelo processo de aprendizagem do perfil do utilizador. O modelo *Rocchio* é uma das técnicas usadas neste processo (ver apêndice 2).

## Representação dos Itens

A informação de representação dos itens poderá ser pouco ou mesmo nada estruturada, designadamente quando os itens são documentos textuais (como por exemplo: páginas *Web*, notícias, *emails* ou documentos), ou mais estruturada, incluindo um pequeno número de atributos (ou características).

Na sua forma mais simples, estruturada, são usados atributos, quer para representar os itens, quer para representar os perfis dos utilizadores (ver figura 14).

### Item representation

Title	Genre	Author	Type	Price	Keywords
The Night of the Gun	Memoir	David Carr	Paperback	29.90	Press and journalism, drug addiction, personal memoirs, New York
The Lace Reader	Fiction, Mystery	Brunonia Barry	Hardcover	49.90	American contemporary fiction, detective, historical
Into the Fire	Romance, Suspense	Suzanne Brockmann	Hardcover	45.90	American fiction, murder, neo-Nazism

### User profile

Title	Genre	Author	Type	Price	Keywords
...	Fiction	Brunonia, Barry, Ken Follett	Paperback	25.65	Detective, murder, New York

Fonte: (Jannach, Zanker, Felfernig, & Friedrich, 2010)

**Figura 14 - Item e Perfil do Utilizador**

Numa abordagem menos estruturada, por exemplo sobre um SR que recomende notícias, as características de cada item (notícia) poderão ser as próprias palavras constantes nesse item (por isso, às características também se denominam conteúdos). Muitos dos exemplos que usam estes sistemas, recomendam notícias ou páginas *Web*, por comparação das palavras-chave de um dado artigo com as que existem noutros artigos que o utilizador já leu e avaliou positivamente, no passado. Neste tipo de soluções, os próprios itens recomendados são geralmente designados por documentos.

Embora dependa do domínio de aplicação, a descrição do perfil do item faz-se normalmente através de um conjunto de palavras-chave, se possível obtidas automaticamente a partir do conteúdo do próprio item (usando técnicas que transformam dados não estruturados em estruturados).

Uma abordagem simplista (e ao mesmo tempo ineficiente) considera uma lista com todas as palavras que surgem em todos os documentos e descreve cada item como um vetor com valores booleanos, ‘0’ ou ‘1’, indicando o ‘1’ a presença da palavra nesse documento. São vários os problemas com este tipo de codificação, quando estes vetores representativos dos itens se comparam com os vetores dos perfis dos utilizadores (que contém as palavras-chave representativas dos seus interesses marcadas a ‘1’). Por um lado é dada a mesma importância a todas as palavras, uma vez que não é considerada a sua frequência, apenas a sua presença. Por outro, nos textos mais longos, a probabilidade de ocorrência das palavras pesquisadas também se torna maior, pelo que o sistema tenderá a encontrar e a propor documentos maiores.

Por estas razões, os documentos são normalmente descritos usando as técnicas de IR, designadamente o formato *ifidf* (já apresentada anteriormente e constante em apêndice 1). Neste caso, a descrição do item é um vetor com o peso *ifidf* de cada palavra.

Ambas as abordagens têm o problema de representarem os itens com vetores muito grandes e com muita ausência de valores (esparsos). Assim, nestas técnicas é vulgar aplicar a redução da dimensionalidade a esses vetores. Algumas das técnicas mais usadas incluem: remover palavras sem significado, tais como ‘o’, ‘de’, ‘em’ (artigos, pronomes, proposições, etc.); analisar as palavras que têm a mesma origem (da mesma família) e considerar só a palavra raiz; considerar apenas um dado número, *n*, de palavras, consideradas as mais informativas (nos sistemas *Syskill & Webert* e *Fab* foram propostas 128 e 100 palavras, respetivamente); ou usar várias palavras em vez de uma só (por exemplo: “União Europeia” ou “Península Ibérica”). Estas técnicas são comumente adotadas quer sobre os perfis dos itens quer sobre os dos utilizadores.

## Processo de Recomendação

Nesta abordagem, BC, a tarefa de recomendação consiste em determinar que itens melhor satisfazem as preferências dos utilizadores.

Tal como na FC, o processo de recomendação BC recorre ao conceito de similaridade. Neste caso, o cálculo da similaridade é entre um item não selecionado e o perfil de utilizador.

Para efetuarem recomendações, os sistemas avaliam de que forma um dado item ainda não selecionado por um dado utilizador é similar aos itens que esse utilizador já selecionou (e gostou) no passado.

A similaridade poderá ser interpretada de diversas formas. Uma delas poderá resultar da verificação de quais as características que estão presentes nesse item (a recomendar) e no perfil desse utilizador (por exemplo, para um dado vídeo policial, ainda não visto, verificar se o utilizador tem preferências por filmes policiais). Neste caso, a resposta possível será do tipo sim ou não, ou seja, o cálculo da similaridade retornará 0 ou 1. Em domínios de aplicação onde os itens a recomendar são mais textuais, a similaridade poderá ser calculada usando o coeficiente de *Dice*, medida que nos dá o nível de sobreposição das palavras-chave presentes no perfil do utilizador e na descrição do item (ver apêndice 3).

Segundo Ricci et al. (2010), os SRBC cujas representações de itens e de perfis foram feitas com base em palavras-chave, demonstraram boa precisão, desde que a base de itens de teste permitisse a representação de um razoável perfil, para cada utilizador. De realçar que quanto maior for o número de exemplos usado para construir o perfil de interesses do utilizador, mais garantias se tem numa boa recomendação.

Ao tratar os perfis de utilizadores como “classes de interesses”, a recomendação configura-se como um problema de classificação.

Tal como já foi referido, as soluções habituais para representar os perfis dos itens e dos utilizadores recorrem normalmente às técnicas IR (como exemplos: interseção de palavras ou VSM com *tfidf*), especialmente em domínios de aplicação onde os itens a recomendar são mais textuais.

Para determinar as recomendações, as soluções habituais usam o algoritmo *K-NN* aplicado aos itens, onde se compara cada novo item com a representação dos protótipos (resultantes dos itens de treino), ou classes, usando uma função de similaridade que determina os *k* vizinhos mais próximos. O valor de avaliação da classe correspondente à maior similaridade é normalmente proposto para estimativa de avaliação desse item. Para dados estruturados poderá ser usada a métrica de distância de Euclides. Para dados não estruturados é normalmente usada a métrica do cosseno sobre a similaridade de vetores representativos das classes e do item (ver apêndice 1).

Outras técnicas usam os classificadores sobre os novos documentos baseados em métodos probabilísticos, tal como o classificador *naïve Bayes*. As técnicas SVM, árvores de decisão e redes neuronais foram igualmente propostas (Pazzani, Billsus, Michalski, & Wnek, 1997) para determinar quais os itens a recomendar.

Estas técnicas mantêm, contudo, alguns dos problemas já referidos na secção 3.1.2, sobre IR e IF (sinonímia, polissemia, etc.), fundamentalmente porque se centram essencialmente nas questões sintáticas e não nas questões semânticas dos textos. Em sistemas mais avançados, procurou-se incluir carga semântica à representação dos itens e aos perfis dos utilizadores, recorrendo a ontologias e a fontes externas de conhecimentos.

São vários os exemplos que se basearam nos conteúdos dos itens e nos perfis dos utilizadores para efetuarem recomendações personalizadas.

O sistema *Letizia* (Lieberman, 1995) consiste numa implementação estendida de um navegador Internet que regista o comportamento de navegação do utilizador e constrói um modelo personalizado baseado em palavras-chave que refletem os seus interesses. Dessa forma, tenta antecipar itens que possam ser do interesse de cada utilizador. O modelo do utilizador é alterado sempre que um utilizador adiciona um marcador (ou favorito) sobre uma página *Web*, ação que o sistema interpreta como o utilizador tendo grande interesse nessa página.

Adomavicius e Tuzhilin (2001) propuseram a implementação do perfil de utilizador com base num conjunto de regras que se aplicam aos atributos dos itens, para filtrar os itens com interesse.

O sistema *NewsWeeder* (Lang, 1995) propõe uma lista personalizada de notícias com estimativa de avaliação, com base no perfil dos seus leitores. Cada leitor avalia as notícias que leu, numa escala de 1 a 5 e são estas avaliações que são usadas para a reaprendizagem do seu perfil. As novas notícias são convertidas em vetores de palavras. Com o objetivo de comparar a aplicação de diferentes técnicas, usaram duas abordagens para analisar a frequência das palavras (nesta abordagem, denominadas por ‘tokens’). Na primeira, usaram as técnicas *tfidf* sobre os vetores de palavras. Inicialmente o sistema usa um processo de aprendizagem que determina um conjunto de vetores protótipos, um para cada categoria de documentos. Para classificar um novo documento, o seu correspondente vetor é comparado com cada vetor protótipo e a maior similaridade cosseno verificada permitirá associar o documento à respetiva categoria e ditará a estimativa de avaliação para a notícia. Na segunda abordagem, usaram a técnica de aprendizagem de máquina MDL (do inglês: *Minimum Description Length*) igualmente na reaprendizagem das categorias de documentos e no cálculo da similaridade destas com os novos documentos.

O algoritmo *Winnnow* (Mladenic, 1999) usado na proposta *Personal WebWatcher* aprende os interesses individuais com base nas páginas *Web* que cada utilizador visita e nos documentos associados aos ‘links’ dessas páginas (até um nível). Considera as páginas visitadas como exemplos positivos dos seus interesses e as não visitadas como exemplos negativos ou desinteressantes.

No sistema *Syskill & Webert*, um agente inteligente aprende o perfil do utilizador (para o qual são estabelecidas as 128 palavras mais informativas) a partir de certas palavras existentes nas páginas *Web* visitadas e usa um classificador *bayesiano* para obter o nível de interesse que cada página terá para cada utilizador (Pazzani, Billsus, Michalski, & Wnek, 1997).

O sistema *NewsDude* (Billsus & Pazzani, 1999) analisa as notícias novas que um dado utilizador leu e recomenda aquelas que poderão ter interesse e ainda não lidas. Usa dois

modelos distintos, ambos baseados em conteúdos, para as recomendações. No curto termo, usa o algoritmo de classificação dos *K-NN*, sobre os itens recentemente avaliados pelo utilizador. No longo termo usa um classificador *bayesiano* e um conjunto inicial de notícias que o utilizador fornece.

A solução *Daily Learner* (Billsus, Pazzani, & Chen, 2000) recomenda uma lista de dimensão fixa com as notícias potencialmente mais interessantes para o utilizador. Usa o algoritmo *K-NN*, sobre os vetores das notícias (VSM com *tfidf* sobre o texto integral). Calcula a proximidade das notícias mais recentes acedidas por cada utilizador com as novas notícias para determinar se estas são ou não do interesse do utilizador. Também no longo termo, usa um classificador *bayesiano*, baseando-se nos dados recolhidos durante um longo período de tempo.

O sistema *Fab* (Balabanovic & Shoham, 1997) recomenda páginas *Web* aos utilizadores, usando as 100 mais importantes palavras representativas do conteúdo de cada página. Essas palavras contidas no documento selecionado são trazidas para o processo de aprendizagem do perfil (algoritmo de *Rocchio*), pelo que a similaridade incide sobre as palavras-chave representativas da página *Web* e as constantes no perfil do utilizador.

### 3.2.3 Limitações das diferentes abordagens

Como já referimos ao longo desta apresentação dos vários tipos de SR, estes apresentam alguns problemas ou limitações. Uns problemas afetam mais certas abordagens do que outras, ou mesmo só constituem problemas nalguns SR. Sistematizamos em seguida os problemas principais:

- Incompletude dos itens – Quando não se possui informação suficiente sobre os itens para realizar o cálculo da similaridade entre eles; este é um problema essencialmente dos SRBC (Pazzani & Billsus, 2007);

- Itens iguais – Quando existem itens iguais ou muito semelhantes, mas com descrições diferentes, podem ser tratados como distintos pelos SRBC (Su & Khoshgoftaar, 2009);
- Arranque a frio (*'cold-start'*) – Quando um novo utilizador ou um novo item é inserido no SR, poder-se-á ficar com informação insuficiente associada a ele; este problema poderá dificultar a determinação de itens similares a um novo item na FC *'item-based'*, ou de utilizadores similares a um novo utilizador na FC *'user-based'*; nos SRBC a ausência de informação sobre um novo utilizador impede que lhe sejam geradas recomendações, o que irá acontecer até o SR aprender o seu perfil (até o utilizador seleccionar alguns itens da sua preferência ou até definir explicitamente os dados do seu perfil); para os novos itens, nos SRBC, quando existe informação textual (nestes casos, a informação necessária é o próprio conteúdo do item) ou quando o sistema consegue obter informação sobre o item, não existe este problema (Su & Khoshgoftaar, 2009);
- Ovelhas cinzentas (*"Gray sheep"*) – Nos SRFC pode acontecer que alguns utilizadores registem avaliações inconsistentes, dificultando assim a sua correlação com os restantes utilizadores (Burke, 2002);
- Transitividade da vizinhança – Nos SRFC podem ocorrer situações onde utilizadores com interesses semelhantes não são identificados como similares, pelo simples facto de não terem avaliado os mesmos itens (Su & Khoshgoftaar, 2009).
- Cobertura reduzida – Nos SRFC, poderão existir dados demasiado esparsos nas matrizes de avaliações, provocado pelo problema do arranque a frio e pela própria existência de poucas avaliações (pouca interatividade dos utilizadores), o que poderá limitar a qualidade das recomendações (Su & Khoshgoftaar, 2009);
- Classificações falsas – Quando as avaliações nos SRFC não correspondem às preferências reais dos utilizadores (comportamentos não responsáveis, ou pouco éticos, ou motivado por ataques, ou ainda porque os utilizadores, motivados por questões de privacidade, escondem os seus reais interesses), a qualidade das recomendações ficará fortemente condicionada (Su & Khoshgoftaar, 2009);
- Escalabilidade – Nas técnicas *'memory-based'*, essencialmente, e em ambas as abordagens (FC ou BC), grandes volumes de dados poderão comprometer os tempos de resposta dos SR (Su & Khoshgoftaar, 2009).

Procuramos, em seguida, relacionar alguns destes problemas, numa análise comparativa entre as duas principais abordagens.

Desta forma, comparativamente à FC, os SRBC apresentam alguns fatores favoráveis, tais como:

- Não requerem uma comunidade de utilizadores, pois não necessitam de calcular a similaridade entre utilizadores;
- Possuem mais informação pois conhecem as características e/ ou descrições sobre os itens recomendados (inexistentes nos SR que só implementem FC);
- Podem recomendar itens ainda não selecionados/ avaliados por outros utilizadores (problema existente nos sistemas de FC onde o sistema só consegue propor itens depois de terem sido avaliados por vários utilizadores).

Em sentido contrário, os SRFC também possuem algumas vantagens, face aos SRBC:

- Para itens onde possa ser difícil obter o seu conteúdo ou informações sobre as suas características (por exemplo, em certos tipos de itens como música, fotos ou vídeos), os SRBC poderão não conseguir recomendá-los enquanto nos SRFC estes poderão ser recomendados com base nas avaliações de outros utilizadores;
- Ao se basearem em avaliações, as recomendações colaborativas apresentam um melhor indicador de qualidade do que as que são apenas baseadas nas informações sobre os itens;
- Podem recomendar itens com conteúdos muito diversos, mesmo inesperados, desde que outros utilizadores tenham selecionado esses itens.

Em termos gerais, os SRBC apresentam certas limitações, embora elas dependam das técnicas usadas para a aprendizagem dos perfis e para a geração de recomendações. Os principais aspetos limitativos desta abordagem são os seguintes:

- Fatores como a fiabilidade das descrições dos itens e dos perfis, como a própria complexidade da análise sobre essas mesmas descrições, poderão limitar a

capacidade do sistema em produzir recomendações adequadas aos interesses dos utilizadores, devido a vários fatores:

- O conjunto limitado de palavras pode não ser suficiente para avaliar a qualidade/ relevância dos mesmos ou mesmo para os distinguir (por exemplo, dois textos diferentes, um interessante e o outro nada interessante, podem ser representados exatamente pelas mesmas palavras-chave);
- A ausência de dados em certos atributos nos itens poderá impedir o algoritmo de os propor;
- As técnicas usadas/ selecionadas poderão igualmente condicionar a sua aplicação, pois algumas poderão não ser as mais adequadas para todos os tipos de descrições de itens (onde poderão existir diversos formatos);
- Para certos tipos de conteúdos, como itens multimédia (imagens, gráficos, áudio, vídeo), a extração automática (implícita) de características pode não ser possível ou fácil de obter, comparativamente com a extração automática em documentos de texto;
- O desejo de privacidade por parte dos utilizadores poderá levá-los a não incluírem algumas das informações necessárias nos seus perfis;
- Excesso de especialização (“*overspecialization*”):
  - Fraca capacidade de serendipidade, ou seja, incapacidade de propor itens inesperados, uma vez que existe uma tendência para que as recomendações incidam sobre itens com características similares aos selecionados no passado;
  - Possibilidade do SR sugerir itens demasiado similares e serem por isso considerados redundantes pelos utilizadores (por exemplo, um sistema propor duas notícias sobre o mesmo evento);
- Exigência de um perfil adequadamente preenchido quer com um treino inicial que inclua um razoável número de itens, quer recorrendo a alguma técnica que permita estabelecer um perfil inicial.

Em resposta ao problema de excesso de especialização, várias soluções foram propostas, incluindo a adição de alguma aleatoriedade às recomendações (Sheth & Maes, 1993) ou a filtragem dos itens demasiado similares (Zhang, Callan, & Minka, 2002).

A desejável diversidade dos SR procura, entre outros aspetos, manter e elevar a motivação dos utilizadores no uso destes sistemas. Interessa-nos distinguir a diversidade quanto à recomendação de itens novos ou inesperados. Um item novo possui características similares a outros que são do interesse do utilizador (sugerir um filme novo de um realizador de um filme já selecionado). Com a serendipidade procura-se sugerir itens não contemplados na descrição do perfil do utilizador e que por isso constituam uma surpresa (um filme novo de um novo realizador), ou seja, são inesperados. Alguns trabalhos procuraram respostas para estas questões (Toms, 2000; McNee, Riedl, & Konstan, 2006).

Também os SRFC possuem diversas limitações, que poderão comprometer a qualidade das recomendações, tais como:

- A técnica de FC exige normalmente um razoável número de utilizadores e uma elevada interatividade destes para conseguir obter os dados suficientes para fornecer recomendações úteis;
- O problema de dados esparsos, já referido, ocorre quando o número de avaliações é insuficiente para encontrar itens ou utilizadores similares; este problema afeta particularmente os algoritmos de FC pois reduz a probabilidade de encontrar um conjunto de utilizadores com avaliações similares; acontece mais vezes em sistemas com um grande rácio entre os números de itens e de utilizadores ou nas fases iniciais de arranque do sistema;
- O problema do arranque a frio prejudica especialmente estes algoritmos e pode acontecer após a adição de novos utilizadores ou de novos itens.

Por força destas limitações, realçamos mais uma vez, que as técnicas selecionadas deverão ser as mais adequadas em função das aplicações a que se destinam. Mesmo adotando a técnica mais adequada, surgem, no entanto, limitações para as quais é necessário análise, pesquisa e soluções. Algumas dessas soluções passam pela adoção de outros tipos de sistemas de recomendação, com outras estratégias.

### 3.2.4 Outros Tipos de Sistemas de Recomendação

Tal como já foi referido no início deste capítulo, existem diferentes taxonomias para os SR, onde são referidos outros tipos (especializações ou combinações dos dois principais), tais como: demográfico, baseado em conhecimento, baseado em regras ou híbrido. Sobre este último tipo, SR híbrido, procuraremos apresentar um maior detalhe, dado o seu interesse para o nosso trabalho.

Um SR demográfico recomenda itens baseado no perfil demográfico do utilizador. Pretende-se que diferentes recomendações sejam geradas para diferentes nichos demográficos, tais como a língua, nacionalidade, vencimento ou idade do utilizador. Exemplos comuns incluem o redireccionamento para *Websites* na língua do requerente. A ideia assente neste tipo de SR consiste na alocação dos utilizadores a categorias com base em certos atributos pessoais e na proposta de recomendações orientadas a essas categorias. Um exemplo de SR demográfico recomenda produtos e serviços a segmentos de clientes, em que cada cliente é alocado a um segmento com base num pequeno questionário (Krulwich, 1997). Um outro sistema adotou um classificador para definição das classes demográficas (Pazzani, 1999).

Nos SR baseados em conhecimento a recomendação de itens faz-se com base no conhecimento (adquirido e registado), em que algumas características dos itens se reconhecem como sendo do interesse ou uma necessidade para um dado utilizador. Derivam por isso mesmo dos SRBC. Uma variante destes sistemas, designados por SR baseados na utilidade, calcula a utilidade de cada item de acordo com as necessidades/interesses para o utilizador. Requerem normalmente um modelo de utilizador detalhado, um processo de seleção e sugestão de itens e uma boa descrição dos itens a sugerir. Integram muitas vezes técnicas de ambas as abordagens: colaborativas e baseadas em conteúdos. De acordo com a abordagem usada, estes sistemas baseiam-se normalmente em técnicas de raciocínio baseado em casos (“*case-based*”) ou em regras (“*constraint-based*”).

O raciocínio baseado em casos (CBR, do inglês: “*Case-Based Reasoning*”) é uma técnica onde a resolução de um novo problema reutiliza a resolução, adotada no

passado, de um caso similar. Tipicamente recorre a medidas de similaridade entre itens e requisitos dos utilizadores (definidos no seu perfil ou obtidos por interrogação durante a pesquisa, em ambiente conversacional), procurando por exemplo, maximizar ou minimizar alguns desses requisitos (minimizar o preço, por exemplo). Obtidos os requisitos, o sistema procura itens que sejam concordantes com os requisitos especificados pelo utilizador. A função similaridade deverá estimar de que forma os requisitos do utilizador se adequam às possíveis soluções (recomendações), ou seja, qual a utilidade de cada opção. O conceito de ‘caso’, neste sistema, poderá dizer respeito a um item já sugerido ou a um item sugerido e os dados do perfil do utilizador que importam para esse item, a propor. Um SR que utiliza esta abordagem efetua recomendações de viagens (Ricci et al., 2006).

Os sistemas baseados em regras (“*constraint-based*”) usam regras definidas explicitamente, que relacionam requisitos sobre as características do perfil do utilizador com as características dos itens, propondo os itens que satisfaçam todas (ou o maior número) as regras. Estes sistemas usam normalmente o histórico de cada utilizador. Um exemplo deste tipo de sistemas poderá considerar uma regra que proponha o próximo livro de uma sequela, aos utilizadores que tenham adquirido o livro anterior.

Baseado em casos ou em regras, ambas as abordagens requerem normalmente conversação com o utilizador, no sentido de completar o preenchimento de requisitos necessários para o processo de recomendação.

Os SR baseados na comunidade privilegiam as preferências dos amigos do utilizador ativo, com um entendimento de que estas serão mais fiáveis para os utilizadores que as recebem (Arazy, Kumar, & Shapira, 2009). Este tipo de sistemas também surge referenciado nos trabalhos relacionados com os SR Sociais (Guy & Carmel, 2011), que iremos referir na secção 3.2.6.

As soluções híbridas combinam diversas técnicas procurando melhorar a fiabilidade do sistema e resolver as desvantagens da utilização de uma só técnica de recomendação.

Com os sistemas híbridos, procura-se que uma dada técnica anule as desvantagens de outra que também esteja a ser usada. Certos estudos defendem que as estratégias

híbridas produzem recomendações mais fiáveis quando comparadas com o uso isolado de uma só técnica de recomendação (Melville & Sindhvani, 2010; Pazzani, 1999).

De uma forma geral, estas soluções combinam técnicas de diferentes tipos de SR, embora nada impeça que um sistema híbrido não combine duas ou mais técnicas de um mesmo tipo, tal como a solução *NewsDude* que usou um classificador *bayesiano* e os classificadores *k-NN* (ambas as técnicas são baseadas em conteúdos).

Burke (2007) apresentou os seguintes tipos de sistemas híbridos, de acordo com as estratégias que eles adotam:

- Ponderação – As recomendações de cada técnica são ponderadas, através de pesos e combinadas para produzir um único conjunto de recomendações;
- Troca – O sistema escolhe para cada recomendação a técnica a adotar, de acordo com o contexto;
- Misto – Recomendações usando diferentes técnicas são apresentadas ao utilizador em simultâneo;
- Combinação de características - Usa uma combinação de características de diferentes origens (por exemplo, combinar características sociais com características de conteúdos, ou requisitos explícitos com requisitos assentes no perfil);
- Aumento de características - Usa uma técnica de recomendação para gerar características que são usadas como argumento de entrada da próxima técnica de recomendação;
- Cascata – Uma técnica de recomendação refina as recomendações de outra (por exemplo, a primeira técnica exclui itens e a segunda atribui as avaliações estimadas).
- Meta-nível – É usada uma técnica para produzir um modelo, que é usado como argumento de entrada da próxima técnica.

Em seguida apresentamos diversos sistemas híbridos, propostos e analisados por diferentes investigadores.

O sistema *Fab*, já referido na seção da FBC, é um exemplo de um modelo híbrido meta-nível. Tal como já foi apresentado, este sistema sugere páginas *Web* de acordo com as preferências dos utilizadores. O sistema cria tópicos de interesses de páginas *Web* (“*clusters*”) e disponibiliza-as aos utilizadores que tenham o tipo de perfil associado a esse tópico. Neste sistema, é usada FBC para atualizar quer os perfis dos utilizadores, quer para redefinir um tópico, usando o algoritmo de aprendizagem de *Rocchio* (FBC). Quando uma nova página é incluída ao sistema, é associada a um tópico. (Balabanovic & Shoham, 1997).

Várias abordagens híbridas são baseadas na FC, mas o perfil do utilizador é construído e mantido numa estratégia BC. Estes perfis são usados para obter a similaridade entre utilizadores (não recorrendo à FC para tal), tal como o fez Pazzani (1999). Nesta abordagem, cada perfil é representado por um vetor de palavras ponderadas, obtido a partir do processo de aprendizagem com vários exemplos usando o algoritmo *Winnnow*. Por sua vez, as previsões são calculadas usando a técnica de FC diretamente sobre a matriz de similaridades entre perfis (de utilizadores) e não sobre a habitual matriz de avaliações.

O sistema proposto por (Claypool, Gokhale, & Miranda, 1999) combina as filtragens obtidas por ambas as técnicas, FC e BC, com ponderações adaptativas (o peso da componente de FC aumenta com o número de utilizadores que acedem a cada item), para propor notícias de jornais aos seus leitores.

Cotter e Smyth (2000) apresentaram um sistema que funde as duas listas de recomendações baseadas em técnicas de FC e BC, respetivamente, numa única lista com recomendações de programa de televisão.

Melville et al. (2002) propuseram um sistema híbrido em que inicialmente um processo de FBC completa a matriz esparsa de avaliações, findo o qual são aplicadas técnicas de FC para gerar as recomendações. Em concreto, esse processo usa um classificador *bayesiano* naïve sobre os itens que cada utilizador avaliou e preenche as avaliações não existentes com as previsões determinadas pelo classificador. Com a matriz resultante, totalmente preenchida de avaliações, obtêm a similaridade entre utilizadores. Para produzir as estimativas finais de avaliação usa o coeficiente de correlação de *Pearson*,

considerando ainda diferentes pesos para as avaliações reais e para as avaliações estimadas, obtidas pelo classificador.

A plataforma de recomendação *RACOFI* apresenta uma arquitetura híbrida, seguindo o modelo de cascata. As recomendações são primeiro calculadas pela componente de filtragem colaborativa, sendo depois usadas como argumento de entrada para um sistema baseado em conteúdos, que recorrendo a regras, refina as recomendações obtidas (Anderson et al., 2003).

De realçar que no concurso promovido pela *Netflix*, já referido, a maioria das soluções apresentadas recaem no tipo de abordagem híbrida.

### 3.2.5 Explicações em Sistemas de Recomendação

Muito dos atuais SR recorrem ao uso de explicações que acompanham as respetivas recomendações, reforçando e complementando as estimativas de avaliação. Segundo Tintarev e Masthoff (2007), são vários os benefícios associados a estas explicações:

- **Transparência** - procura-se que o utilizador perceba por que um dado item é preferível a outro, ou seja, deve-se explicar como o sistema funciona;
- **Validade** - as explicações podem igualmente dar condições para o próprio utilizador validar a recomendação (certa ou errada) que lhe é simultaneamente proposta;
- **Confiabilidade** - a confiabilidade que a explicação poderá trazer reduzirá a incerteza do utilizador, o que vai aumentar a sua confiança no sistema;
- **Poder de persuasão** - uma explicação persuasiva procura realçar os aspetos positivos (ignorando os negativos), persuadindo o utilizador na sua seleção do item;
- **Eficácia** - traduz-se no apoio ao utilizador para este tomar as decisões mais acertadas;
- **Eficiência** - poderá reduzir o esforço na tomada de decisão (ou o tempo necessário);

- Satisfação - crê-se que as explicações poderão contribuir para um maior nível de satisfação do utilizador no uso do SR;
- Relevância - quando um SR necessita de interação com o utilizador para produzir a recomendação (SR do tipo conversacional) as explicações poderão ajudá-lo a perceber o porquê da informação adicional;
- Compreensibilidade - as explicações permitem igualmente melhorar a compreensão do utilizador sobre a recomendação produzida;
- Educação - ao melhorar os conhecimentos dos utilizadores estamos a capacitá-los para melhores tomadas de decisão sobre o domínio da recomendação o que poderá levar o utilizador a efetuar novas aquisições ou novas pesquisas sobre esse mesmo domínio, ou seja, a recorrer novamente ao SR.

De realçar que alguns destes benefícios possuem grandes níveis de inter-relação.

Na figura seguinte, no sítio Amazon.com é explicado ao utilizador que a recomendação do primeiro livro (item de cima) se deve ao facto de ele ter adquirido um outro livro (item de baixo).

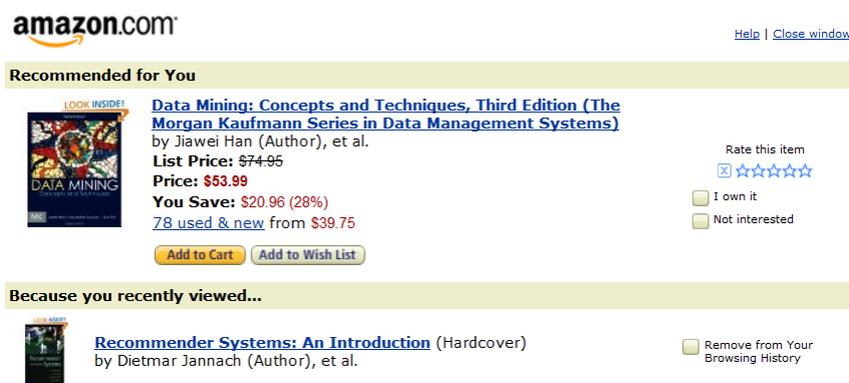


Figura 15 – Uso da opção “Fix this recommendation” no sítio Amazon.com

As explicações podem ter vários tipos. A explicação do tipo vizinho mais próximo (utilizador ou item) usa essa proximidade para efetuar sugestões ao utilizador ativo (exemplos: “quem comprou o item X também comprou os itens Y e Z”; “o item Y é recomendado porque avaliou o item X, relacionado”). Uma explicação baseada em conteúdo surge das características dos itens existentes no SR e do perfil do utilizador (exemplo: “Esta revista refere os tópicos X e Y que são do seu interesse”). As

explicações baseadas na rede social, embora envolvendo questões relacionadas com a privacidade, usam as relações de confiança que os utilizadores estabelecem nas redes sociais para criar explicações eventualmente mais confiáveis (exemplo: “O seu amigo X escreveu no blogue o seguinte: Y”; “X% dos seus amigos gostam deste item e apenas Y% não gostam”).

Outro tipo de explicações, introduzido mais recentemente, recorre ao uso de ‘tags’ sociais (ver figura 16).



Fonte: (Vig, Sen, & Riedl, 2009)

Figura 16 - Uso de 'tags' no Website MovieLens

Segundo (Vig, Sen, & Riedl, 2009), as ‘tags’ sociais podem ser analisadas relativamente à sua relevância relativamente ao item ou preferência relativamente ao utilizador (ver figura 17).



Fonte: (Vig, Sen, & Riedl, 2009)

Figura 17 - Exemplo do uso de ‘tags’

A relevância de uma ‘tag’ descreve a relação entre o item e a ‘tag’. Essa relação poderá medir a sua popularidade (quantos utilizadores usaram a ‘tag’ para um dado item?) ou a correlação da preferência pela ‘tag’ com a preferência verificada pelo item (será que os

utilizadores que mostraram preferência por uma dada ‘tag’, por exemplo o nome de um dado ator, também mostraram interesse pelo item que lhe está associado, por exemplo o nome de um filme?). A preferência do utilizador por uma dada ‘tag’ pode ser obtida por interrogação direta da opinião ao utilizador sobre a mesma, ou inferida a partir das suas ações (se um dado utilizador atribuir elevadas avaliações a itens com uma mesma ‘tag’, provavelmente terá uma preferência positiva por essa ‘tag’).

Por fim, interessa referir que o uso de explicações deverá ter em conta não só os objetivos que as mesmas pretendem atingir, como as técnicas de recomendação usadas no SR. De realçar ainda que as recomendações poderão ter um efeito positivo sobre a decisão do utilizador, mas também poderão contribuir para direcionar o utilizador para tomadas de decisões que apenas servem os interesses do fornecedor (e sendo desvantajosas para o utilizador, poderão levar ao seu afastamento da solução).

### 3.2.6 Novos Desenvolvimentos

Nesta secção apresentamos algumas aplicações inovadoras onde têm surgido propostas que usam os SR.

Exemplos dessas aplicações incluem o uso de fontes de conhecimento externas, como a *Wikipedia*, a utilização de ‘tags’, tomam em consideração fatores de contexto e integram-se nos serviços *Web 2.0*.

Tal como já foi referido, as ambiguidades da análise linguística constituem um problema para as soluções de recomendação baseadas apenas nas construções sintáticas dos textos, ou das descrições dos itens e perfis de utilizadores. Algumas soluções que procuram responder a este problema, recorrem a técnicas de análise semântica, usando bases de conhecimento como léxicos ou ontologias para representar os perfis e descrever os itens. A ideia essencial assenta na utilização de uma interpretação “semântica” dos interesses e necessidades dos utilizadores. Algumas dessas propostas vão no sentido de complementar o conhecimento que o sistema já foi capaz de adquirir de forma endógena (com base nos perfis, itens e interações entre ambos) com o conhecimento exógeno, obtido a partir de recursos externos. O sistema *Wikifi!*

(Mihalcea & Csomai, 2007) é uma dessas propostas. Neste sistema, o perfil dos itens pode ser obtido de forma manual ou de forma automática. A forma automática extrai conceitos existentes nos textos dos itens e associa-os às páginas da *Wikipedia* correspondentes (considerada informação semântica relacionada). A comparação entre as formas automática e manual demonstraram que esta solução é de interessante aplicação.

Uma das áreas promissoras para os SR baseia-se nos conteúdos gerados pelos utilizadores nas aplicações *Web2.0*, designadamente com as *folksonomias*. O uso de ‘tags’ já foi referido, quer como forma de indexação, quer como forma de anotação (ou explicação) sobre os itens. Para além destas utilizações, também foi proposto o uso destas ‘tags’ para representação do perfil do utilizador, dos itens ou de ambos, em combinação com as habituais técnicas dos SR (Diederich & Iofciu, 2006; Firan, Nejdli, & Paiu, 2007; Szomszor et al., 2007). Estas ‘tags’ poderão ser criadas por cada utilizador (pessoais), por outros utilizadores que classificaram o mesmo item (sociais) ou por utilizadores considerados peritos. Defende-se que os peritos, ao possuírem um conhecimento maior sobre um dado item, poderão registar uma avaliação mais coerente sobre o mesmo (Aurnhammer, Hanappe, & Steels, 2006).

Uma outra área inovadora no desenvolvimento dos SR considera o contexto em que as recomendações são geradas. A ideia deste tipo de recomendações assenta numa personalização que, além de se basear no utilizador, considera o contexto em que a recomendação é produzida. Vejamos alguns exemplos: o tempo (ou época do ano) deverá ser considerado nas recomendações de férias (verão ou inverno deverão levar o SR a propor recomendações distintas), ou o dia da semana (fim de semana ou dia de semana) e/ ou a refeição (almoço ou jantar), assim como o número e tipo de acompanhantes (refeição de lazer ou profissional), poderão constituir todos eles, aspetos relevantes no processo de recomendação de um restaurante. Para incorporar o contexto nos SR foram sugeridas três diferentes abordagens para os respetivos algoritmos de recomendação:

- Pré-filtragem: somente se considera a informação relativa ao atual contexto (por exemplo, só se usam as avaliações obtidas no mesmo contexto); na literatura encontram-se alguns exemplos que exploraram esta abordagem (Ahn, Kim, &

Han, 2006; Baltrunas & Amatriain, 2009; Lombardi, Anand, & Gorgoglione, 2009);

- Pós-filtragem: o algoritmo de recomendação não considera o contexto e apenas as recomendações resultantes serão filtradas de acordo com o contexto pretendido; esta abordagem foi analisada comparativamente com a abordagem anterior no trabalho de (Panniello, Tuzhilin, Gorgoglione, Palmisano, & Pedone, 2009);
- Modelação por contexto: esta é a técnica mais sofisticada e usa diretamente os dados de contexto para o cálculo da previsão de avaliação das recomendações; foi proposta em alguns sistemas (Abbar, Bouzeghoub, & Lopez, 2009; Oku, Nakajima, Miyazaki, & Uemura, 2006).

De realçar que os domínios de aplicação dos SR nos últimos anos têm aumentado de forma crescente, tirando proveito do desenvolvimento das redes sociais e dos conteúdos gerados e criados pelos próprios utilizadores de forma distribuída (*Web 2.0*). Atualmente, encontramos conteúdos com diversos formatos, tais como ‘tags’, votos (“Like”), relacionamentos (amigos, grupos, ...), blogues, fotos, músicas, vídeos, *emails*, mensagens instantâneas, entre outros. Desta forma, alguns sistemas procuraram explorar estes novos formatos dando origem aos SR Sociais (Guy & Carmel, 2011). Estes sistemas sugerem conteúdos (por exemplo, vídeos, *wikis*, notícias, artigos de fóruns, *blogs*, ‘tags’), pessoas, grupos de pessoas, comunidades, etc.

### 3.3 Sistemas de Recomendação aplicados ao Ensino

O desenho, desenvolvimento e teste de inovações tecnológicas que permitam melhorar as práticas de ensino e/ ou aprendizagem para os estudantes está associada à área da Aprendizagem baseada nas Novas Tecnologias, igualmente designada por Tecnologia Avançada de Aprendizagem (TEL, do inglês: *Technology Enhanced Learning*). Os Sistemas de Recomendação aplicados ao ensino são referenciados nessa área de tecnologias (Manouselis, Drachsler, Vuorikari, Hummel, & Koper, 2010).

### 3.3.1 Domínio de Aplicação

Ao longo deste documento, várias vezes fizemos referência aos inúmeros recursos de aprendizagem, essencialmente digitais, disponíveis para o ensino, quer em ambientes formais, como informais.

Consideramos por isso mesmo, que os sistemas de informação de suporte ao ensino poderão beneficiar enormemente da existência de funcionalidades ou serviços que ajudem os estudantes a obter os recursos de aprendizagem mais adequados a cada um, da mesma forma que os SR comerciais ajudam os consumidores a encontrar os produtos mais adequados. É neste enquadramento que se justifica a inclusão dos sistemas de recomendação nos sistemas de suporte ao ensino.

A aprendizagem é um processo muito exclusivo, cheio de particularidades, abrangendo questões pedagógicas, modelos de aprendizagem, competências existentes e a obter por cada aluno, diferentes tempos de aprendizagem (necessários para os mesmos conteúdos) para diferentes alunos, eventual necessidade de processos de repetição de aprendizagem, diferentes prioridades para as diversas atividades de aprendizagem, eventuais pré-requisitos e dependências entre atividades; etc.. Essas particularidades devem ou podem interferir no desenho dos SR, nas funcionalidades que eles propõem, tornando-os diferentes dos SR comerciais. De realçar que a influência do tipo de item a recomendar (curso a inscrever, conteúdo de aprendizagem, etc.), ou seja, do seu domínio de aplicação concreto, é determinante no desenho destes sistemas.

Para os professores, o uso dos SR poderá ter impacto na preparação das aulas, na disponibilização das mesmas ou dos conteúdos associados, na avaliação dos alunos, etc..

Estes são apenas alguns fatores, que só por si, tornam o desenho e a implementação de SR para o ensino, únicos, o que significa que a simples transferência de um SR existente (de um domínio comercial, por exemplo) para o ensino pode revelar-se inadequado para os seus destinatários (professores e alunos).

De realçar que, geralmente, num SR comercial, um consumidor apenas procura um produto num determinado nível de qualidade e preço, o que torna a solução do ensino mais complexa. Requer na maioria das vezes, uma abordagem personalizada, deve analisar a influência de todas as suas particularidades e procurar focalizar-se nos aspetos fundamentais que são os objetivos da aprendizagem e o suporte a oferecer aos alunos no sentido destes os atingirem (Manouselis et al., 2010).

### 3.3.2 Funções

Nos SR aplicados ao ensino, os habituais utilizadores são alunos e os itens são atividades de aprendizagem. O principal resultado deste tipo de sistemas deverá ser propor aos alunos as atividades de aprendizagem mais adequadas ao desenvolvimento das suas competências. Para tal, dever-se-ão considerar as características relevantes dos alunos (onde se incluem as competências já obtidas) assim como as características das atividades de aprendizagem.

Já anteriormente foram apresentadas as principais tarefas suportadas pelos SR (Herlocker et al., 2004). Da sua adequação ao ensino (Manouselis et al., 2010) são propostas as seguintes tarefas:

- Recomendar alguns itens adequados - resulta uma lista com sugestões de itens (sugerir lista de conteúdos educativos associados a um tópico);
- Recomendar todos os itens adequados - resulta uma lista com todos os itens relevantes para o utilizador (sugerir lista completa de artigos científicos sobre um tópico);
- Efetuar anotação em contexto – efetuar recomendações enquanto o utilizador está a fazer outras tarefas (incluir estimativa com o potencial interesse para o utilizador sobre os conteúdos de um curso num sistema de gestão de aprendizagem, como o *Moodle*);
- Recomendar uma sequência - em vez de gerar uma só recomendação, propor uma lista ordenada de itens a selecionar (por exemplo: propor uma lista ordenada de conteúdos a realizar para atingir um dado objetivo);

- Recomendar durante a navegação- na navegação entre páginas *Web* efetuar sugestões (propor recomendações para o curso que o aluno está a frequentar);
- Funções de demonstração da credibilidade do SR - disponibilizar funcionalidades que permitam ao utilizador testar as respostas do SR, designadamente na fase inicial (no início, propor recomendações de grande confiança/ credibilidade).

Para estas tarefas poderem ser cumpridas, alguns requisitos deverão ser acautelados, tais como a definição dos atributos que poderão representar a utilidade/ relevância e dos critérios que poderão medir a confiança e a credibilidade do sistema.

Outras tarefas foram igualmente sugeridas como podendo ser incluídas nos SR e que serão úteis para o ambiente de ensino (Manouselis et al., 2010; Manouselis, Drachler, Verbert, & Duval, 2013):

- Encontrar novos recursos – recomendar novos itens (receber sugestões com os novos recursos, ou recursos inesperados de tópicos abrangidos pelo aluno);
- Encontrar parceiros – recomendar outros utilizadores com interesses relevantes (recomendações com referências a alunos com perfis similares, do curso ou da rede de aprendizagem);
- Encontrar diferentes caminhos de aprendizagem – propor caminhos alternativos por entre os mesmos recursos de aprendizagem (receber sequências alternativas de conteúdos, visando os mesmos objetivos);
- Prever avaliações dos estudantes;
- Estimar a qualidade de ensino dos professores.

Para estas tarefas adicionais, torna-se necessário explorar as técnicas mais adequadas para a seleção de itens, determinação da similaridade, representação dos perfis dos alunos e determinação dos critérios a usar para a recomendação de sequenciamentos alternativos.

### 3.3.3 Técnicas de Recomendação

Num estudo de (Drachsler, Hummel, & Koper, 2008) foram mapeadas as técnicas de recomendação principais e a sua eventual aplicabilidade aos SR aplicados ao ensino.

As técnicas de FC ‘*user-based*’ e ‘*item-based*’ mostram-se úteis em aprendizagens com diferentes tópicos, uma vez que são independentes do domínio (não necessitando de serem ajustadas para diferentes tópicos). Este aspeto será mais relevante nas redes de aprendizagem onde o número de tópicos poderá ser elevado. Com estas técnicas os alunos poderão beneficiar das experiências de outros alunos, com base nas avaliações que estes fizeram às atividades de aprendizagem já efetuadas. A verificação de avaliações similares entre alunos poderá ser considerada para agrupar alunos e em função dos grupos propor as atividades mais adequadas.

A criação de grupos também poderá decorrer com base em dados recolhidos para o perfil dos alunos. Nesse caso, torna-se mais simples alocar desde o início os alunos a grupos e assim criar uma solução que minimiza as situações de “*cold-start*”, pois é mais fácil sugerir recomendações a um aluno novo em função do grupo a que é alocado.

As técnicas de recomendação baseadas nos conteúdos consideram técnicas de correlação entre as características dos alunos e/ ou das atividades de aprendizagem. As duas principais abordagens correlacionam características de perfis e de atividades ou só entre atividades.

### 3.3.4 Exemplos

Nos últimos anos, são vários os trabalhos propostos para os SR aplicados ao ensino. Passaremos de seguida a analisar alguns deles.

O sistema *Altered Vista* foi implementado na sua totalidade, tendo sido testado e avaliado. O objetivo inicial do trabalho assentava no processo de obtenção das avaliações dos alunos aos conteúdos de aprendizagem e na sua posterior distribuição

pelos outros alunos. Estudaram o desenho do sistema, os meta-dados a usar para registrar as avaliações dos alunos e desenvolveram um protótipo que recomendava conteúdos relevantes e divulgava o nome de alunos com interesses similares (Walker, Recker, Lawless, & Wiley, 2004).

O sistema *RACOFI* (*Rule-Aplying Collaborative Filtering*) combinou duas abordagens com o objetivo de recomendar atividades de aprendizagem adequadas aos alunos: filtragem colaborativa aplicada às avaliações que os alunos fazem sobre os conteúdos e mineração de regras de associação entre atividades de aprendizagem (Anderson et al., 2003).

No sistema *QSIA* (*Questions Sharing and Interactive Assignments*), o aluno pode optar entre receber recomendações explícitas de um colega (ou amigo) ou usar o serviço de filtragem colaborativa (Rafaeli, Dan-Gur, & Barak, 2005).

No sistema *CYCLADES* foi proposto um ambiente onde os alunos pesquisam, acessam e avaliam recursos retirados do repositório de arquivos disponibilizado pelo projeto *Open Archives Initiative*. As recomendações de recursos educativos, provenientes de diferentes arquivos digitais, são disponibilizadas através de um SR baseado em técnicas de filtragem colaborativa. Foram efetuados testes e avaliações sobre vários algoritmos (Avancini & Straccia, 2005).

Também o sistema *CoFind* recorreu aos conteúdos livres existentes na Internet, mas propôs que as recomendações se baseassem em *folksonomias* (marcadores sociais) em vez de preferências de alunos (Dron, Mitchell, Siviter, & Boyne, 2000).

Tang e McCalla (2005) propuseram um sistema, mais tarde desenvolvido e testado, que usava uma abordagem híbrida, considerava o uso de marcadores ('tags') na caracterização de artigos de investigação que eram guardados e recomendados (e que por sua vez os alunos avaliavam após lhes acederem), agrupava os alunos de acordo com os seus interesses (usando técnicas de *clustering*) e usava filtragem colaborativa para identificar os alunos com interesses similares, mas dentro de cada grupo.

Sobre o sistema *Moodle*, foi implementado um SR simples, que não considerava informações sobre o perfil dos alunos, usando apenas as técnicas de filtragem colaborativa. A avaliação sobre esse sistema demonstrou eficácia, no sentido em que as atividades de aprendizagem eram levadas até ao fim, mas não eficiência, uma vez que as atividades de aprendizagem passaram a necessitar de mais tempo (Janssen et al., 2005).

A abordagem do modelo *LORM* (*Learning Object Recommendation Model*) recaiu sobre um sistema híbrido de recomendação de conteúdos de aprendizagem, usando múltiplos atributos para os descrever (Tsai, Chiu, Lee, & Wang, 2006).

Também o uso de múltiplos atributos nas avaliações dos recursos educativos foi proposta e testada com vários algoritmos de filtragem colaborativa na recomendação de atividades de aprendizagem (Manouselis, Vuorikari, & Van Assche, 2007).

O sistema *CourseRank* é um guia de cursos para os alunos da *Universidade de Stanford*, que usa uma abordagem híbrida para recomendação de cursos adequados aos alunos baseada na informação relacional existente sobre os cursos e sobre os alunos (Koutrika, Bercovitz, Kaliszan, Liou, & Garcia-Molina, 2009).

Nadolski et al. (2009) criaram um ambiente de simulação onde testaram vários algoritmos de recomendação numa abordagem híbrida. Compararam diferentes técnicas, incluindo filtragem colaborativa com recurso a ontologias. As técnicas de filtragem colaborativa demonstraram resultados positivos, tanto em redes de aprendizagem como em ambientes formais.

O sistema *ISIS* adotou uma abordagem híbrida para propor a melhor próxima atividade de aprendizagem baseada nas escolhas de outros alunos com perfis similares. Usava informações sobre itens, sobre os utilizadores (perfis) e sobre as suas avaliações. Nos testes efetuados puderam constatar que o SR melhorou especialmente a eficiência (tempo de estudo necessário para completar as atividades de aprendizagem), houve satisfação no uso e variabilidade nos sequenciamentos (Drachsler et al., 2009).

A plataforma *RPL* implementada no repositório de cursos da *Virtual University of Tunis* é um protótipo que usa um sistema híbrido de recomendação de conteúdos de

aprendizagem (combinando um algoritmo de filtragem colaborativa com filtragem baseada em conteúdo), usando dados que foram registados (em *logs*) e extraídos (derivados) das ações dos alunos sobre o sistema (Khribi, Jemni, & Nasraoui, 2009).

A proposta de Bobadilla et al. (2009) teve por base dar maior relevância aos alunos com mais conhecimentos (que tivessem tido melhores avaliações). Para tal, sugerem alterações à formulação associada às técnicas de filtragem colaborativa ‘*memory-based*’ que permitam dar um maior peso a esses alunos.

Ghauth e Abdullah (2010) propuseram um SR para conteúdos de aprendizagem capaz de mostrar itens similares ao que está a ser selecionado e recomendar alguns com base nas avaliações dos alunos. Para o primeiro objetivo propõem o uso de uma técnica de recomendação baseada no conteúdo (uso do modelo do espaço vetorial para calcular a similaridade entre itens). Para o segundo objetivo, consideram-se as avaliações que os melhores alunos fizeram aos conteúdos.

O sistema *DELPHOS* propôs um sistema híbrido de recomendação de conteúdos de aprendizagem. Usa uma combinação de diferentes técnicas de filtragem, considerando a similaridade entre conteúdos, o nível do seu uso por outros alunos (conteúdos frequentemente utilizados ou não), a sua avaliação (baseado em 12 critérios, com diferentes níveis de relevância ou ponderações, correspondentes a 6 categorias) e a similaridade entre perfis de utilizadores. Estes quatro filtros são posteriormente ponderados por forma a calcular o valor estimado do conteúdo que irá (ou não) constar da lista de conteúdos a recomendar (Zapata, Menendez, Prieto, & Romero, 2011).

### **3.4 Avaliação dos Sistemas de Recomendação**

Segundo Dix et al. (2003) a avaliação de um sistema interativo pretende assegurar que ele se comporta como esperado por quem o desenhou e que satisfaz os requisitos do utilizador.

São várias as perspectivas de avaliação dos SR. As principais métricas que se encontram definidas são essencialmente técnicas e pretendem avaliar a precisão das avaliações estimadas. Contudo, outras propriedades dos SR merecem atenção no que diz respeito à avaliação do desempenho e da qualidade das recomendações geradas. Em particular, quando aplicados ao ensino, a avaliação destes sistemas deverá corresponder ao domínio específico em que as recomendações são aplicadas.

Nas secções seguintes serão abordados, com algum detalhe, os principais aspetos relacionados com a avaliação dos SR, de um modo geral, e em particular sobre os SR educativos.

### 3.4.1 Dimensão Técnica

A avaliação dos SR começou a ser estudada essencialmente através de medidas técnicas sobre os algoritmos de recomendação aplicados às lojas de vendas de produtos na Internet (Adomavicius & Tuzhilin, 2005; Burke, 2002; Herlocker et al., 2004). De realçar que os estudos desta área beneficiaram da existência de conjuntos de dados (*Eachmovie*, *MovieLens* e *Netflix* são dos mais relevantes) e de ferramentas que implementam diversos algoritmos, disponibilizadas de forma livre para poderem ser exploradas. O principal grupo de medidas desenvolvidas para os SR, essencialmente vocacionado para o comércio eletrónico, está relacionado com o fator precisão. A ideia de que os SR que produzem recomendações mais precisas são os preferidos dos utilizadores, faz com que quer a avaliação como o esforço de desenvolvimento destes sistemas recaia predominantemente sobre os algoritmos, para que estes produzam as melhores recomendações.

As avaliações que estes sistemas produzem incidem geralmente numa das seguintes categorias:

- Classificações binárias;
- Classificações n-árias;
- Classificações n-árias em listas ordenadas.

O uso de classificações binárias é muito comum em sistemas de recomendação. Neste caso, é atribuída igual relevância a todas as recomendações e os utilizadores só podem indicar se gostam ou não de um item (ou se é bom ou mau, ou se é relevante ou não). De realçar que por vezes as classificações com escalas de diversos valores são convertidas para binárias.

As classificações n-árias permitem aferir o quão próximo estiveram as classificações inferidas pelo sistema, das classificações atribuídas pelos utilizadores, quando a avaliação obedece a uma escala com diversos valores.

Quando as recomendações resultam numa lista ordenada de classificações, onde a escala possui igualmente diversos valores, falamos em classificações n-árias em listas ordenadas. Neste caso as métricas de avaliação a usar permitem avaliar a qualidade das listas de itens apresentadas aos utilizadores, de acordo com a preferência demonstrada por estes. De realçar que a ordem com que os itens são recomendados é importante, já que os itens nas posições finais da lista têm tendência a serem ignorados pelos utilizadores.

No que diz respeito às métricas de desempenho propostas, várias assentam numa matriz entre itens seleccionados pelos utilizadores e itens recomendados pelo sistema, conforme tabela seguinte (Shani & Gunawardana, 2009):

**Tabela 4- Classificação dos possíveis resultados de uma recomendação**

<b>ITEM</b>	<b>Recomendado</b>	<b>Não recomendado</b>
<b>Usado</b>	Verdadeiro-Positivo (VP)	Falso-Negativo (FN)
<b>Não usado</b>	Falso-Positivo (FP)	Verdadeiro-Negativo (VN)

Shani e Gunawardana (2009) agruparam em três classes as métricas de precisão das recomendações:

- Precisão das avaliações – neste caso interessa medir a precisão da avaliação prevista (tipicamente um valor numérico ou um valor de uma escala de diversos

valores) pelo algoritmo de recomendação para cada utilizador; as medidas do Erro Médio Absoluto (MAE, do inglês: “Mean Absolute Error”) e Erro Médio Quadrático (RMSE, do inglês: “Root Mean Squared Error”) são as mais referenciadas (ver apêndice 5);

- Precisão no uso das recomendações – neste caso interessa-nos medir se o sistema recomendou itens que o utilizador selecionou ou não (e não a precisão das estimativas de avaliação); algumas das medidas mais usadas, baseiam a sua formulação nos dados da tabela 4, e incluem a Precisão, Cobertura, Rácio dos verdadeiros-negativos, Rácio dos falsos-positivos, Exatidão ou Medida-F (ver apêndice 5);
- Precisão das listas ordenadas de itens – as medidas desta classe consideram a ordem dos itens nas listas apresentadas aos utilizadores, permitindo avaliar a qualidade das listas de itens apresentadas aos utilizadores, de acordo com a preferência demonstrada por estes (a ideia base assenta na comparação entre a lista que cada utilizador faria, com a lista que o SR fez); algumas das métricas mais referenciadas incluem o grupo e métricas de ganho acumulado (DCG, do inglês “Discount Cumulative Gain”), *Lift index* (Ling & Li, 1978; Hsu, Chung, & Huang, 2004) e *RankScore* (Breese et al., 1998).

Algumas destas métricas são descritas no apêndice 5, podendo encontrar-se um estudo detalhada em (Shani & Gunawardana, 2009) e em (Herlocker et al., 2004).

### 3.4.2 Outras Dimensões da Avaliação

Para além das classes de métricas associadas à precisão dos algoritmos, existe um conjunto adicional de fatores cuja avaliação poderá ser extremamente útil nos diversos SR e que se encontra detalhadamente referenciada (Ricci et al., 2010).

As situações de arranque a frio (“*cold-start*”), já referidas, quer pela adição de novos itens como de novos utilizadores poderão refletir uma importante medida que nos revela o grau de cobertura ou abrangência do sistema.

O grau de confiança nas avaliações do sistema, que normalmente melhora com a utilização do mesmo, é outro aspeto a considerar na avaliação dos sistemas.

A credibilidade do sistema está normalmente associada à sua capacidade de gerar boas recomendações (ainda que possam não ser usadas ou selecionadas pelos utilizadores) independentemente das avaliações.

A similaridade entre itens é uma característica usada em muitos SR. No entanto, nalgumas aplicações poderemos ter interesse em adicionar recomendações de itens diversos.

Essa diversidade poderá e deverá ser avaliada. A diversidade poderá considerar itens que constituam uma novidade ou que sejam inesperados. Nalgumas soluções poderá ainda ser útil avaliar a capacidade do SR produzir recomendações que sejam novidades (itens desconhecidos mas de alguma forma associados ao conhecimento que temos dos utilizadores são recomendados; por exemplo propor um novo filme de um realizador que o utilizador gosta). Para além das novidades, também a capacidade de gerar recomendações inesperadas, poderá ser bastante útil em certos sistemas. Neste caso, interessa medir se estas recomendações são ou não desejáveis para cada utilizador pois, se por um lado é importante apresentar recomendações inesperadas ou desconhecidas, a excessiva diversidade e novidade nas recomendações poderá afetar a satisfação dos utilizadores.

Sobre estes últimos dois fatores foram propostos o índice de *Gini* (Fleder & Hosanagar, 2007) e o coeficiente de entropia de *Shannon* (Ricci et al., 2010), para medir a diversidade presente nas recomendações.

A utilidade do SR é outro aspeto importante a considerar nas avaliações. Neste caso, poderá ser relevante avaliar a utilidade para quem recebe como para quem fornece o serviço de recomendação (por exemplo, medir o incremento das vendas para o fornecedor da loja e a poupança que o consumidor consegue obter).

Nalgumas aplicações, poderá ainda ser necessário medir o risco do SR. Nesses casos, procura-se medir não só o valor que se estima ganhar (utilidade esperada) com a recomendação, ajustando-a ao risco associado (variância da utilidade).

Outro aspeto relevante envolve a robustez da solução. Esta poderá estar relacionada com aspetos de segurança ou com a sua escalabilidade. No caso da segurança, torna-se útil medir a capacidade do sistema ser imune a ataques (injeção de informação falsa, como perfis de utilizadores falsos que poderão influenciar as recomendações). Para avaliar a escalabilidade do sistema deverá ser analisada a sua capacidade de responder a inúmeros pedidos de recomendações num curto período, por exemplo.

A privacidade é também uma característica relevante, pois os utilizadores podem pretender beneficiar das recomendações mas manter os seus interesses privados. Por outro lado, a privacidade ou a ausência dela (ou ainda o estabelecimento de diferentes níveis de privacidade) poderá influenciar outras medidas, pelo que poder-se-á ter que analisar o que medir.

A adaptabilidade é outra propriedade relevante da maioria dos SR. Envolve os novos itens e os novos utilizadores. Medir a influência das alterações ao perfil dos utilizadores sobre as recomendações geradas é uma medida que se poderá mostrar necessária. Outra medida que poderá ser útil poderá avaliar a necessidade de informação para que um dado item consiga ser recomendado.

A escalabilidade, já referida sobre a robustez destes sistemas, é outra propriedade fundamental quando se pretende gerar recomendações rapidamente e temos um enorme conjunto de dados. Interessa neste caso, medir os vários fatores que poderão influenciar o desempenho destas soluções.

As medidas referidas, essencialmente técnicas, conjuntamente com as propriedades que caracterizam o desenho das várias soluções de recomendação representam, contudo, apenas uma dimensão da avaliação. Outras dimensões serão consideradas na secção seguinte, específica, sobre a avaliação destes sistemas quando aplicados ao ensino.

### 3.4.3 Avaliação dos Sistemas de Recomendação Aplicados ao Ensino

A avaliação dos SR aplicados ao ensino, dadas as particularidades do contexto da área da educação, não estará devidamente abrangida, sem envolver igualmente as medidas pedagógicas e de avaliação do envolvimento e contribuição da rede no processo de aprendizagem.

Considerando estas três dimensões de avaliação, foi proposta uma ferramenta de avaliação para os SR aplicados ao ensino, com onze critérios de avaliação (Drachsler, Hummel, & Koper, 2009):

- Dimensão Técnica:
  - Precisão – medida que avalia quão perto a estimativa de avaliação dos itens gerada pelo SR está do valor real de preferência de cada utilizador;
  - Cobertura – mede a percentagem de itens para os quais o SR consegue determinar as estimativas de avaliação;
  - Performance – avalia se o SR é capaz de produzir as recomendações em tempo útil.
- Dimensão Educacional:
  - Eficácia – medida que avalia se a totalidade das atividades de aprendizagem foram exploradas e estudadas;
  - Eficiência – medida que avalia o tempo despendido para atingir os objetivos da aprendizagem;
  - Satisfação – avalia o grau de satisfação dos alunos com as recomendações recebidas;
  - Taxa de Abandono – medida que avalia o número de alunos que abandonaram o uso do SR durante a aprendizagem;
- Medidas de Análise da Rede Social:
  - Variedade – mede a diversidade de caminhos de aprendizagem individuais propostos aos alunos capazes de os conduzir aos objetivos pretendidos;

- Centralidade – medida que reflete o nível de envolvimento do aluno com a rede (número de ligações entre os vários alunos da rede);
- Proximidade – mede o grau de proximidade do aluno com toda a comunidade de alunos da rede e representa a capacidade de obtenção de informação através dos membros da rede, quer por via direta, como indireta;
- Coesão – mede a força dos laços de coesão entre os alunos na rede (quantos alunos estão ligados a todos os membros da rede, por exemplo).

As medidas de Análise da Rede Social (ou SNA: do inglês: *Social Network Analysis*) são mais relevantes quando estão envolvidas redes de aprendizagem.

A adoção e implementação desta proposta possui algumas dificuldades metodológicas e pragmáticas. Alguns critérios podem mesmo apresentar resultados contraditórios nas diversas dimensões. Por exemplo, um grupo de alunos que avaliou muitos LO, que estabeleceu muitas ligações com outros alunos, possui um papel central numa rede de aprendizagem numa perspectiva SNA. Contudo, numa perspectiva educativa, esse mesmo grupo de alunos poderá apresentar valores mais baixos de eficiência (necessitarem de mais tempo de estudo) e de eficácia (completaram com sucesso menos LO) do que outros alunos da rede.

Em alternativa, podemos considerar a investigação realizada no âmbito da educação, e usar uma das ferramentas clássicas de avaliação, aí estudadas, depois da sua adaptação ao contexto dos SR. Vejamos a aplicação do modelo de quatro níveis de *Kirkpatrick*, proposto para avaliar os SR aplicados ao ensino (Kirkpatrick & Kirkpatrick, 2006):

- Reação do Utilizador – aferir se o aluno gostou das recomendações que recebeu;
- Aprendizagem – aferir se o SR ajudou a obter os conhecimentos e competências pretendidas e se ainda ajudou a obter novas ideias;
- Comportamento – aferir se os conhecimentos obtidos a partir das recomendações recebidas poderão ser aplicados na vida real;
- Resultados – aferir a melhoria e eficácia dos resultados a partir das recomendações recebidas.

Em resumo, existem várias propostas para a avaliação dos SR aplicados ao ensino, que poderão ser conjugadas e aplicadas tendo em conta os vários objetivos de cada SR. Desejavelmente deverão ser analisados os métodos a usar para avaliar cada um dos componentes, incluindo os próprios algoritmos de recomendação adotados, os aspetos pedagógicos e de interação social. Essas métricas e métodos de avaliação deverão, sempre que possível, ser integrados no desenho dos sistemas, procurando assim recolher dados de avaliação ao mesmo tempo que o sistema é explorado pelos diferentes destinatários (alunos, professores e outros).

# Capítulo 4

## O Modelo Proposto

Ao longo deste capítulo iremos descrever o problema desta investigação e a metodologia que nos conduziu até à sua resolução. O modelo e a arquitetura da solução serão descritas nas secções 4.3 a 4.5. No final do capítulo serão apresentadas algumas considerações finais sobre as nossas opções e sobre algumas das suas alternativas.

### 4.1 O Problema

Tal como referido na secção 1.2 deste documento, uma das preocupações deste trabalho é a maximização da aprendizagem num contexto formal no ES. Desta forma iniciamos com a caracterização do ambiente onde se pretende atuar.

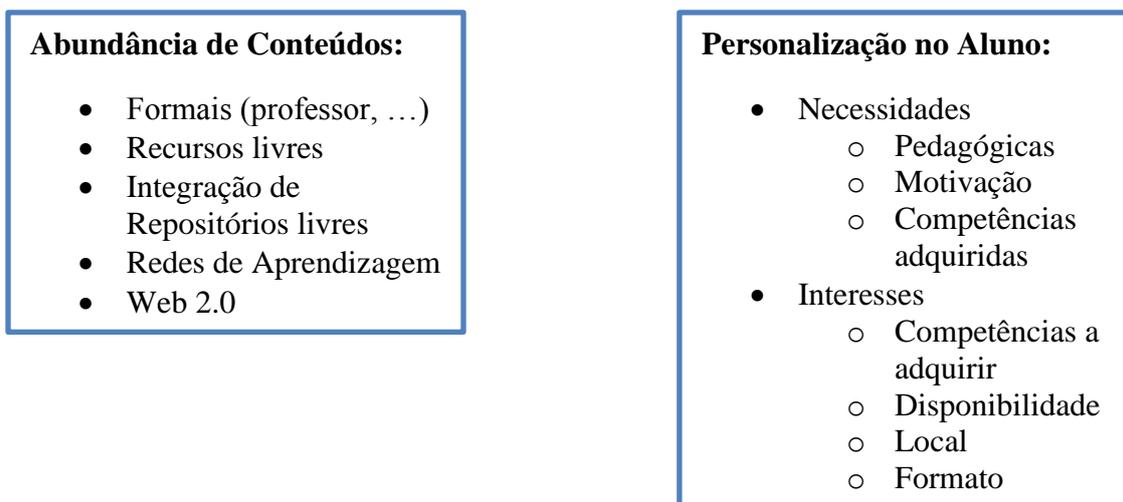
Quando consideramos o ensino, interessa distinguir o que acontece formalmente, em domínios bens estruturados (tipicamente instituições vocacionadas) com o que decorre das redes de aprendizagem informais (já referidas).

A aprendizagem informal acontece diariamente, decorre das atividades sociais ou profissionais diárias, em ambientes de trabalho, familiares ou de lazer. É, tipicamente, pouco estruturada (em termos dos objetivos de aprendizagem, local e período onde ocorrem e no seu suporte) e não é, normalmente, acreditada. Por vezes, acontece de

forma não intencional. Está normalmente mais associada à aprendizagem ao longo da vida. Esta aprendizagem é, na sua maior parte, controlada pelo próprio aluno, decorre ao seu ritmo e de acordo com as suas opções e preferências. As atividades de aprendizagem provêm de diversas fontes: comunidades de peritos, colegas de trabalhos, outros alunos ou amigos. Diferentes atividades em diferentes contextos, eventualmente a concorrer para um mesmo objetivo podem decorrer ao mesmo tempo. O uso de tecnologias propicia normalmente ambientes de *e-learning*.

A aprendizagem formal inclui as ofertas de ensino habituais das universidades e escolas. Apresenta, normalmente, uma elevada estruturação, cursos bem definidos suportados em currículos aprovados e em sistemas de acreditação que garantem a sua qualidade. A aprendizagem possui habitualmente um número relevante de horas de contacto entre professores e alunos, em ambientes de aulas teóricas, práticas, laboratoriais, entre outros. Os professores geralmente organizam a formação e distribuem os conteúdos educativos auxiliares, de suporte à aprendizagem, geralmente através de sistemas de gestão de aprendizagem. Estes sistemas permitem geralmente o acesso a esses conteúdos, através da Internet, em horários e locais do interesse de cada aluno, num ambiente de *b-learning*. Na maioria das vezes, esses conteúdos são disponibilizados somente para os alunos inscritos (no curso, módulo, unidade curricular, etc.) e durante o período letivo habitual, em que a formação presencial decorre e até concluir a sua avaliação. Estes sistemas não facilitam a reutilização nem a edição de conteúdos e são normalmente fechados quanto à publicação de conteúdos, ou seja, apenas os seus professores adicionam e gerem esses conteúdos.

Para esta caracterização, torna-se igualmente relevante observarmos as tendências sobre os processos de aprendizagem neste contexto. Duas tendências com elevado impacto são a personalização da aprendizagem em torno do aluno e a abundância de conteúdos educativos disponíveis (ver figura 18), já referidas em secções anteriores.

**Figura 18 - Factos Relevantes**

Com a personalização da aprendizagem, procuramos satisfazer os interesses e necessidades em torno de cada aluno. Mesmo num curso formal, vamos encontrar fatores como o nível de conhecimento, a abordagem pedagógica preferida, formato dos conteúdos pretendido, dispositivo e local de acesso aos conteúdos, disponibilidade, motivação e objetivos, específicos para cada aluno, em cada momento. A compatibilização do ensino formal com a sua adequação ao aluno surge como um desafio, ao qual este trabalho procura dar respostas. Em secções anteriores (1.1, 1.2) e no capítulo 2, já foram referidos alguns dos principais aspetos relacionados com a personalização da aprendizagem em torno do aluno.

A abundância de conteúdos educativos é resultante de vários fatores, potenciados pela Internet. Ao longo deste trabalho já foram referidos alguns dos mais relevantes, tais como as iniciativas que promovem a existência de recursos educativos abertos, a integração de repositórios de conteúdos de acesso igualmente livre, ou facilitado (secção 2.1.1), as interações sociais que se estabelecem nas redes de aprendizagem (secção 2.1.3) e as aplicações e serviços da *Web 2.0* onde conteúdos são criados, partilhados, transformados e retransmitidos facilmente (secção 2.1.4).

Para responder ao problema principal, acima enunciado dividimos a questão subjacente em duas questões mais específicas resultantes dos factos acima reconhecidos: por um lado existe uma abundância de recursos educativos e por outro pretende-se uma personalização do ensino em torno do aluno:

- Como transferir a “parte desejada” da abundância de recursos para a formação de cariz formal?
- Que conteúdos educativos e por que ordem deverão ser disponibilizados a cada aluno, por forma a melhor servirem os propósitos e as necessidades de cada aluno, em cada momento da sua aprendizagem?

Para a primeira questão, colocámos várias hipóteses. O nosso objetivo não será trazer para a formação de cariz formal todos os conteúdos relacionados. Interessa-nos por isso aplicar algum tipo de filtro que apenas importe os conteúdos que possam interessar aos alunos que estão a frequentar o curso, e que ao mesmo tempo sejam concordantes com os objetivos e práticas defendidas pelos responsáveis da formação. De notar que esses conteúdos a adicionar serão providos de outras fontes ou criados pelos próprios. Essa importação poderá ser automática ou manual. Ao ser automática, pretende-se criar um mecanismo que possa adicionar conteúdos a um LMS, sem a intervenção humana. Optámos, no entanto, pela hipótese de serem os próprios alunos a adicionarem outros recursos educativos providos de outras fontes ou criados pelos próprios. Pretende-se igualmente que esses conteúdos possam permanecer no sistema para as edições seguintes de cada formação. Idealmente, os conteúdos deverão igualmente ser reciclados, por exemplo, quando outros conteúdos que sejam adicionados os possam substituir. Adicionalmente poderão existir outros fatores que influenciem o descarte dos conteúdos. É de realçar que, na maioria dos LMS usados habitualmente nas instituições de ensino, a possibilidade de alteração, melhoria ou inclusão de conteúdos por outras pessoas diferentes dos professores (que coordenam a ação formativa), não existe.

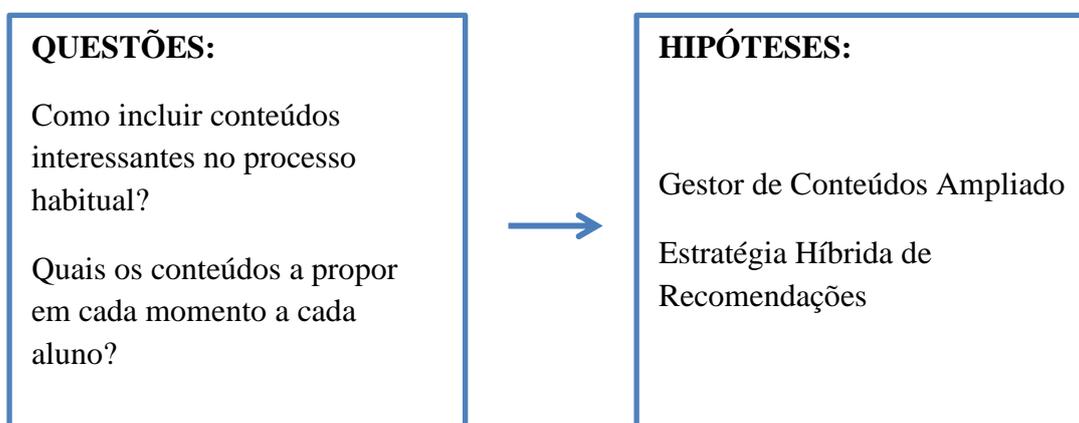
Em suma, para a resposta à primeira questão colocámos como hipótese o modelo de gestão de conteúdos ampliado, que será apresentado na secção 4.3.

Para a segunda questão, existem vários trabalhos de investigação, já referenciados (secções 2.2 e 3.3), que procuram oferecer aos alunos uma aprendizagem personalizada. As hipóteses que colocámos vão no sentido da adoção de sistemas adaptativos, em particular de sistemas de recomendação. Geralmente, os sistemas adaptativos aplicados ao ensino baseiam-se sobretudo nas competências pretendidas, nos perfis e necessidades

dos alunos e na definição de regras e/ ou algoritmos que conduzem/ geram a adaptabilidade. Um caso particular da adaptabilidade dos sistemas diz respeito apenas ao sequenciamento das atividades de aprendizagem (secção 2.2.1).

A nossa proposta para responder à segunda questão recaiu na adoção de um modelo de recomendações híbrido, baseado no perfil dos alunos, nos conteúdos e nas interações entre ambos, que será apresentado na secção 4.4.

A formulação do problema e correspondentes hipóteses de solução são apresentadas no esquema da figura 19.



**Figura 19 - Do Problema às Hipóteses**

De realçar que as hipóteses avançadas não pretendem constituir respostas únicas às questões desta investigação. O nosso interesse é o de testar as hipóteses propostas e verificar de que forma poderão ser consideradas parte de soluções que se perspetivam mais abrangentes. Em concreto, a adição de novos conteúdos manualmente pelos alunos não se apresenta como solução única para a primeira questão colocada. Interessa-nos verificar ou refutar esta hipótese, como sendo ou não uma das possíveis. Também com a estratégia híbrida de recomendações proposta não se pretende aferir se será a única solução para a questão de como propor conteúdos de aprendizagem de forma personalizada ao aluno. Interessa-nos verificar se a hipótese e o modelo considerados poderão dar um contributo positivo no sentido de que tal aconteça.

## 4.2 Metodologia

Nesta secção é apresentada a metodologia seguida tendo em vista a criação de uma solução (que se tornou a finalidade deste trabalho), posteriormente analisada conjuntamente com os principais contributos que daí resultarem.

A metodologia seguida neste projeto de investigação teve duas fases essenciais, designadamente a que decorreu até à formulação da tese proposta para solução e a que se lhe seguiu.

Na fase inicial do projeto, adotou-se uma estrutura convencional de um projeto de investigação, tendo os trabalhos decorrido da seguinte forma:

- **Identificação do problema:** Nesta etapa foi identificado um problema e a pertinência do seu estudo, tendo sido especificados o objetivo geral e os objetivos específicos da investigação, as questões-chave associadas, assim como as justificações que nos conduziram a essas questões; o seu resultado encontra-se descrito nas secções 1.1, 1.2 e 4.1 deste documento;
- **Revisão de fundamentos e dos estudos anteriores relacionados:** Nesta etapa foram identificados e analisados os trabalhos relacionados relevantes para as questões chave formuladas, assim como foram estudados os conceitos que resultaram da leitura e análise desses estudos; o seu resultado encontra-se sumariado nos capítulos 2 e 3 deste documento;
- **Geração das hipóteses de solução:** Nesta etapa, após análise das alternativas propostas noutros trabalhos, foram formuladas as hipóteses que procurarão dar resposta às questões identificadas; essas hipóteses encontram-se descritas nas secções 1.2 e 4.1 deste documento;
- **Desenvolvimento do Modelo de solução:** Nesta etapa, de modelação das hipóteses consideradas para resolução das questões-chave, foram desenvolvidos dois modelos que pretendem representar os subsistemas que implementarão as

respostas pretendidas; estes modelos incluem os objetos relevantes e foram agregados numa arquitetura (ou modelo global) que ilustra os relacionamentos entre os diversos componentes; os modelos encontram-se representados nas secções 4.3 e 4.4 e a arquitetura global da solução surge na secção 4.5 deste documento.

Na fase seguinte do projeto, a preocupação central residiu no desenvolvimento de um protótipo que possibilitasse uma avaliação experimental do modelo proposto. Não se considerou, devido ao tempo que seria necessário, o desenvolvimento de um sistema completo. Por forma a integrar o modelo pretendido num ambiente conhecido dos alunos e a dispor mais rapidamente de um ambiente de testes e validação optou-se pela sua integração no sistema de gestão de aprendizagem em uso, na instituição de ensino escolhida para se efetuar esses testes. A escolha recaiu no sistema *Moodle*. Esta opção, como mais tarde veremos, embora tenha permitido um mais rápido desenvolvimento de um protótipo integrado, não se mostrou favorável, em termos de usabilidade, pelos alunos.

Como metodologia de realização desta fase, foi adotada a estrutura característica da investigação pela engenharia (Oliveira, 2008), sobre Sistemas de Informação, por isso mesmo mais orientada ao problema. Desenrolou-se em diversas etapas, ajustadas aos objetivos e às finalidades do projeto, sumariadas da seguinte forma:

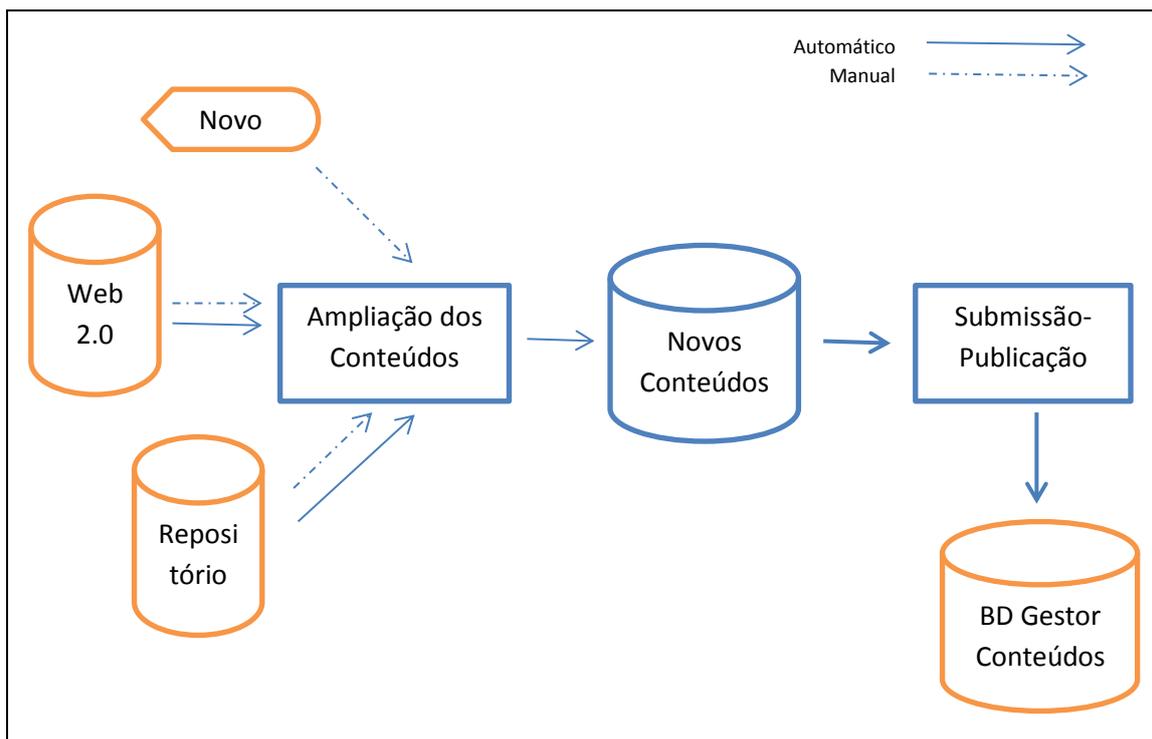
- **Conceptualização:** Na verdade esta etapa incluiu o desenvolvimento do modelo e tendo por base esse mesmo modelo incluíram-se as condições a verificar para atingir os objetivos do sistema, ou seja, os seus requisitos; para tal, foram efetuadas adicionalmente as seguintes atividades:
  - Identificação do ambiente de desenvolvimento da plataforma *Moodle*;
  - Identificação do modelo de dados da plataforma *Moodle*;
  - Identificação do modelo de dados, associado ao modelo proposto; tendo em vista a avaliação, foram identificados os dados a existir para que pudesse ser feita a avaliação do sistema, baseada nas métricas identificadas como sendo habituais nos SR (secção 3.4) e nas outras dimensões que decidimos usar (secção 5.3);

- Identificação do modelo funcional, associado ao modelo proposto;
- Prototipagem: Nesta etapa, estão incluídos os trabalhos que culminaram no desenvolvimento do protótipo:
  - Desenho das estruturas de dados, códigos a usar e relacionamentos entre estruturas de dados existentes e as adicionadas, sobre o *Moodle*;
  - Desenho das funcionalidades, designadamente da interface e sua integração com a plataforma *Moodle*;
  - Codificação do sistema;
- Testes unitários (aos módulos desenvolvidos) e de integração (interação com o sistema normal); de realçar que a não realização de testes de aceitação por parte dos utilizadores (alunos), veio a demonstrar-se uma limitação deste trabalho;
- Demonstração: Antes de submeter o protótipo aos alunos, para sua exploração, foram carregados conteúdos, dados de utilizadores e foi demonstrado aos alunos a utilização do sistema, incluindo as funcionalidades de definição de perfil do aluno e importação de novos conteúdos por alunos;
- Aplicação do novo sistema: Foi efetuada formação e suporte aos alunos (quer em aula como por email) na utilização do sistema durante 2 meses;
- Avaliação: Foram exportados os dados gerados durante a utilização do sistema pelos alunos e posteriormente tratados (secção 5.3) e analisados (secção 5.4); para o tratamento de dados usou-se uma aplicação de folha de cálculo;
- Questionário: No final da utilização do sistema foi submetido um inquérito anónimo com questões sobre alguns aspetos relacionados com a usabilidade e utilidade do sistema, tendo em vista a obtenção de informação sobre algumas dimensões da avaliação, não quantitativas, consideradas pertinentes para o estudo e resultantes duma análise baseada nas secções 3.4.2 e 3.4.3; para o tratamento de dados usou-se uma aplicação de folha de cálculo;

- Tratamento, análise e interpretação dos resultados: Para além dos aspetos referidos nos dois pontos anteriores, interessa destacar a preocupação que houve em estabelecer relações entre os dados e as explicações obtidas por ambas as técnicas (métricas e questionários), conforme apresentado nas secções 5.4 e 6.1;
- Comunicação: De realçar que antes da fase de prototipagem foi publicado um artigo com o modelo proposto (Madeira et al., 2012a); após a implementação do protótipo mas ainda sem dados de validação foi publicado o artigo (Madeira, Quaresma, & Abreu, 2012b); foi ainda submetido outro artigo com a avaliação experimental do protótipo, estando o mesmo na fase de revisão por parte duma revista;
- Conclusão deste trabalho: Elaboração do presente documento.

### 4.3 Gestor de Conteúdos Ampliado

O modelo de ampliação de conteúdos prevê a adição de conteúdos, ou de referências para eles, quer manualmente pelo utilizador (aluno, professor, ou qualquer outro utilizador autorizado), como automaticamente por algum sistema que reconheça conteúdos existentes na Internet, em serviços da *Web 2.0* (artigos de blogues, por exemplo) ou em repositórios de conteúdos (essencialmente de acesso livre e preferencialmente através de API disponibilizadas para processos de integração) e que sejam potencialmente relevantes para a área em estudo. Neste modelo, por conteúdo, consideramos um conceito amplo que sendo mais próximo da atividade de aprendizagem, pode igualmente representar um documento, um endereço para um recurso alojado na *Web*, um questionário, uma ficha de exercícios, etc. Este modelo surge ilustrado na figura 20.



**Figura 20 - Modelo de Ampliação dos Conteúdos**

Tratando-se de um modelo a aplicar num sistema formal de ensino, deverá existir algum tipo de controlo anterior à publicação e ao acesso por todos os alunos, ou seja, cada novo conteúdo deverá ser aprovado ou rejeitado previamente. Só após aprovação, os novos conteúdos ficam disponíveis para publicação e posterior acesso.

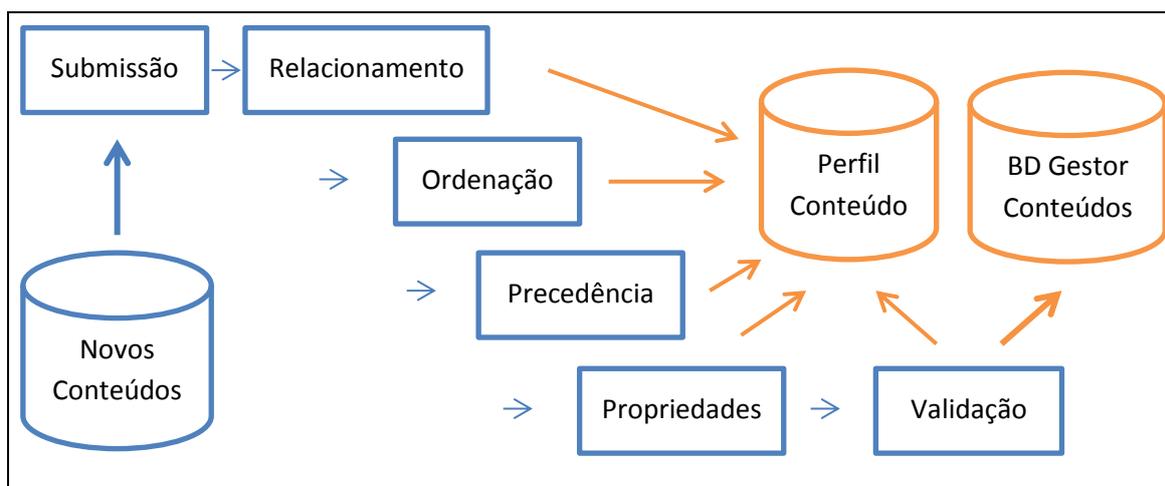
Numa situação normal o responsável pela formação planeia, cria e publica alguns conteúdos recorrendo a um LMS. Neste contexto, propomos que os conteúdos adicionados devam ser relacionados com os existentes por forma a criar grupos de conteúdos relacionados entre si, correspondendo a um ou mais tópicos agrupados de forma coerente. O relacionamento entre conteúdos permitirá assinalar conteúdos melhorados, complementares ou opcionais o que facilita igualmente a seleção dentro do mesmo grupo de conteúdos. O aluno poderá optar por estudar um ou mais conteúdos de cada grupo. A definição dos grupos de conteúdos é da responsabilidade do gestor do curso, que deverá assegurar a coerência dos conteúdos agrupados.

Propomos a inclusão de duas características sobre os conteúdos: estimativa do tempo de estudo necessário e qualidade do conteúdo (representativo de um nível de satisfação

esperado para o aluno que usar esse conteúdo). Estas características foram propostas, por serem necessárias ao modelo híbrido de recomendações.

Duas outras funcionalidades foram consideradas na ampliação do gestor de conteúdos: ordenação e definição de pré-requisitos. A indicação de uma ordem entre os grupos de conteúdos permitirá estabelecer pré-requisitos ou precedências formais (para outros grupos de conteúdos).

O processo que se inicia com a submissão de um novo conteúdo até à sua publicação vem ilustrado na figura 21 (Madeira et al., 2012a). Todas as funcionalidades deverão estar acessíveis aos professores. Os alunos poderão submeter novos conteúdos e propor o seu relacionamento com os conteúdos disponíveis. De destacar que os conteúdos habituais que um professor publica deverão seguir as mesmas etapas dos conteúdos publicados por outros intervenientes.



**Figura 21 - Fases da Publicação de Conteúdos**

Em resumo, este modelo descreve a forma de adicionar conteúdos, por parte de professores e alunos, automaticamente a partir de fontes externas ou com a importação explícita para o LMS. Uma vez que se pretende ter algum tipo de controlo sobre os conteúdos propostos, para além da validação deverão ser indicados alguns atributos que complementam os meta-dados sobre os mesmos, designadamente o relacionamento de cada conteúdo com algum outro já existente, a sua ordem, grupo de conteúdos pré-requisito, tempo estimado de estudo e nível de qualidade do conteúdo.

A designação de gestor de conteúdos ampliado deriva não só do alargamento da base de conteúdos disponíveis, como da expansão da informação existente no perfil de cada conteúdo.

## 4.4 Personalização de Recomendações

Para a resposta à segunda questão do problema, “Quais os conteúdos a propor em cada momento a cada aluno?”, foram analisadas várias hipóteses alternativas.

Considerando o modelo de gestor de conteúdos ampliado proposto para responder à primeira questão, dispomos de um conjunto, eventualmente alargado, de conteúdos agrupados por tópico de aprendizagem, eventualmente com precedências entre si.

Consideramos igualmente que no contexto de ensino formal, os alunos ao se inscreverem num dado curso mostram interesses comuns e aceitam os objetivos e as competências que se encontram implicitamente estabelecidas. Da mesma forma, assumimos que as competências que cada aluno já adquiriu serão consideradas nos requisitos que existirão no acesso a esse curso (condições de acesso ao ensino superior, eventuais frequências de outras unidades curriculares, módulos, etc.), ou seja, os eventuais pré-requisitos que possam existir no acesso a um dado curso serão analisados na inscrição do curso, o que permite assumir que quando um aluno é aceite num dado curso é porque reúne as competências necessárias para o mesmo. Já os níveis de certas competências poderão variar o que, só por si, justifica que os alunos necessitem de trabalhar de forma diferente para atingir os mesmos objetivos finais. Desta forma, a nossa abordagem foi considerar o problema das competências (existentes e a atingir) como resolvido implicitamente devido às características do ensino formal.

Uma primeira hipótese colocada para resolver a questão referida incluía a adoção de sistemas adaptativos capazes de propor conteúdos de forma personalizada. Tal como foi referido no ponto 2.2 os sistemas adaptativos “baseiam-se sobretudo nas competências pretendidas, nos perfis e necessidades dos alunos e na definição de regras e/ ou algoritmos que conduzem/ geram a adaptabilidade”. Ao considerarmos não tratar o

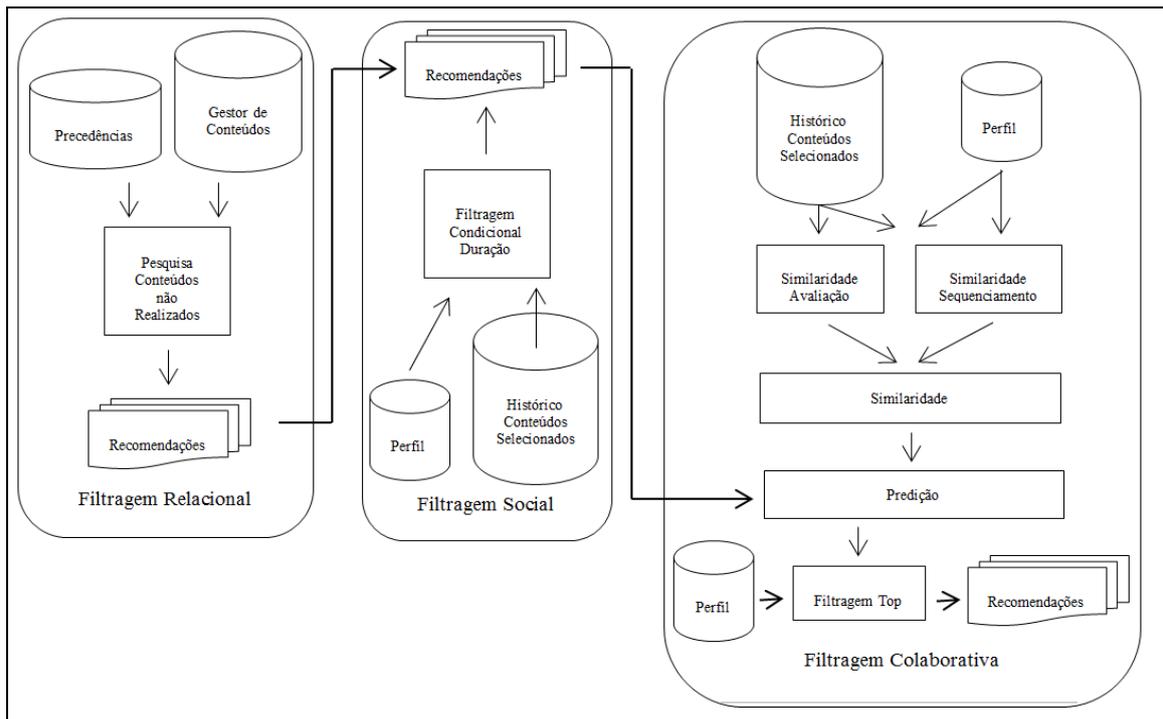
problema das competências, a definição de regras baseadas nessas competências também não é exequível, pelo que descartamos a adoção de um modelo similar ao ilustrado na figura 5.

Um dos argumentos importantes para a nossa proposta de solução é acreditarmos na ideia de que alunos com os mesmos objetivos e com tempos de estudo formais similares podem beneficiar das avaliações aos conteúdos de anteriores alunos. Ora essa é a ideia principal das técnicas de recomendação por filtragem colaborativa. A adaptabilidade proposta não terá que se basear em modelos de competências e em regras, mas sim nos caminhos de aprendizagem de outros alunos.

A nossa hipótese, que pretendemos verificar, assenta assim num subsistema de apoio ao aluno que tem como propósito recomendar-lhe em cada etapa da sua aprendizagem uma lista ordenada dos conteúdos (ainda não efetuados), por ordem decrescente de relevância. Ao pretendermos ter uma resposta personalizada para cada aluno, entendemos que a mesma se deve basear na existência de um perfil de aluno.

#### **4.4.1 Processo de Recomendação**

Para obter a lista de conteúdos a propor, considerámos uma estratégia de recomendações híbrida, em cascata, onde cada técnica de recomendação vai refinando as recomendações da anterior (ver figura 22).”



Fonte: (Madeira, Quaresma, & Abreu, 2012a)

**Figura 22 - Estratégia Híbrida de Recomendações**

Em linhas gerais, pretendemos um sistema de recomendações de conteúdos a alunos que observe as seguintes características:

- Só presente conteúdos com uma duração de estudo adequada a cada aluno (definida por ele no seu perfil);
- Só presente conteúdos com uma avaliação (nível de satisfação) adequada a cada aluno (só conteúdos com valores acima do definido no seu perfil);
- No cálculo da estimativa de avaliação valorize as avaliações registadas pelos alunos que possuam uma média adequada aos interesses do aluno (valor indicado no perfil do aluno) e pelos alunos que efetuaram um caminho de aprendizagem similar ao do passado recente do utilizador ativo.

Para além dos parâmetros do perfil a que nos referiremos na próxima secção, solicita-se ao aluno que no final do estudo de cada conteúdo, explicitamente avalie o conteúdo (registre o nível de satisfação obtido) e indique o tempo que usou para o explorar.

De realçar que a nossa proposta não propõe a adoção de um sistema de recomendações híbrido tradicional, onde as técnicas principais de recomendação surgem numa "arrumação própria". A proposta usa algumas técnicas de filtragem que incluem o descarte de conteúdos baseado na verificação de certas condições e usa igualmente técnicas que são "inspiradas" nas técnicas tradicionais de filtragem colaborativa. Em concreto, as avaliações dos alunos sobre conteúdos juntamente com a similaridade entre alunos são consideradas, para efeitos de cálculo da estimativa de avaliação dos conteúdos a propor. Propomos uma formulação específica para a similaridade entre alunos, mas partilhamos a formulação habitual usada no cálculo da estimativa de classificação das técnicas de filtragem colaborativa.

A lista final é ordenada pelas estimativas de classificação dos conteúdos, que ainda não foram abordados pelo aluno ativo. Pode ser formulada da seguinte forma:

$$u_{ac} : A \times C \rightarrow R \quad (1)$$

Em que:

- $A$  é o conjunto de alunos inscritos no curso;
- $C$  é o conjunto de conteúdos que podem ser recomendados;
- $R$  é um conjunto ordenado de recomendações;
- $u_{ac}$  é a função utilidade que prediz a classificação do conteúdo  $c$  para o aluno  $a$ .

Na fase 1, designada por filtragem relacional, a técnica aplicada pretende obter, para o aluno ativo, a lista de conteúdos não realizados e sem pré-requisitos por satisfazer, ou seja, serão descartados todos os conteúdos que tenham pré-requisitos (outros conteúdos) que ainda não foram selecionados.

Na fase 2, propomos uma segunda filtragem, a aplicar sobre a lista de conteúdos resultante da primeira fase. Esta filtragem incidirá sobre os parâmetros do perfil do aluno ativo e sobre a atividade dos outros alunos (daí a designação de filtragem social) sobre os conteúdos resultantes da fase 1. Caso o aluno tenha definido no seu perfil um valor para a duração máxima de tempo de estudo pretendida para cada conteúdo, a lista obtida da fase 1 é revista tendo em consideração a duração média do tempo de estudo

indicado pelos outros alunos e o valor atribuído por defeito por quem submeteu o conteúdo (professor ou aluno). Caso um dado conteúdo não tenha ainda sido selecionado ('cold-start'), este valor será o considerado (na duração média de estudo do conteúdo), permitindo assim, que esse mesmo conteúdo não seja descartado. No caso de não ter sido definida no perfil do conteúdo uma duração estimada pelo professor ou aluno, nem o respetivo conteúdo tenha sido selecionado, a média obtida será nula. Neste caso, a nossa opção foi manter a inclusão do conteúdo na lista, com duração zero. Tirando estes casos, a lista resultante incluirá apenas os conteúdos com uma duração média inferior ou igual à duração definida no perfil do aluno. A duração média de um dado conteúdo  $c$  ( $\overline{d}_c$ ), é obtida pela seguinte formulação:

$$\overline{d}_c = \frac{\sum_{a \in A} d_{a,c}}{|A|} \quad (2)$$

Em que:

- $A$  é o resultado da união do conjunto de alunos que já atribuíram duração ao conteúdo  $c$  com o elemento que publicou o mesmo;
- $d_{a,c}$  é a duração atribuída pelo aluno  $a$  ao conteúdo  $c$  ou pelo responsável pela sua publicação.

A etapa seguinte (fase 3) inicia-se com o cálculo do valor de similaridade entre o aluno ativo e todos os outros (definido entre um mínimo de 0 e um máximo de 1). O modelo propõe uma avaliação da similaridade entre utilizadores baseado em múltiplos critérios.

O primeiro critério, “similaridade-avaliação” considera a avaliação definida no perfil do aluno ativo. Essa avaliação que cada aluno indica no seu perfil pretende valorizar os alunos que possuam uma avaliação média ao curso superior ou igual a esse valor. Idealmente este valor deverá ser obtido por integração com o sistema de informação académico da instituição. Quando o aluno não tiver definido esse parâmetro, esta métrica não será calculada. Para os alunos com uma avaliação média igual ou superior ao parâmetro correspondente indicado no perfil do aluno ativo é-lhes atribuído o máximo valor de similaridade. Abaixo da avaliação definida, a métrica considera a seguinte formulação:

$$\text{sim}^g_{a_i, a_j} = \begin{cases} 1 - \frac{(G_i - g_j)}{G_i} & g_j < G_i \\ 1 & g_j \geq G_i \end{cases} \quad (3)$$

Em que:

- $\text{sim}^g_{a_i, a_j}$  é a métrica que avalia a similaridade-avaliação entre os alunos  $a_i$  e  $a_j$ ;
- $G_i$  é a avaliação definida no perfil do aluno  $a_i$ ;
- $g_j$  é a avaliação que o aluno  $a_j$  obteve.

A segunda métrica, similaridade-sequenciamento”, considera o valor do tamanho da sequência definido no perfil do aluno ativo. O tamanho da sequência definido no perfil de cada aluno determina, relativamente ao último conteúdo estudado, quantos e quais os anteriores conteúdos que serão considerados na avaliação da métrica. Consideramos que a seleção dos mesmos conteúdos e pela mesma ordem, no passado, confere uma maior proximidade entre os alunos. Assim, um outro aluno que tenha selecionado exatamente os mesmos  $n$  conteúdos e exatamente pela mesma ordem, em qualquer posicionamento na sua sequência global de aprendizagem, terá uma similaridade máxima com o aluno ativo. Para um novo aluno, sem conteúdos selecionados, ou que não defina qualquer valor para o parâmetro do tamanho da sequência, no seu perfil, esta métrica não é calculada. A formulação completa desta métrica é a seguinte:

$$\text{sim}^s_{a_i, a_j} = \frac{\sum_{k=1}^n \exists c_{k,j} + \sum_{k=1}^{n-1} \Delta c_{k,j}}{(2 * n) - 1} \quad (4)$$

Em que:

- $\text{sim}^s_{a_i, a_j}$  é a métrica que avalia a similaridade-sequencia entre os alunos  $a_i$  e  $a_j$ ;
- $\Delta(c_{k,j}) = \begin{cases} 1 & \text{pos}_j(c_{k+1,i}) - \text{pos}_j(c_{k,i}) = 1 \\ 0 & \text{noutros casos} \end{cases}$ ;
- $\exists c_{k,j} = \begin{cases} 1 & \text{se } c_k \text{ tiver sido selecionado por } a_j \\ 0 & \text{noutros casos} \end{cases}$ ;
- $\Delta(c_{k,j})$  é a diferença, entre as posições de ordem da sequência dos vários pares de conteúdos que o aluno  $a_i$  realizou, para o aluno  $a_j$ ;
- $\exists c_{k,j}$  representa a seleção do conteúdo  $c_k$  pelo aluno  $a_j$ ;

- $n$  é o tamanho da sequência definida no perfil do aluno  $a_i$ , ou o número de conteúdos já observados por esse aluno quando este número for inferior a  $n$ .

A similaridade total entre dois alunos é obtida pela média aritmética de ambas as métricas, ou pelo valor de uma só métrica caso alguma seja nula.

Por fim, para concluir a fase de filtragem colaborativa, pretende-se, para os conteúdos da lista resultante da fase 2, determinar a predição do seu nível de satisfação (avaliação) para o aluno ativo,  $a_i$ . Para a obter, usamos a função habitual das técnicas ‘*memory-based*’ (Breese et al., 1998), numa formulação que prevê ainda o cálculo nas situações de ‘*cold-start*’:

$$p_{a_i, c_k} = \begin{cases} \overline{sl_{a_i}} + \frac{\sum_{j \in J} (sl_{a_j, c_k} - \overline{sl_{a_j}}) * sim_{a_i, a_j}}{\sum_{j \in J} sim_{a_i, a_j}} & \text{se } \overline{sl_{a_i}} \neq 0 \\ \frac{\sum_{j \in J} (sl_{a_j, c_k} * sim_{a_i, a_j})}{\sum_{j \in J} sim_{a_i, a_j}} & \text{se } \overline{sl_{a_i}} = 0 \\ sl_{perfil, c_k} & \text{se as 2 primeiras formulações} = 0 \\ 0 & \text{se } sl_{perfil, c_k} = 0 \text{ e se as 2 primeiras formulações} = 0 \end{cases} \quad (5)$$

Em que:

- $p_{a_i, c_k}$  é a predição do nível de satisfação para o aluno ativo,  $a_i$ , do conteúdo  $c_k$ ;
- $sim_{a_i, a_j}$  é a métrica que avalia a similaridade total entre os alunos  $a_i$  e  $a_j$ ;
- $sl_{a_j, c_k}$  é o nível de satisfação registado pelo aluno  $a_j$  para o conteúdo  $c_k$ ;
- $\overline{sl_{a_i}}$  é a média dos níveis de satisfação registados sobre os conteúdos pelo aluno  $a_i$ ;
- $\overline{sl_{a_j}}$  é a média dos níveis de satisfação do aluno  $a_j$ ;
- $sl_{perfil, c_k}$  é o nível de satisfação existente no *perfil* do conteúdo  $c_k$ , atribuído por defeito.

Na formulação (5) estão previstas soluções para várias situações de ‘cold-start’. Apresentamos uma formulação alternativa para quando o aluno ativo ainda não efetuou nenhuma avaliação (logo a média das suas avaliações será 0). Se porventura o cálculo das duas primeiras formulações tiver um resultado nulo (devido a algumas das seguintes razões, consideradas isoladamente ou em simultâneo: itens novos ainda não avaliados, ausência de parâmetros no perfil do utilizador ativo que impedem o cálculo das similaridades, ausência de seleção de conteúdos por parte dos outros utilizadores, média da classificação dos outros alunos desconhecida), consideramos para estimativa do nível de satisfação do conteúdo, o valor definido no perfil do conteúdo. Caso este valor não exista, o conteúdo será proposto sem estimativa de avaliação (ou seja, no final da lista), independentemente do nível de satisfação mínimo pretendido, registado no perfil do aluno ativo.

A lista final de recomendações de conteúdos é ordenada pelos valores de predição obtidos, de forma decrescente e filtrada com base no nível de satisfação mínimo pretendido, ou seja, apenas os conteúdos com um valor igual ou superior ao indicado no perfil do aluno ativo serão apresentados. Caso este parâmetro não esteja definido serão apresentados todos os conteúdos resultantes.

De realçar que a seleção do aluno poderá incidir sobre um ou mais conteúdos dessa lista, não sendo vinculativo, sequer, que o aluno tenha que selecionar o conteúdo com maior avaliação.

#### **4.4.2 Perfis**

A informação considerada para efeitos de personalização usa diversos atributos que surgem refletidos nos perfis dos alunos e dos próprios conteúdos.

Cada aluno tem a possibilidade de registar os seguintes quatro parâmetros, para além dos que podem ser solicitados pelo LMS:

- Duração – parâmetro opcional que pretende indicar qual a duração máxima de estudo desejado para cada conteúdo que o sistema deverá propor; este parâmetro é essencial para a fase 2 da estratégia de recomendação; caso não esteja definido, a lista resultante da fase 2 será igual à final da fase 1;
- Nível de Satisfação – parâmetro opcional que indica ao sistema qual o nível mínimo de satisfação estimado que o utilizador pretende que os conteúdos recomendados tenham; caso não esteja definido, a lista de conteúdos resultante da fase 3 será igual à final da fase 2, com a diferença que a lista da fase 2 é não ordenada e a lista da fase 3 é ordenada pelo valor estimado da avaliação, de forma decrescente;
- Tamanho da sequência - parâmetro opcional que permite o cálculo da similaridade-sequenciamento e representa o número de conteúdos (e implicitamente quais os conteúdos) que deverão ser comparados no histórico mais recente do utilizador ativo com os dos outros utilizadores; caso não esteja definido, não será calculada esta métrica de similaridade;
- Avaliação – parâmetro opcional que indica a média mínima que corresponde a uma similaridade-avaliação máxima; o aluno pretende ser mais similar com os alunos com uma média igual ou superior ao valor indicado; caso não esteja definido, não será calculada esta métrica de similaridade.

Sobre cada conteúdo, propomos os seguintes dois parâmetros, para além dos que podem ser solicitados pelo LMS:

- Duração – parâmetro opcional que pretende indicar qual a duração de estudo estimada para o conteúdo; a sua definição permitirá obter resultados na segunda filtragem mesmo que o conteúdo não tenha sido ainda selecionado;
- Nível de Satisfação – parâmetro opcional que pretende indicar qual a nível de satisfação expectável para o conteúdo; a sua definição permitirá propor uma estimativa de avaliação (igual a esse valor) quando o conteúdo não tiver sido

avaliado ou quando o valor de similaridade entre o utilizador ativo e todos os outros que avaliaram esse mesmo conteúdo for nulo.

### 4.4.3 Exemplo de Execução

Como exemplo de aplicação do modelo de recomendações acima apresentado, consideremos os dados da seguinte tabela:

**Tabela 5 - Lista dos Conteúdos selecionados - Perfis de alunos**

Aluno (perfil)	Conteúdos						Sequência	Avaliação
	c <sub>1</sub> (d=50, sl=3)	c <sub>2</sub> (d=30, sl=4)	c <sub>3</sub> (d=60, sl=4)	c <sub>4</sub> (d=40, sl=4)	c <sub>5</sub> (d=50, sl=4)	c <sub>6</sub> (d=50, sl=5)		
a <sub>1</sub> (d=55, sl=4, g=17, n=3)	d=50, sl=4	d=20, sl=5		d=40, sl=3			c <sub>1</sub> , c <sub>2</sub> , c <sub>4</sub>	14
a <sub>2</sub> (d=50, sl=4, g=14, n=2)	d=40, sl=3	d=40, sl=3		d=40, sl=3	d=60, sl=3		c <sub>5</sub> , c <sub>1</sub> , c <sub>2</sub> , c <sub>4</sub>	13
a <sub>3</sub> (d=30, sl=4, g=15)	d=60, sl=3			d=40, sl=3	d=60, sl=5		c <sub>4</sub> , c <sub>1</sub> , c <sub>5</sub>	15
a <sub>4</sub> (d=40, sl=4, g=14)		d=60, sl=3		d=40, sl=3	d=40, sl=5	d=45, sl=4	c <sub>5</sub> , c <sub>6</sub> , c <sub>2</sub> , c <sub>4</sub>	

d = duração; sl = nível de satisfação, g = avaliação, n = tamanho da sequência

A aplicação da estratégia de recomendação para o aluno  $a_1$ , resulta para a fase 1 uma lista formada pelos conteúdos ainda não efetuados  $\{c_3, c_5, c_6\}$ .

Para o exemplo da tabela 5 e considerando o conteúdo  $c_5$ , com duração estimada de 50 minutos atribuída pelo professor que publicou este conteúdo, teremos uma duração média de 52,5 (formulação 2), pelo que este conteúdo seria mantido na lista de conteúdos a recomendar para o aluno  $a_1$  (cujo perfil indica o valor 55 para a duração). Já o conteúdo  $c_3$ , como ainda não foi selecionado tem uma duração média igual ao valor estimado, de 60, que é superior à duração indicada no perfil, de 55, logo é retirado da lista. A lista resultante desta fase 2 seria composta pelos conteúdos  $\{c_5, c_6\}$ .

Para o cálculo da similaridade avaliação (formulação 3) temos o seguinte:  $sim^g_{a_1, a_2} = 0,76 = [1-(17-13)/17]$ ; em sentido contrário,  $sim^g_{a_2, a_1} = 1$ , pois a avaliação definida no

perfil de  $a_2$  é igual à que foi obtida pelo aluno  $a_1$  (14 valores);  $sim^g_{a_1,a_3} = 0,88$  e a  $sim^g_{a_1,a_4}$  não pode ser determinada pois não existe avaliação para o aluno  $a_4$ .

A similaridade-sequencia (formulação 4) entre os alunos  $a_1$  e  $a_2$  é de 1 pois o aluno  $a_2$  fez a mesma sequência (de tamanho 3) que  $a_1$  ( $c_1, c_2, c_4$ );  $sim^s_{a_1,a_3} = \frac{2+0}{5} = 0,4$  e  $sim^s_{a_1,a_4} = \frac{2+1}{5} = 0,6$ .

As similaridades globais entre alunos serão então:  $sim_{a_1,a_2} = 0,88$ ,  $sim_{a_1,a_3} = 0,64$  e  $sim_{a_1,a_4} = 0,6$ .

Para o cálculo da estimativa de avaliação (formulação 5) tem-se:

$$p_{a_1,c_5} = 4 + \frac{((3-3) * 0,88) + ((5-3,67) * 0,64) + ((5-3,75) * 0,6)}{(0,88 + 0,64 + 0,6)} = 4,75;$$

$$p_{a_1,c_6} = 4,08;$$

$p_{a_1,c_3} = 4$  (nível de satisfação atribuído pelo professor) – conteúdo descartado na fase 2.

A lista resultante de recomendações para o aluno  $a_1$  mostra os conteúdos  $c_5$  e  $c_6$  por esta ordem com os valores de predição para o nível de satisfação de 4,75 e 4,08, respetivamente.

## 4.5 Arquitetura da Solução

A arquitetura da solução final integra o modelo do gestor de conteúdos ampliado e o modelo personalizado de recomendações. Os conteúdos e respetivos perfis criados no primeiro modelo, assim como as informações sobre as precedências entre conteúdos são disponibilizados para o segundo. Para além dessas informações e conteúdos, o sistema de recomendações baseia-se no perfil dos alunos e nas suas informações de retorno (avaliação e tempo de estudo de cada conteúdo) para propor uma lista de conteúdos adequados a cada aluno, em cada momento da sua aprendizagem (ver figura seguinte).

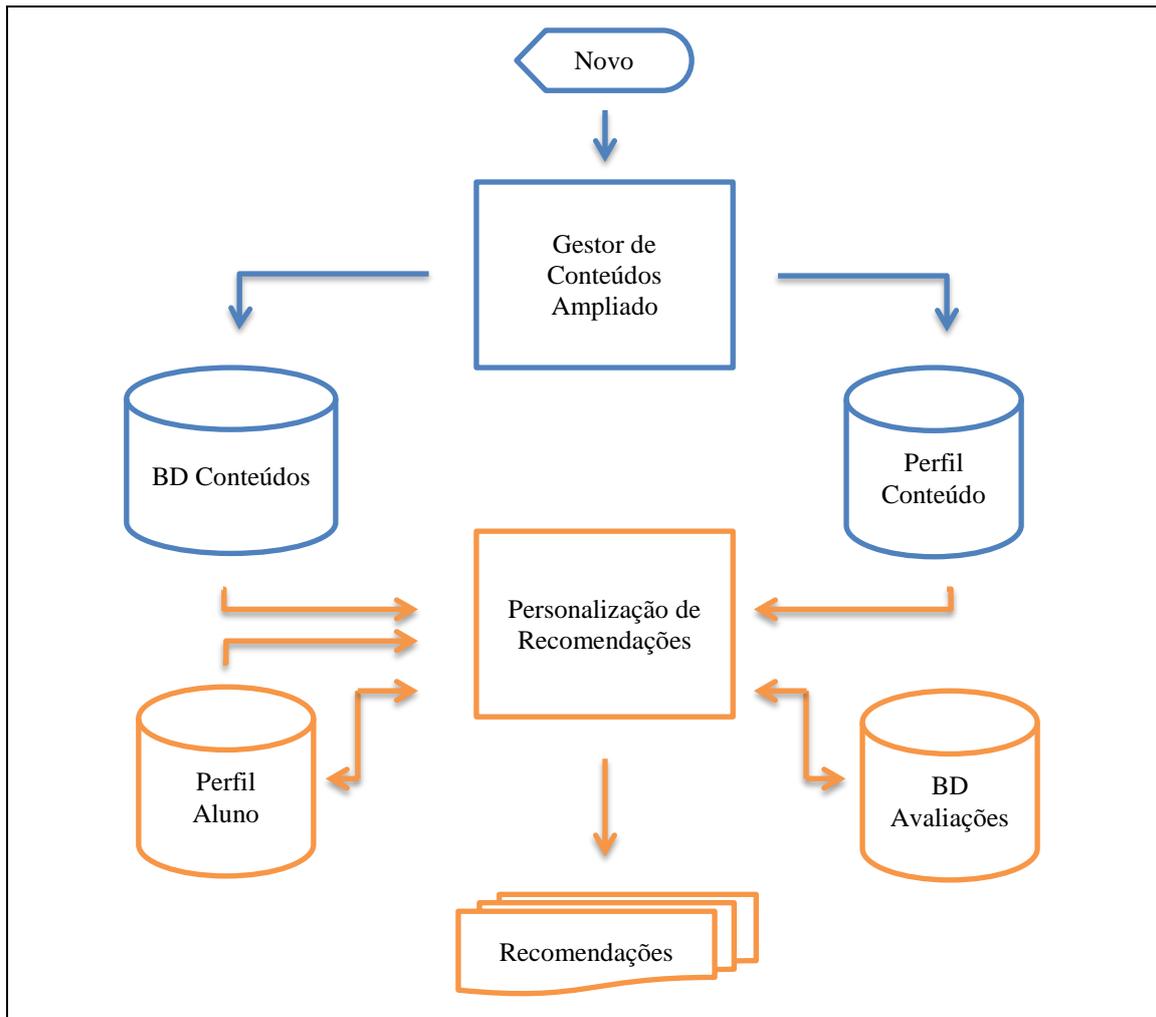


Figura 23 - Arquitetura do Modelo

Em termos de interação com o utilizador-aluno, o sistema requer que o aluno indique explicitamente os dados para o seu perfil e as suas avaliações (nível de satisfação e tempo de estudo) e permite que este adicione conteúdos novos ao sistema, conforme já referido.

## 4.6 Considerações Finais sobre o Modelo

Nesta secção iremos analisar as opções tomadas, apresentar algumas justificações, alternativas e confrontar as opções tomadas com as opções tradicionais dos sistemas de recomendação.

Relativamente ao primeiro subsistema, gestor de conteúdos ampliado, propusemos a adição manual de novos recursos. No entanto, consideramos que seria interessante que a importação pudesse ser automática a partir de fontes diversas. Alguns projetos efetuaram propostas na mesma linha de ideias. No sistema *CoFind* (Dron, Mitchell, Siviter, & Boyne, 2000), os alunos também adicionavam novos conteúdos (endereços ‘url’) ao SR. O sistema *CYCLADES* (Avancini & Straccia, 2005) usava técnicas de filtragem colaborativa sobre recursos retirados de repositórios de arquivos. A utilização de serviços *Web 2.0* no suporte ao ensino foi também já referida na secção 2.1.4. Uma hipótese que colocámos e que pretendemos estudar, na continuação deste trabalho, considera a possibilidade de usar as técnicas de recomendação baseadas em conteúdos para propor automaticamente ao gestor de conteúdos ampliado, novos conteúdos, usando a similaridade entre os conteúdos propostos pelo professor e os existentes em repositórios, nalguns endereços de serviços *Web 2.0*, ou mesmo na Internet. Como possibilidades de representação dos perfis dos conteúdos consideramos usar o próprio conteúdo, atributos sobre o mesmo ou *folksonomias*. Dependendo da proveniência dos conteúdos, da existência ou não de informação sobre cada conteúdo e do seu formato, poderão ser adotadas técnicas IR que permitam representar os perfis dos conteúdos como vetores de palavras comparando-as com os perfis dos conteúdos publicados pelos professores (através da função cosseno). O próprio relacionamento entre documentos poderá ser obtido automaticamente no caso de existir uma grande similaridade entre 2 documentos. Esta técnica permitiria trazer automaticamente para o sistema conteúdos, para que possam ser validados ou descartados pelo responsável da formação (formal).

Relativamente ao segundo subsistema, vejamos a correspondência entre os conceitos do nosso domínio de aplicação e dos SR, em geral: os itens dos SR são os conteúdos da nossa proposta, os utilizadores são alunos e as interações entre ambos, registadas na matriz de avaliações (Aluno x Conteúdo), são os níveis de satisfação do aluno sobre cada conteúdo.

Na fase 1, a filtragem relacional retira os conteúdos que já foram estudados. Este comportamento é análogo à abordagem dos sistemas de recomendação que habitualmente não propõem itens já adquiridos, vistos ou avaliados. Uma questão relativa a esta fase e que consideramos relevante é a seguinte: Será que um dado

conteúdo deverá ser proposto repetidamente, mesmo que o aluno nunca o escolha? Em termos gerais, se um dado utilizador recebe várias vezes na lista de recomendações vários itens repetidamente sem nunca os escolher, será que o SR deverá continuar a propô-los? Supondo que um utilizador já selecionou várias vezes o 2º ou 3º item de listas de recomendações, e nunca selecionou o 1º, sendo este sempre o mesmo, não deverá o sistema “aprender” algo sobre esta relação (de “não seleção”) entre o utilizador-ativo e esse item?

O descarte de conteúdos baseado nas regras de precedências é específico deste domínio de aplicação. Contudo, a aplicação de regras combinada com técnicas de recomendação já foi usada na proposta *RACOFI* (Anderson et al., 2003), incidindo sobre as avaliações dos conteúdos para determinar se certas atividades de aprendizagem deveriam ou não ser propostas. Na nossa abordagem as regras incidem sobre os meta-dados dos perfis dos conteúdos e impedem o SR de propor conteúdos com precedências ainda não realizadas. Sendo de esperar que os alunos possuam competências semelhantes, poderá haver alunos que possam ter adquirido algumas competências em ações de formação externas ao curso e que por esse motivo, possam não necessitar de estudar alguns desses conteúdos, marcados como pré-requisitos de outros. Assim, em alternativa à filtragem de conteúdos que possuam precedências não realizadas, poderá ser usado um coeficiente de redução (reduzindo a sua avaliação) por forma a colocar os conteúdos com precedências não realizadas mais abaixo na lista de recomendações. A formulação 5 poderia então ser alterada, para a seguinte forma:

$$p'_{a_i,c_k} = p_{a_i,c_k} \times \beta \quad (5a)$$

Em que:

- $0 < \beta < 1$  representa o coeficiente de redução da predição obtida da formulação 5.

Na fase 2, é usado um segundo critério, designadamente a duração de estudo de cada conteúdo. Ao contrário de outras propostas, como o sistema *DELPHOS* (Zapata,

Menendez, Prieto, & Romero, 2011), onde foram usados multicritérios na avaliação do cálculo das similaridades considerando assim diversas ponderações no cálculo da estimativa de classificação, na nossa proposta os valores da duração são usados sem qualquer ponderação, ou seja, os valores são considerados sem atribuir maior ou menor importância ao aluno que registou os dados (todas as durações têm igual peso). A duração estimada para cada conteúdo resulta da média das durações existentes e ignora os diferentes níveis de similaridade entre utilizadores (formulação 8 da filtragem colaborativa, do apêndice 4). Esta duração estimada de estudo será usada para filtragem dos conteúdos com base nos interesses do aluno (valor duração do seu perfil). Uma alternativa a esta abordagem seria considerar os dois critérios, duração e nível de satisfação, eventualmente ponderados, no cálculo da estimativa de classificação (abordagem semelhante à usada no sistema *DELPHOS*). Na prática, uma eventual diferença entre a duração média proposta e a duração do perfil do aluno não serviria para descartar conteúdos mas somente influenciaria o cálculo da estimativa da sua classificação final (maiores desvios provocariam classificações mais reduzidas).

No final, o nível de satisfação que cada aluno regista sobre cada conteúdo é usado na formulação da estimativa de classificação a propor aos outros alunos, para esse conteúdo, considerando as ponderações baseadas nas similaridades entre alunos. Este cálculo é semelhante ao habitualmente usado na filtragem colaborativa, conforme formulação 5.

A nossa proposta distingue-se no cálculo da similaridade entre alunos. Em vez de utilizarmos um coeficiente de correlação de *Pearson* ou a similaridade cosseno entre utilizadores, que se baseiam exclusivamente nas avaliações feitas, propomos uma métrica que resulta da ponderação de duas. Uma das principais razões tem a ver com o reduzido número avaliações de alunos que serão considerados num curso de ensino formal. Mesmo considerando os ex-alunos, este número será da ordem das centenas ou poucos milhares. É conhecido o problema dos dados esparsos nos SR. No domínio de aplicação desta proposta, ensino formal, o número de alunos envolvidos, nunca será semelhante aos SR comerciais. Não nos parece por isso, também ser necessário restringir os dados de cálculo, com um algoritmo *K-NN*, por exemplo.

Na primeira métrica de similaridade, é atribuída preferência aos resultados que certos alunos obtiveram (baseado na média de curso obtida até então). Permitimos, desta forma, que o aluno possa dar preferência às avaliações que os melhores alunos fizeram aos conteúdos. A similaridade tem um valor mais elevado aos alunos com notas acima de um dado valor (“dou mais importância à opinião do alunos com notas acima de um dado valor”). Esta ideia já foi proposta e testada com resultados satisfatórios (Bobadilla, Serradilla, & Hernando, 2009), com a inclusão de um coeficiente de ponderação que privilegia os melhores alunos. Esse coeficiente é aplicado ao valor de similaridade entre utilizadores (usando o cálculo habitual da similaridade entre utilizadores, baseado nas suas avaliações). Uma outra alternativa (Breese et al., 1998) sugere o uso de um fator de amplificação, que permite atribuir uma maior importância aos vizinhos mais próximos do utilizador ativo. Este fator amplifica as avaliações dos utilizadores mais similares (não altera o valor da similaridade entre alunos).

Com a segunda métrica de similaridade, pretende-se valorizar os alunos com um passado recente de escolhas de conteúdos próximo do histórico recente do aluno ativo. Não encontramos referências, no domínio dos sistemas de recomendação aplicados ao ensino, a abordagens semelhantes, em que a similaridade entre utilizadores se baseie no passado recente das atividades feitas pelo utilizador ativo. Contudo, alguns trabalhos já referidos na subsecção 2.2.1, sobre sistemas adaptativos, valorizam o sequenciamento de atividades de aprendizagem no passado, nas propostas que são feitas para as próximas atividades de aprendizagem.

A existência de perfis de conteúdos e de alunos, com alguns parâmetros preenchidos explicitamente permite a implementação de alguns aspetos representativos dos interesses dos alunos e cria soluções para as situações de arranque a frio.

Conforme já foi referido, as competências existentes e a atingir estarão mais ou menos definidas em cursos formais. O parâmetro “duração desejada de estudo” é representativo de um interesse do aluno. Na nossa abordagem, esse parâmetro funciona como filtro sobre as estimativas de duração dos conteúdos, em função das durações que os outros

alunos registaram. Uma alternativa seria considerar esta duração como um segundo critério de classificação, conforme já referido. Nesse caso, a duração definida no perfil não constituiria um filtro mas sim um valor desejável. Os desvios das durações observadas face ao interesse de cada aluno poderão ser valorizados de forma diferente em função do aluno (e neste caso a ponderação poderia resultar do cálculo de uma métrica de similaridade entre alunos no que respeita aos tempos de estudo).

O nível de satisfação pretendido indicado no perfil de cada aluno funciona igualmente como filtro, tal como já foi referido (no final, são descartados os conteúdos com um nível de satisfação abaixo do valor existente no perfil do aluno ativo). Como alternativas à indicação explícita deste valor ou mesmo à sua necessidade poderíamos considerar uma lista do tipo TOP-N (por exemplo, os 10 conteúdos mais bem classificados), uma lista com uma dada percentagem de conteúdos (por exemplo, só indicar 50% dos conteúdos, do topo da lista) ou só a lista com os conteúdos relevantes (por exemplo, apenas aqueles que possuem uma avaliação superior ou igual a 4, numa escala de 1 a 5).

Quer o tamanho da sequência de conteúdos recentemente realizados, quer a média de classificações dos alunos no curso, são parâmetros que permitem atribuir maior ou menor similaridade entre os alunos e dessa forma influenciar o peso das suas classificações, no cálculo da estimativa de classificação dos conteúdos. Sem estes dois parâmetros o sistema acaba por recomendar os conteúdos com base na classificação atribuída por defeito. Uma variante, não considerada no modelo, e que introduz uma terceira opção na formulação 5, calcula a estimativa da classificação com base na média de classificações registadas quando não existe similaridade entre utilizadores. Neste caso, somente quando não existam quaisquer avaliações registadas sobre um dado conteúdo (conteúdo novo ou nunca selecionado) é que se proporia a classificação de defeito, existente no perfil do conteúdo. A formulação 5 ficaria assim alterada, da seguinte forma:

$$p_{a_i, c_k} = \begin{cases} \overline{sl_{a_i}} + \frac{\sum_{j \in J} (sl_{a_j, c_k} - \overline{sl_{a_j}}) * sim_{a_i, a_j}}{\sum_{j \in J} sim_{a_i, a_j}} & \text{se } \overline{sl_{a_i}} \neq 0 \\ \frac{\sum_{j \in J} (sl_{a_j, c_k} * sim_{a_i, a_j})}{\sum_{j \in J} sim_{a_i, a_j}} & \text{se } \overline{sl_{a_i}} = 0 \\ \frac{1}{|J|} \sum_{j \in J} sl_{a_j, c_k} & \text{se as formulações anteriores} = 0 \\ sl_{perfil, c_k} & \text{se as formulações anteriores} = 0 \\ 0 & \text{se as formulações anteriores} = 0 \end{cases} \quad (5b)$$

Relativamente aos parâmetros dos perfis dos conteúdos, sendo todos eles opcionais, o seu objetivo será o de evitar que os conteúdos possam não ser recomendados, nas situações de ‘cold-start’.

Assim, a duração de estudo proposta por defeito permite o cálculo de um valor de estudo na fase 2, se não existirem registos de alunos com a indicação da duração.

O nível de satisfação estimado permite que um conteúdo possa ser recomendado mesmo sem ter havido quaisquer avaliações sobre ele, na fase 3.



# Capítulo 5

## Avaliação do Modelo

Neste capítulo descrevemos os trabalhos de implementação e desenvolvimento de um protótipo, sua utilização e avaliação sobre o modelo proposto no capítulo anterior (Madeira et al., 2012b). A investigação realizada incluiu a conceção, projeto e prototipagem de um sistema (secção 5.1), assente no modelo, para resolução do problema. Esse sistema foi sujeito a experimentação (secção 5.2), testes e validação (secção 5.3). No final do capítulo inclui-se uma análise crítica aos resultados obtidos.

### 5.1 Implementação do Sistema

Baseado no modelo definido no capítulo anterior, desenvolvemos um protótipo que suporta ambos os subsistemas propostos, gestor de conteúdos ampliado e estratégia híbrida de recomendações de listas de conteúdos, adequadas ao perfil de cada aluno. De realçar que as especificidades do domínio de aplicação e do próprio modelo tornam o desenho e a implementação deste SR para o ensino, únicos.

O protótipo foi implementado como um módulo do LMS *Moodle* versão 2.2.1, numa das suas plataformas, com *PHP* 5.3.8, *MySQL* 3.4.9 e servidor *Web Apache* 2.2.21.

Esse módulo surge no *Moodle* como uma atividade que o professor adiciona, permitindo ao aluno a sua seleção. O aluno efetua a autenticação usual deste LMS, e poderá selecionar essa atividade sempre que pretender aceder às novas funcionalidades do modelo proposto. As funcionalidades que foram implementadas incluem a criação, importação e alteração de conteúdos para o LMS (ver figura 23), criação e alteração dos seus perfis (ver figura 25), aceder aos conteúdos e solicitar lista de recomendações (ver figura 24).

Tal como referido no ponto 4.3, o processo inicia-se com a publicação de conteúdos, por alunos e professor. Ambos podem relacionar os conteúdos com tópicos existentes, assim como propor o tempo de estudo previsto e o nível de satisfação esperado, para cada conteúdo. O estabelecimento de precedências entre tópicos e a validação de todos os conteúdos (que permite a sua disponibilização aos alunos) é da responsabilidade do professor. Cada aluno pode solicitar a lista de recomendações e sobre esta selecionar um ou mais conteúdos. Para cada conteúdo selecionado o aluno terá que indicar o nível de satisfação obtido com a sua exploração e opcionalmente o tempo que levou a estudar o mesmo. O aluno só poderá solicitar nova lista de recomendações de conteúdos após a conclusão de todos os conteúdos previamente selecionados.

Cada aluno pode ainda editar e alterar algum dos parâmetros do seu perfil (indicados em 4.4.2), em qualquer momento.

Para implementarmos o relacionamento entre conteúdos usamos um campo que assume o valor “*Base*” para conteúdos principais publicados pelo professor. Um conteúdo que se relacione com o tipo “*Base*” poderá ter o tipo “*Upgrade*”, “*Alternative*” ou “*Supplementary*” e nesse caso indica-se qual o conteúdo “*Base*” com o qual está relacionado. Os campos “*Sequencing Order*” e “*Prerequisite Order*” estabelecem a ordem do tópico (grupo de conteúdos) e o número do tópico pré-requisito. Os campos “*Estimated study time*” e “*Satisfaction Level*” definem os correspondentes valores de defeito. Os restantes campos são específicos da implementação no *Moodle*.

Página principal ► Disciplinas ► Networking ► RC ► Tópico 10 ► Redes de Computadores - Introdução

**Navegação**

- Página principal
- A minha página inicial
- Páginas do sítio
- O meu perfil
- ▼ Disciplinas
  - ▼ Networking
    - ▼ RC
      - Participantes
      - Relatórios
      - Geral
      - ▼ Tópico 10
        - Internet Protocol
        - Redes de Computadores - Introdução**
        - Aplicações Telemáticas
        - Modelo OSI
        - OSI
        - Tecnologia Ethernet
        - Ethernet - Nível Físico
        - Ficha Questões I
        - Redes Locais PT STP
        - Network layer
        - Physical layer
        - Camada de rede

**Edit Content Redes de Computadores - Introdução**[Back](#)**Course :** Redes de Computadores**Content :** Redes de Computadores - Introdução**Content Type:** resource**Published by :** Filipe Madeira**Sequencing Order :** **Prerequisite Order (optional):** **Section :** **Estimated study time (min.) :** **Approved :** **Visible :** **Relation type :** **Related with :** **Satisfaction Level (1=Not Satisfied - 5=Totally Satisfied):** **Figura 23 - Painel Perfil do Conteúdo**

No final da publicação de um novo conteúdo, o LMS deverá ter um conteúdo concreto ou uma referência ('url') para ele na base de dados, juntamente com as já referidas propriedades que constituem as características do seu perfil. Os restantes tipos de conteúdos não foram previstos para efeitos deste protótipo.

Recommendations								
Os Conteudos BASE sao os propostos pelo Professor Deverao selecionar pelo menos UM conteudo de cada numero constante em ORDER								
Order	Prerequisite	Content	Content Type	Published by	Related with	Relation Type	Predict Satisfaction Level (>= 4 is Relevant)	Select
12	10	Routing Cisco	resource	aluno 1		Base	3.718	<input checked="" type="checkbox"/>
13	10	NAt Cisco	resource	aluno 1		Base	3.650	<input type="checkbox"/>
13	10	PT_Nat_2	resource	aluno 1	NAt Cisco	Supplementary	3.650	<input checked="" type="checkbox"/>
11		Subnetting Cisco	resource	aluno 1	TCP IP Endereçamento e Encaminhamento	Supplementary	3.574	<input checked="" type="checkbox"/>
8		Resumo Questões I	resource	teacher 1	Ficha Questões III	Supplementary	3.518	<input type="checkbox"/>
10		TCP IP - Nivel 4	resource	teacher 1	TCP/IP 1	Supplementary	3.451	<input type="checkbox"/>
12	10	PT routing serial	resource	aluno 1	Routing Cisco	Supplementary	3.442	<input type="checkbox"/>
11		TCP IP Endereçamento e Encaminhamento	resource	teacher 1		Base	3.433	<input type="checkbox"/>
11		VLSM	resource	teacher 1	TCP IP Endereçamento e Encaminhamento	Supplementary	3.400	<input type="checkbox"/>
13	10	Pt_Nat_1	resource	aluno 1	NAt Cisco	Supplementary	3.318	<input type="checkbox"/>
13	10	PT Nat 3	resource	aluno 1	NAt Cisco	Supplementary	3.315	<input type="checkbox"/>
1		IEEE	url	teacher 1	Redes de Computadores - Introdução	Supplementary	3.312	<input type="checkbox"/>

Figura 24 - Painel Lista de Recomendações

Na implementação deste protótipo consideramos que a fase 1 apenas se inicia com a verificação de que não existem conteúdos por finalizar, por parte do aluno ativo. Desta forma, os alunos terão que concluir o estudo de cada conteúdo antes de poderem solicitar nova recomendação.

### Redes de Computadores

Página principal ► As minhas disciplinas ► RC ► Geral ► Redes de Computadores - Recommender System

**Navegação**

- Página principal
- = A minha página inicial
- Páginas do site
- O meu perfil
- ▼ As minhas disciplinas
  - ▼ RC
    - Participantes
    - ▼ Geral
      - **Redes de Computadores - Recommender System**

Settings

**My Profile**

Back

Sequence Length (collaborative filtering) : <=

Minimal Average Grade (0 - 20) : >=

Maximal Average Duration (min) : <=

Minimal Average Satisfaction Level (from 1=Not Satisfied to 5=Totally Satisfied) : >=

Saved in : 24/05/12, 13:16

Figura 25 - Painel Perfil do Aluno

Após terem finalizado cada conteúdo, os alunos devem editar a recomendação e definir o tempo de estudo necessário e usado para completar esse conteúdo (campo opcional) e o nível de satisfação obtido (campo obrigatório) com o mesmo (ver figura 26).

**Redes de Computadores**

Página principal > As minhas disciplinas > RC > PT routing serial

**Navegação**

Página principal

- A minha página inicial
- Páginas do sítio
- O meu perfil
- As minhas disciplinas
  - RC
    - Participantes
    - Geral
    - Tópico 1
    - PT routing serial

**Settings**

- Administração da disciplina
- Definições do meu perfil

**Edit Recommendation**

Back

**Course :** Redes de Computadores

**Content :** PT routing serial

**Content Type :** resource

**Study Time (min.) :** 30

**Satisfaction Level (1=Not Satisfied - 5=Totally Satisfied):** 5 >= 4 is Relevant

**Begin :** 24 Maio 2012, 13:08

**End :** 24 Maio 2012, 13:13

Figura 26 - Painel de Edição da Recomendação

## 5.2 Experimentação

Nesta secção, iremos caracterizar a experimentação, remetendo a sua análise para a secção 5.4.

A experimentação do protótipo correu num curso de Informática numa IES, na unidade curricular do 1º ano de Redes de Computadores, no 2º semestre do ano letivo de 2011-2012. Trinta e dois alunos nela participaram durante dois meses.

Neste período, 57 conteúdos agrupados em 19 tópicos foram adicionados ao LMS *Moodle*. O maior grupo continha 7 conteúdos e o menor somente 1 conteúdo.

Dos 57 conteúdos, 40 tinham um tópico como pré-requisito e 17 não possuíam qualquer pré-requisito.

Dezanove conteúdos eram do tipo “*Base*” (ou seja, conteúdo principal do grupo) e os restantes 38 foram todos referenciados como suplementares (“*supplementary*”).

Quinze conteúdos (26,3%) foram publicados por outros alunos e os restantes (42) pelo professor.

O nível médio dos níveis de satisfação propostos por defeito para os conteúdos foi de 3.73 (numa escala de 1 a 5) e o tempo médio de estudo proposto foi de 80.5 minutos (com um mínimo de 5 e um máximo de 600 minutos), com um desvio padrão de 93.9.

De realçar que durante os 2 meses da experimentação, os alunos apenas dispuseram deste protótipo para aceder aos conteúdos auxiliares da unidade curricular.

Durante a experimentação, os alunos solicitaram uma lista de recomendações, 141 vezes, das quais selecionaram 595 conteúdos (o que dá uma média de 4.2 conteúdos selecionados por cada lista de recomendações apresentada e uma média de 18.6 conteúdos selecionados por aluno). Das 141 listas de recomendações, em 49 listas apenas 1 único conteúdo foi selecionado e em 18 listas foram selecionados 2 conteúdos.

Apenas 13 dos 32 alunos selecionaram pelo menos um conteúdo de todos os 19 tópicos.

De todos os 595 conteúdos selecionados, só 156 provinham de listas de recomendações que se basearam num perfil de aluno completo (ou seja, que tinham valores nos parâmetros que permitiram calcular as similaridades entre utilizadores).

Dos 595 conteúdos selecionados, 496 obtiveram o valor estimado de classificação pelo valor de defeito, definido no perfil do conteúdo (ou seja, vamos considerar que estes 83.4% de seleções correspondem a situações típicas de arranque - ‘cold-start’).

Nas 156 seleções que se basearam em perfis completos, a fase 2 (de filtragem social) reduziu o tamanho da lista da fase 1 em 134 situações e a fase 3 (filtragem colaborativa) reduziu as listas 56 vezes.

Sendo a taxa de conteúdos publicados por alunos de 26,3%, a seleção destes conteúdos face aos dos professores, considerando o total de 595 conteúdos selecionados, foi de 29,1% (ou seja foram selecionados 173 vezes conteúdos de alunos).

Considerando todas as 141 listas de recomendações, o número médio de conteúdos foi de 15.9, ou seja, foram recomendados 2242 conteúdos, considerando todos os alunos. Deste número total de conteúdos, 47% foram propostos como relevantes (estimativa do nível de satisfação igual ou superior a 4) e 53% como não relevantes (inferior a 4). Apesar de em menor número, os conteúdos relevantes (posicionados mais acima na lista) mereceram 59.8% das preferências dos alunos.

Dos 595 conteúdos selecionados, no momento em que concluímos o estudo somente tínhamos 532 conteúdos avaliados, em termos de nível de satisfação e apenas 285 tinham o tempo de estudo usado no respetivo conteúdo.

Tal como já foi referido, cada aluno selecionou uma média de 18.6 conteúdos. Quando comparados os 32 caminhos de aprendizagem dos 32 alunos, verificamos que não

existem quaisquer dois caminhos iguais entre si, ou seja, obtiveram-se 32 sequenciamentos distintos.

## 5.3 Avaliação

Tal como referido na secção 3.4 a avaliação dos SR deverá ter várias dimensões, em particular, quando estamos perante um domínio de aplicação com especificidades muito próprias, como é o caso do ensino. Desta forma, procurámos efetuar recolha de diferentes tipos de dados, quer usando as principais métricas de avaliação das técnicas de recomendação, quer através de um questionário anónimo submetido aos alunos que utilizaram este sistema, no final do período de experimentação.

### 5.3.1 Dimensão Técnica

Em termos de métricas foram obtidos valores sobre as 3 categorias (conforme apêndice 5):

- Métricas de uso das recomendações;
- Métricas de Precisão da Predição;
- Métricas de Precisão das Listas.

Relativamente ao uso das recomendações, considerámos a transformação das avaliações da escala de 1 a 5 para uma escala binária (relevantes: igual ou superior a 4; não relevantes: inferior a 4) e registámos as seguintes matrizes de valores obtidos, cruzando os conteúdos propostos com os selecionados, na primeira matriz (tabela 6) e relativamente aos conteúdos selecionados e medidos, cruzando os níveis de estimação com os níveis medidos, relativamente ao grau de satisfação dos conteúdos, na segunda matriz (tabela 7):

**Tabela 6 - Estimação x Seleção das Recomendações**

Item proposto		Seleção		Totais
		Selecionado	Não selecionado	
Estimação	Relevante	356	698	1054
	Não relevante	239	949	1188
Totais		595	1647	2242

Com bases nestes valores poderemos referir que 33,8% (356/1054) dos conteúdos recomendados como relevantes foram selecionados e que apenas 20,1% (239/1188) dos conteúdos recomendados como não relevantes foram selecionados. Tal como já foi referido, 47% (1054/2242) dos conteúdos foram propostos como relevantes (estimativa do nível de satisfação igual ou superior a 4) e 53% (1188/2242) como não relevantes (inferior a 4). Apesar de em menor número, os conteúdos relevantes (posicionados mais acima na lista) mereceram 59.8% (356/595) das preferências dos alunos. A percentagem de conteúdos selecionados de entre os estimados como não relevante foi de 40,2% (239/595).

**Tabela 7 - Estimação x Avaliação das Recomendações**

Item selecionado		Avaliação			Totais
		Relevante	Não relevante	Não avaliado	
Estimação	Relevante	189	130	37	356
	Não relevante	69	144	26	239
Totais		258	274	63	595

Com base nos valores da tabela 7, poderemos referir que 62,6%  $([189+144]/[258+274])$ , dos conteúdos selecionados e avaliados, obtiveram uma avaliação concordante com a que foi estimada (em termos da sua relevância ou não). A percentagem de conteúdos confirmados relevantes de entre todos os que foram selecionados e avaliados foi de 48,5%  $(258/[258+274])$ . A percentagem de conteúdos recomendados como relevantes de entre todos os que foram considerados relevantes foi de 73,3%  $(189/258)$ .

Sobre as métricas de precisão da predição das recomendações, obtivemos um valor de 0,79 para a medida MAE (taxa do erro absoluto médio). Este valor teve por base de cálculo os 532 conteúdos que foram avaliados pelos alunos. Se consideramos apenas as 86 recomendações que não corresponderam a situações de ‘cold-start’ (recomendações em que foi possível estimar a classificação usando a similaridade entre utilizadores), a métrica MAE desce para 0,43 (considerando apenas estas 86 situações). Em situações de ‘cold-start’ a métrica foi de 0,86. A evolução das métricas com a seleção de recomendações e registo dos valores de avaliação pelos alunos, é ilustrada nas seguintes figuras:

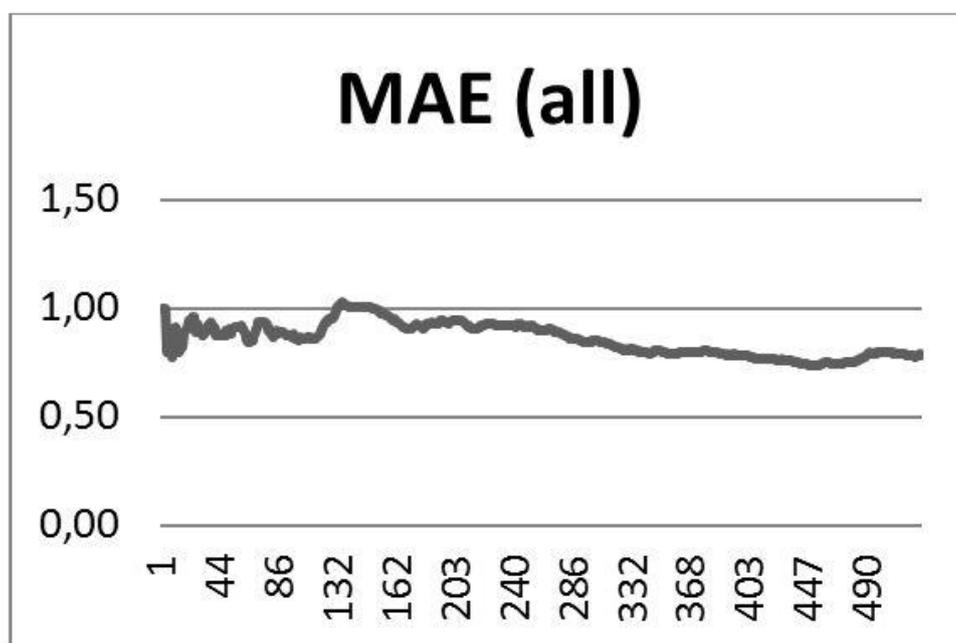


Figura 27- Evolução da MAE (todas as recomendações)

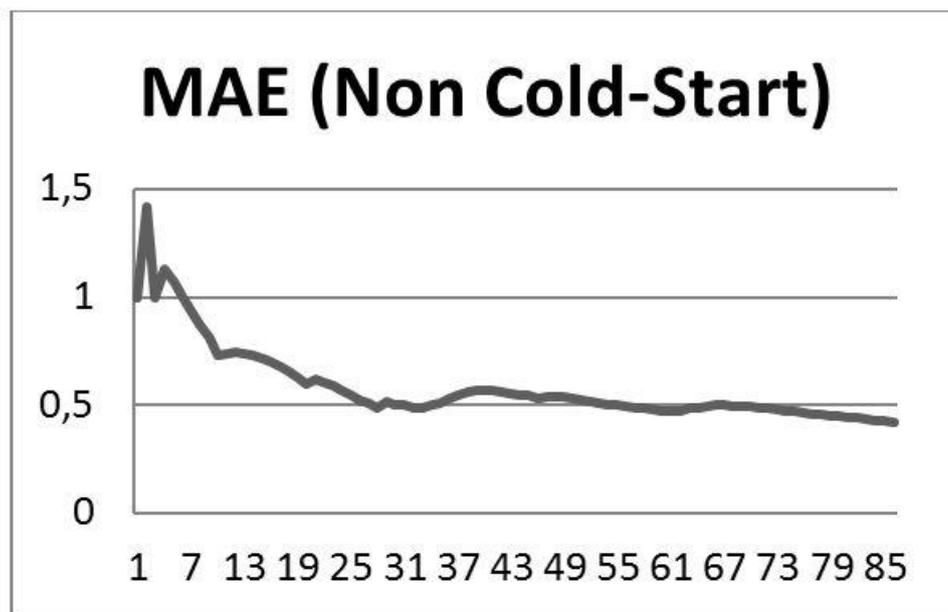


Figura 28 - Evolução da MAE (somente as recomendações 'non cold-start')

Os valores de RMSE foram de 1,11 para 532 conteúdos, 0,58 para os 86 conteúdos recomendados sem 'cold-start' e 1,19 para os conteúdos avaliados originários de recomendações 'cold-start'.

Em termos de métricas de precisão das listas, usámos o índice *lift index*, considerando todas as seleções dos alunos e só as 86 em situação de não 'cold-start'. Os valores obtidos foram de 0,8 e 0,69, respetivamente. Quando se consideram todas as recomendações temos listas com um máximo de 28 posições. Quando só se consideram as listas de recomendações sem situações de 'cold-start', temos listas com um máximo de 11 posições. Quando se consideraram todas as seleções, cerca de 50% dos conteúdos pertenciam aos 2 primeiros decis. No caso reduzido, das 86 seleções, só com 11 posições, os decis têm intervalos menores, pelo que foram necessários os 3 primeiros decis para incluir metade das seleções.

Para a métrica *RankScore* com  $\alpha = 8$  (uma vez que a dimensão média das listas de recomendação foi de 15,9 conteúdos), obtivemos o valor de 0,90.

### 5.3.2 Outras Dimensões

Para além da dimensão técnica, também se avaliaram alguns critérios de outras dimensões, nomeadamente da dimensão pedagógica referida na secção 3.4.3.

Em termos de eficácia verificou-se que dos 57 conteúdos, foram explorados 51, ou seja, cerca de 89,5%.

Relativamente à eficiência, verificou-se que na média dos 285 conteúdos onde foi possível obter o tempo do estudo com o conteúdo, foram necessários menos 31,4 minutos do que o tempo definido por defeito (cerca de 40,4% menos tempo), por quem publicou o conteúdo.

Conforme já referido anteriormente, 62,6% dos conteúdos selecionados obtiveram uma avaliação concordante com a que foi estimada, ou seja, o valor de estimativa foi considerado igual ao da avaliação, em termos do conteúdo ser relevante ou não relevante. É de notar que, para o cálculo desta percentagem, os valores foram transformados numa escala binária.

Em termos de taxa de abandono, podemos referir que cerca de 5 alunos apenas selecionaram 3 ou menos conteúdos e acabaram por não concluir com sucesso a unidade curricular (tendo inclusive, desistido de realizar as provas de avaliação finais).

O critério da variedade que mede a diversidade dos caminhos de aprendizagem individuais propostos aos alunos, foi de 100%, pois tal como também já foi referido todas as sequências dos 32 alunos foram distintas.

Em termos de aprendizagem e resultados, podemos referir que no final do semestre letivo, 8 dos 32 alunos não concluíram com sucesso a unidade curricular. Esta taxa de reprovação de 25%, não é contudo comparável, com outras, uma vez que a própria

unidade curricular foi revista em termos de conteúdos e abordagens pedagógicas, face aos anos transatos.

Um outro resultado, embora um pouco à margem da avaliação do sistema, diz respeito à comparação entre o nível de satisfação atribuído por defeito, no carregamento do conteúdo e a média dos níveis de satisfação registados pelos alunos sobre cada conteúdo. Cerca de 58% dos conteúdos obtiveram uma média de satisfação inferior à atribuída por defeito, em que 20% do total de conteúdos tinham mais do que um nível (em 5) de satisfação abaixo do valor de defeito (valor atribuído no perfil do conteúdo). Em sentido contrário, 12% dos conteúdos tiveram um nível de satisfação acima do esperado em mais do que um nível e 42% dos conteúdos estão com um valor médio de satisfação igual ou superior ao esperado.

No final da experimentação, convidámos os alunos que participaram, a responder a um inquérito anónimo com questões sobre alguns aspetos relacionados com a usabilidade e utilidade do sistema. Foram colocadas 11 questões (ver apêndice 6), 6 das quais requerendo uma resposta dentro da escala de *Likert*, de 1 (muito negativo) a 5 (muito positivo) e 4 requerendo uma resposta do tipo ‘Sim’- ‘Não’. A última questão solicitava aos alunos que ordenassem uma lista de critérios, de acordo com a sua relevância para o suporte à decisão na escolha do conteúdo.

Os resultados do questionário indicam que 91% dos alunos consideram importante poderem publicar conteúdos, tal como os professores o fazem. Metade dos alunos acha importante haver pré-requisitos entre conteúdos. Cerca de 77% dos alunos atribuem importância a poderem avaliar os conteúdos e indicar o seu tempo de estudo. Apesar de apenas 26% dos conteúdos terem sido recomendados com base num perfil de aluno completo, 71% dos alunos acha importante poder personalizar o seu perfil. Cerca de 62% considerou que este tipo de sistema pode ajudar no processo de seleção de conteúdos. Uma razoável percentagem de alunos, 77%, considerou que o protótipo não é fácil de usar.

As respostas às questões “Sim - Não” mostraram que cerca de 59% dos alunos não atribuíram importância à origem dos conteúdos (se publicados por professores ou por alunos). O nível de satisfação estimado foi considerado relevante na escolha dos conteúdos por parte de 68% da população de alunos, mas somente 27% atribuiu importância ao tempo de estudo apresentado. Cerca de 73% dos alunos compreendeu o funcionamento do sistema, no sentido em que as avaliações que eles produziam sobre o nível de satisfação ou sobre o tempo de estudo iriam influenciar as próximas recomendações.

Finalmente, dos 8 critérios sugeridos para escolha, 44% dos alunos considerou o nível de satisfação como o mais relevante e 33% preferiu o tipo de relacionamento entre conteúdos. O tempo de estudo proposto por defeito foi o mais importante para 17% dos alunos e os restantes 6% escolheram como primeiro critério o facto de o conteúdo ser uma novidade.

## 5.4 Discussão sobre os Resultados

A análise aos resultados obtidos, quer pelas métricas como pelas respostas ao questionário permitem efetuar várias observações, algumas podendo mesmo ser consideradas como conclusões deste estudo.

Consideramos que a hipótese de permitir que os alunos possam contribuir com novos conteúdos é válida, reconhecida nas respostas aos questionários, assim como na própria seleção desses conteúdos por parte dos alunos (29,1% seleções sobre o total de seleções, havendo 26,3% de conteúdos publicados por alunos).

Quanto à qualidade global das recomendações, as várias métricas sugerem que os alunos deram preferência às recomendações do topo da lista (conforme métrica de listas), às recomendações com estimativa de avaliação relevante (embora o sistema recomendasse mais conteúdos com recomendações abaixo do nível 4).

Sobre a precisão das técnicas de recomendação também podemos referir que o sistema tem um bom desempenho. Mesmo com a transformação da escala de *Likert* numa escala binária tivemos uma percentagem de acertos de 62,6% sobre a totalidade das estimativas de classificação. Também na medida MAE se registou um valor relativamente baixo, com diferenças médias inferiores a 0,79 entre as avaliações e as estimativas. De realçar que se consideramos as técnicas aplicadas com base nalgum histórico e no perfil de aluno completo, o valor da MAE baixa para 0,43, o que significa que com o uso e com o perfil definido, cada aluno pode obter melhores estimativas de classificação, ou seja mais próximas da sua classificação real. O desvio passa nesse caso de 0,79 para 0,43, ou seja melhora em 54,4%. Mesmo nos valores da medida RMSE, que dão maior ênfase aos maiores desvios, obtiveram-se valores (1,11 para todas as seleções avaliadas e 0,58 para as situações de perfil definido e existência de histórico de avaliações) que confirmam o bom desempenho do processo de cálculo das estimativas de avaliação.

Ambos os valores calculados para as métricas das listas mostram um elevado desempenho com um índice *LiftIndex* de 0,8 e de *RankScore* de 0,9, o que significa um ótimo posicionamento dos conteúdos nas listas de recomendações.

Comparativamente com o nível de satisfação, o parâmetro da duração dos conteúdos mostrou-se menos útil. Apenas em 47,9% dos conteúdos avaliados se obteve informação sobre a duração do estudo dos conteúdos. Apenas 17% dos alunos considerou este critério como o mais relevante e somente 27% atribuiu relevância a esse parâmetro no processo de decisão da escolha dos conteúdos.

Em termos de utilização, poderemos concluir que o sistema foi compreendido e adotado pelos alunos, especialmente por aqueles que demonstraram interesse em obter aprovação na unidade curricular.

O total dos 32 alunos obteve experiências únicas de aprendizagem, correspondendo a 32 sequências de conteúdos distintas, compostas por sequências de tamanhos diferentes, conteúdos diferentes e com ordens de conteúdos igualmente diferentes.

Como aspetos limitativos desta solução poderemos assinalar a elevada percentagem de alunos que atribuiu uma elevada dificuldade ao uso do sistema.

A ausência de perfis totalmente preenchidos, no momento das recomendações é outro aspeto relevante a assinalar. A exigência de preenchimento explícito dos parâmetros dos perfis é referida como um dos aspetos a minimizar neste tipo de sistemas e voltou, nesta experimentação, a confirmar-se. Devemos por isso procurar soluções que passem por perfis implícitos.

A ausência de histórico de avaliações e de durações de estudo sobre os conteúdos, no momento de arranque contribuiu igualmente para que muitas das recomendações se tenham baseado nos valores propostos por defeito para a avaliação e tempo de estudo. Essas recomendações não consideraram as similaridades entre utilizadores, pelo que o melhor desempenho das técnicas de recomendação só foi possível de obter nas recomendações mais finais.

A utilização do parâmetro de duração do tempo de estudo não produziu os resultados esperados, não só porque foi pouco considerado no momento da avaliação dos conteúdos, como também o foi no preenchimento do perfil. No questionário também não mereceu a relevância da maioria dos alunos.

Relativamente à importância da formulação da similaridade e do cálculo da estimativa de avaliação, podemos concluir que trouxeram benefícios (já referidos) à precisão das recomendações. Contudo, não foi possível determinar a relevância comparativa das duas similaridades entre si.

Um aspeto que merece nesta altura ser destacado diz respeito à comparação do modelo proposto e implementado com outras implementações e outros sistemas. De facto, na literatura relacionada, alguma já referenciada na secção 3.3.4, foi possível identificar uma variedade de opções, a maioria com abordagens híbridas e recorrendo a técnicas mais ou menos inovadoras, pelo menos num ou noutro aspeto. Nalguns desses trabalhos foram feitas avaliações, na sua maioria baseadas em medidas sobre as técnicas de recomendação. Contudo, a principal limitação dos SR aplicados ao ensino é a ausência de conjuntos de dados de teste relevantes e disponíveis (à semelhança do que existe noutros domínios de aplicação, tais como *Eachmovie*, *MovieLens* e *Netflix*) que permitam criar ambientes de simulação adequados a este domínio.



## Capítulo 6

### Conclusões e Trabalho Futuro

Perante as questões inicialmente formuladas, sobre como adicionar novos conteúdos num contexto formal e de como disponibilizar os conteúdos adequadamente a cada aluno, de forma personalizada, formulámos hipóteses, desenvolvemos modelos e implementámos um protótipo. Esse protótipo foi experimentado e avaliado.

As conclusões que apresentaremos na secção seguinte são essencialmente as contribuições deste trabalho de investigação e pretendem responder aos quesitos identificados no início deste trabalho.

Durante todas as fases surgiram novas hipóteses, novos considerandos, diferentes perspetivas e possibilidades de evolução, que fomos anotando. Procuraremos na secção 6.2 sistematizar os principais aspetos daí resultantes.

Sobre este trabalho foram submetidos e aceites 2 artigos a duas conferências com revisão de pares, uma nacional e outra internacional, considerando o problema, modelo e arquitetura da solução proposta (Madeira et al., 2012a; Madeira et al., 2012b). Neste momento temos submetido um outro artigo com a avaliação experimental do protótipo implementado sobre o modelo, aguardando a resposta da revista.

## 6.1 Conclusões

Em termos de conclusão, procuraremos verificar de que forma as questões formuladas no capítulo 1, de introdução, puderam ser respondidas pelas hipóteses que colocámos e pela avaliação que foi realizada sobre o protótipo desenvolvido.

A primeira questão envolvia a necessidade de inclusão de um maior número de conteúdos ou atividades de aprendizagem. A nossa resposta passou por incluir um modelo onde alunos efetuam a adição de conteúdos ou de referências para outros conteúdos ou atividades de aprendizagem disponíveis na Internet, que são validados e relacionados com os que são publicados normalmente pelo professor responsável pela formação presencial. Após implementação, testes e validação é possível referir, em termos de contribuições deste trabalho, o seguinte:

- A adição de conteúdos, sua adoção e as respostas ao inquérito pelos alunos permitiram validar o interesse da solução proposta, em ensino formal;
- A solução proposta para o relacionamento entre conteúdos permite agrupá-los em tópicos ou grupos de tópicos, apoiando os alunos na escolha dos conteúdos mais adequados sobre cada grupo e evitando a exploração de conteúdos redundantes ou menos adequados ao perfil de cada aluno.

A segunda questão envolvia o processo de seleção das atividades e conteúdos de aprendizagem que melhor pudessem adequar-se aos interesses e necessidades de cada aluno, em cada momento da sua aprendizagem. Em termos de contribuições deste trabalho para a resposta a esta questão, poderemos referir o seguinte:

- O modelo de recomendações híbrido proposto gerou respostas adequadas e com níveis de precisão aceitáveis quer para a estimativa de classificações como para a formação das listas, face ao perfil de cada aluno;
- Os alunos atribuíram relevância à classificação proposta pelo sistema de recomendações, no seu processo de seleção de conteúdos;

- A precisão das recomendações é melhor quando as recomendações são baseadas em filtragem colaborativa resultantes de perfis completos e quando existe um histórico de avaliações;
- Embora com diferente relevância, os 4 parâmetros propostos para o perfil de aluno (máximo tempo de estudo pretendido, dimensão do histórico, média do aluno e nível mínimo de satisfação pretendido), mostraram influenciar a estratégia de recomendação e logo a seleção de conteúdos por parte dos alunos;
- A proposta de perfil do conteúdo contemplando 2 informações distintas (tempo de estudo e nível de satisfação), permitiu que o sistema de recomendações considerasse todos os conteúdos no processo de geração de recomendações, mesmo sem quaisquer avaliações sobre os conteúdos;
- A formulação de similaridade entre alunos, que valoriza os melhores alunos (ou pelo menos melhores que um dado nível) e o passado recente de conteúdos selecionados por cada aluno é específica deste domínio de aplicação e mostrou poder gerar recomendações adequadas aos interesses dos alunos, de acordo com o perfil proposto.

Como consequência deste trabalho, foi desenvolvido um protótipo sobre um sistema com grande utilização, como o *Moodle*, e testado em contexto de Ensino Superior. Consideramos que a experimentação é um recurso essencial a adotar quando se pretende avaliar a utilidade e importância, enquanto contributo para a investigação. A experimentação indica que esta solução pode contribuir para criar experiências únicas de aprendizagem designadamente através de sequenciamentos de conteúdos personalizados.

Acreditamos que a possibilidade de adição de novos conteúdos pelos alunos, tal como foi proposto, poderá constituir uma atividade motivadora para os mesmos, atrativa para os professores e não descaracterizadora do modelo de ensino formal.

Um efeito não esperado, deste trabalho, resultou na sua contribuição para uma melhoria de vários conteúdos, nomeadamente naqueles cujas médias das avaliações dos alunos foram significativamente inferiores às esperadas (propostas por defeito).

Gostaríamos igualmente de destacar que um dos principais objetivos inerentes a esta investigação consistiu na revisão dos fundamentos e literatura relacionada, que se revelou fundamental no desenvolvimento da solução proposta.

Ao longo do desenvolvimento deste trabalho foi possível identificar algumas limitações, em termos dos resultados obtidos, designadamente:

- A implementação do protótipo sobre o sistema *Moodle* não mereceu a usabilidade desejada por parte dos alunos que, habituados às funcionalidades do gestor de conteúdos, estranharam as novas funcionalidades em termos de recomendações;
- Não foi possível determinar o grau de importância comparativo dos dois parâmetros usados no cálculo da similaridade entre alunos, ainda que o valor global se tenha mostrado relevante no cálculo das recomendações;
- Não foi realizada a comparação entre a nossa proposta de similaridade entre alunos e a formulação habitual usada na filtragem colaborativa;
- Destacamos ainda que, devido ao curto período de tempo em que a experimentação decorreu (2 meses numa só turma de uma só unidade curricular), não nos parece ser possível aprofundar todas as contribuições referidas, devendo a utilização contínua, repetida e alargada deste tipo de soluções poder vir a reforçar ou não, algumas das conclusões;
- Não foi possível demonstrar que este tipo de sistemas possa contribuir para um melhor sucesso dos alunos em termos da sua aprendizagem.

Em resumo, somos de destacar a experiência com uma estratégia de recomendações que usa um conjunto alargado de conteúdos, baseada numa formulação de similaridade que permitiu a classificação e o apoio à seleção de conteúdos por parte dos alunos. Esta solução veio igualmente mostrar que o desenho do interface com o aluno é fundamental, no âmbito dos sistemas de recomendação de apoio à aprendizagem.

## 6.2 Trabalho futuro

Em trabalhos futuros, procuraremos avaliar as publicações realizadas por alunos, não só em termos da quantidade de conteúdos selecionados face aos publicados (como foi feito), mas incluindo outros aspetos, tais como aferir a taxa de rejeição dos conteúdos por professores e analisar se existem diferenças no comportamento do sistema (estimativa da classificação) ou nos alunos (avaliações reais), comparativamente com os conteúdos publicados por professores.

O tipo de conteúdo (“*Base*”, “*Supplementary*”, “*Upgrade*”, “*Alternative*”) deverá ser igualmente analisado relativamente às opções de seleção e classificação que os alunos efetuam.

Entendemos que as 2 métricas que compõem a similaridade (média de curso dos alunos e histórico de conteúdos) deverão ser estudadas por forma a aferir se ambas são relevantes, se alguma delas não o é ou ainda se a sua importância é igual (tal como foi neste modelo proposto) ou diferente. Também os critérios que foram usados não serão os únicos que farão sentido na personalização. Outros critérios associados ao perfil do conteúdo, como o nível e dificuldade do conteúdo ou a sua validade poderão igualmente ser importantes para o cálculo da estimativa de classificação ou mesmo para a decisão de inclusão ou exclusão da lista de recomendações. A possibilidade de abertura de avaliações a outros intervenientes, como outros professores poderia igualmente contribuir para melhorar as avaliações propostas. Relativamente à similaridade entre alunos, pretendemos comparar a nossa proposta com as abordagens habituais, que recorrem ao coeficiente de *Pearson* ou similaridade cosseno sobre as avaliações dos alunos.

Antes da próxima experimentação torna-se necessário melhorar o sistema, designadamente quanto ao interface com o utilizador, visando uma melhor usabilidade. Defendemos que a própria apresentação possa ser adaptativa tendo em conta o aluno.

Seria igualmente interessante alargar a experiência a outros alunos de outros cursos e analisar os resultados obtidos, comparando-os.

Embora se reconheça a importância da tecnologia, queremos compreender o efeito deste tipo de soluções sobre os resultados e sucesso da aprendizagem, pelo que pretendemos desenvolver uma abordagem que permita avaliar de que forma este tipo de soluções poderá melhorar esses resultados essenciais.

Uma hipótese que colocámos e que pretendemos estudar, na continuação deste trabalho, considera a possibilidade de usar as técnicas de recomendação baseadas em conteúdos para propor automaticamente ao gestor de conteúdos ampliado, novos conteúdos, usando a similaridade entre os conteúdos propostos pelo professor e os existentes em repositórios, nalguns endereços de serviços *Web 2.0*, ou mesmo na Internet. A similaridade entre conteúdos também poderá ser testada quando o aluno solicitar aprofundamento dos conceitos relacionados com um dado conteúdo.

Uma abordagem que pretendemos propor pretende basear as recomendações “num seguidor”, o aluno mais similar em cada momento de aprendizagem. O sistema deverá propor apenas os conteúdos com base no elemento “seguidor”, determinado no momento. O problema aqui colocar-se-á essencialmente no algoritmo de similaridade entre alunos e não no cálculo da estimativa de classificação.

Finalmente, na secção 4.6 foram apresentadas algumas considerações que poderão ser igualmente perspectivadas como trabalho futuro.

Em resumo existem várias possibilidades que gostaríamos de explorar no futuro, quer sobre o mesmo modelo, quer sobre um modelo, eventualmente alterado.

# Bibliografia

- Abbar, S., Bouzeghoub, M., & Lopez, S. (2009). Context-aware recommender systems: A service oriented approach. *VLDB PersDB Workshop*.
- Adomavicius, G., & Tuzhilin, A. (1-4 de 2001). Expert-Driven Validation of Rule-Based User Models in Personalization Applications. *5*, 33-58.
- Adomavicius, G., & Tuzhilin, A. (6 de 2005). Toward the Next Generation of Recommender Systems: A Survey of the State-of-the-Art and Possible Extensions. *IEEE Transactions on Knowledge and Data Engineering* , *17*(6), 734-749.
- Advanced Distributed Learning. (2004). *SCORM Sequencing and Navigation (SN) Version 1.3.1*. Advanced Distributed Learning.
- Ahn, H., Kim, K., & Han, I. (2006). Mobile advertisement recommender system using collaborative. *Proceedings of the 2006 Conference of the Korea Society of Management Information Systems*, (pp. 709-715).
- Ahn, J.-w., Brusilovsky, P., Grady, J., He, D., & Syn, S. Y. (2007). Open user profiles for adaptive news systems: help or harm? *Proceedings of the 16th international conference on World Wide Web* (pp. 11-20). Banff, Alberta, Canada: ACM.
- Anderson, M., Ball, M., Boley, H., Greene, S., Howse, n. N., Lemire, D., & McGrath, S. (2003). RACOFI: A Rule-Aplying Collaborative Filtering System.
- Arazy, O., Kumar, N., & Shapira, B. (2009). Improving social recommender systems. *IT Professional*, 38-44.

- Aurnhammer, M., Hanappe, P., & Steels, L. (2006). Integrating Collaborative Tagging and Emergent Semantics for Image Retrieval . *Proceedings of the WWW 2006 Collaborative Web*.
- Avancini, H., & Straccia, U. (2005). User recommendation for collaborative and personalised digital archives. *International Journal of Web Based Communities*, 163-175.
- Balabanovic, M., & Shoham, Y. (3 de 1997). Fab: content-based, collaborative recommendation. *Communications of the ACM*, 40(3), 66-72.
- Baltrunas, L., & Amatriain, X. (2009). Towards time-dependant recommendation based on implicit feedback. *Workshop on Context-Aware Recommender Systems*.
- Baptista, J. (2010). The birth of a company-wide wiki. *Proceedings of the Workshop on Open Source and Design of Communication* (pp. 7-10). Lisbon, Portugal: ACM.
- Beck, R. J. (2010). *Learning Objects*. Obtido de Center for International Education: [http://www4.uwm.edu/cie/learning\\_objects.cfm?gid=56](http://www4.uwm.edu/cie/learning_objects.cfm?gid=56)
- Belkin, N. J., & Croft, W. B. (1992). Information Filtering and Information Retrieval: Two Sides of the Same Coin. *Communications of the ACM*, 29-38.
- Billsus, D., & Pazzani, M. J. (1998). Learning collaborative information filters. *Proceedings of the fifteenth international conference on machine learning (ICML-98)* (pp. 46-54). Madison, Wisconsin: Morgan Kaufmann Publishers Inc.
- Billsus, D., & Pazzani, M. J. (1999). A personal news agent that talks, learns and explains. *Proceedings of the third annual conference on Autonomous Agents* (pp. 268-275). Seattle, Washington, United States: ACM.
- Billsus, D., Pazzani, M., & Chen, J. (2000). A learning agent for wireless news access. *Proceedings of the 5th international conference on Intelligent user interfaces* (pp. 33-36). New Orleans, Louisiana, United States: ACM.
- Blei, D., Ng, A., & Jordan, M. (2003). Latent dirichlet allocation. *Journal of Machine Learning*, 993-1022.

- Bobadilla, J., Serradilla, F., & Hernando, A. (2009). Collaborative filtering adapted to recommender systems of e-learning. *Knowledge-Based Systems* , 261-265.
- Botha, A., Herselman, M., & van Greunen, D. (2010). Mobile user experience in a mlearning environment. *Proceedings of the 2010 Annual Research Conference of the South African Institute of Computer Scientists and Information Technologists* (pp. 29-38). Bela Bela, South Africa: ACM.
- Bozarth, J. (2010a). Twitter. In J. Bozarth, *Social Media for Trainers* (pp. 23-52). Pfeiffer.
- Bozarth, J. (2010b). Facebook and Other Communities. In J. Bozarth, *Social Media for Trainers* (pp. 53-82). Pfeiffer.
- Bozarth, J. (2010c). Blogs. In J. Bozarth, *Social Media for Trainers* (pp. 83-108). Pfeiffer.
- Bozarth, J. (2010d). Wikis. In J. Bozarth, *Social Media for Trainers* (pp. 109-126). Pfeiffer.
- Bozarth, J. (2010e). Other Tools. In J. Bozarth, *Social Media for Trainers* (pp. 127-141). Pfeiffer.
- Bra, P. D., Aerts, A., Berden, B., Lange, B. d., Rousseau, B., Santic, T., . . . Stash, N. (2003). AHA! The Adaptive Hypermedia Architecture. *Proc. of the fourteenth ACM conference on Hypertext and Hypermedia* (pp. 81-84). ACM.
- Bra, P. D., Houben, G.-j., & Wu, H. (1999). AHAM: A Dexter-based Reference Model for Adaptive Hypermedia. *Proceedings of the tenth ACM Conference on Hypertext and hypermedia : returning to our diverse roots: returning to our diverse roots* (pp. 147-156). Darmstadt, Germany: ACM.
- 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* (pp. 43-52). Madison, Wisconsin: Morgan Kaufmann Publishers Inc.
- Burke, R. (11 de 2002). Hybrid Recommender Systems: Survey and Experiments. *User Modeling and User-Adapted Interaction*, 12(4), 331-370.

- Burke, R. (2007). Hybrid web recommender systems. In P. Brusilovsky, A. Kobsa, & W. Nejdl (Eds.), *The adaptive web - Lecture Notes In Computer Science* (Vol. 4321, pp. 377-408). Springer-Verlag, Berlin, Heidelberg.
- Cain, J. (2008). Online Social Networking Issues Within Academia and Pharmacy Education. *American Journal of Pharmaceutical Education*, 72(10).
- Canny, J. (2002). Collaborative filtering with privacy via factor analysis. *Proceedings of the 25th annual international ACM SIGIR conference on Research and development in information retrieval* (pp. 238-245). Tampere, Finland: ACM.
- Chew, L. K. (2003). eLearning Standards and Learning Paths. In L. S. Committee.
- Chow, T., & Chmura, A. (2010). Implementing a virtual community of interest at Capella University. *Proceedings of the 2010 ACM conference on Information technology education* (pp. 59-64). Midland, Michigan, USA: ACM.
- Claypool, M., Gokhale, A., & Miranda, T. (1999). Combining content-based and collaborative filters in an online newspaper. *Proceedings of the SIGIR-99 workshop on recommender systems: algorithms and evaluation*.
- Cotter, P., & Smyth, B. (2000). PTV: Intelligent personalized TV guides. *Twelfth conference on innovative applications of artificial intelligence*, (pp. 957-964). Austin, Texas .
- Couros, A. (2010). Developing Personal Learning Networks for Open and Social Learning. In G. Veletsianos (Ed.), *Emerging technologies in distance education* (pp. 109-128). Athabasca University Press.
- Crestani, F. (1997). Application of Spreading Activation Techniques in Information Retrieval. *Artificial Intelligence Review*, 453-482.
- Davidson, A.-L., & Waddington, D. (9 de 2010). E-Learning in the university: When will it really happen? *eLearning Papers*, 21, pp. 1-10.
- Deshpande, M., & Karypis, G. (2004). Item Based Top-N Recommendation Algorithms. *ACM Transactions on Information Systems*, 143-177.

- Diederich, J., & Iofciu, T. (2006). Finding Communities of Practice from User Profiles Based On Folksonomies. *In Proceedings of the 1st International Workshop on Building Technology Enhanced Learning solutions for Communities of Practice (TEL-CoPs '06), co-located with the First European Conference on Technology-Enhanced Learning*, (pp. 288-297).
- Dix, A., Finlay, J. E., Abowd, G. D., & Beale, R. (2003). *Human-Computer Interaction*. Harlow, England: Pearson.
- DL N° 38/2007 de 16 de Agosto -Aprova o regime jurídico da avaliação do ensino superior. pp. 5310 - 5313. (s.d.).
- DL N° 42/2005 de 22 de Fevereiro - Princípios reguladores de instrumentos para a criação do espaço europeu de ensino superior. DR - I SÉRIE - A - N° 37 , pp. 1494-1499. (s.d.).
- DL N° 62/2007 de 10 de Setembro - Regime jurídico das instituições de ensino superior. DR - 1ª série - N° 174 , pp. 6358 - 6389. (s.d.).
- DL N° 64/2006 de 21 de Março - Condições especiais de acesso e ingresso no ensino superior. DR - I SÉRIE - A N° 57 , pp. 2054 - 2056. (s.d.).
- DL N° 74/2006 de 24 de Março - Graus académicos e diplomas do ensino superior. DR - I Série - A - N° 60 , pp. 2242 - 2257. (s.d.).
- DL N° 88/2006 de 23 de Maio - Cursos de Especialização Tecnológica. DR - I Série - A - N° 99 , pp. 3474 - 3483. (s.d.).
- Dolog, P., & Nejdl, W. (2003). Using UML and XMI for Generating Adaptive Navigation Sequences in Web-Based Systems. *Proc. of UML 2003 — The Unified Modeling Language. Model Languages and Applications. 6th Intl. Conference* (pp. 205-219). Springer.
- Downes, S. (10 de 2005). *E-learning 2.0*. Obtido de elearn Magazine:  
<http://elearnmag.acm.org/featured.cfm?aid=1104968>
- Drachsler, H., Hummel, H. G., & Koper, R. (2008). Personal recommender systems for learners in lifelong learning networks: the requirements, techniques and model. *International Journal of Learning Technology* , 404--423.

- Drachler, H., Hummel, H. G., & Koper, R. (2009). Identifying the Goal, User model and Conditions of Recommender Systems for Formal and Informal Learning. *J. Digit. Inf.*
- Drachler, H., Hummel, H. G., Van den Berg, B., Eshuis, J., Waterink, W., Nadolski, R. J., . . . Koper, R. (2009). Effects of the ISIS Recommender System for navigation support in self-organised Learning Networks. *Journal of Educational Technology and Society*, 122-135.
- Dron, J., Mitchell, R., Siviter, P., & Boyne, C. (2000). CoFIND-an experiment in n-dimensional collaborative filtering. *Journal of Network and Computer Applications*, 131-142.
- Dutta, S., & Bilbao-Osorio, B. (2012). *The Global Information Technology Report 2012 - Living in a Hyperconnected World*. Geneva: World Economic Forum.
- Ekstrand, M. D., Riedl, J., & Konstan, J. A. (2011). Collaborative Filtering Recommender Systems. *Foundations and Trends in Human-Computer Interaction* , 81-173.
- Eschenbrenner, B., & Nah, F. F.-H. (2007). Mobile technology in education: uses and benefits. *IJMLO - International Journal of Mobile Learning and Organisation*, 1(2), 159-183.
- Firan, C. S., Nejd, W., & Paiu, R. (2007). The Benefit of Using Tag-Based Profiles. *Proceedings of the 2007 Latin American Web Conference* (pp. 32-41). IEEE Computer Society.
- Fitzpatrick, J. L., Sanders, J. R., & Worthen, B. R. (2011). *Program Evaluation: Alternative Approaches and Practical Guidelines*. Pearson.
- Fleder, D. M., & Hosanagar, K. (2007). Recommender systems and their impact on sales diversity. *Proceedings of the 8th ACM conference on Electronic commerce* (pp. 192-199). San Diego, California, USA: ACM.
- G.-R.Xue, Lin, C., Q.Yang, W.Xi, Zeng, H.-J., Y.Yu, & Chen, Z. (2005). Scalable collaborative filtering using cluster-based smoothing. *Proceedings of the 28th*

- Annual International ACM SIGIR Conference on Research and Development in Information Retrieval* (pp. 114-121). Salvador, Brazil: ACM.
- García, A. V. (2009). Uso de wikis en ingeniería informática. *Red U - Revista de Docencia Universitaria*.
- Ghauth, K., & Abdullah, N. (2010). Learning Materials Recommendation Using Good Learners' Ratings and Content-Based Filtering. *Educational Technology Research and Development*, 711-727.
- Giannakos, M. N., & Vlamos, P. (2010). Comparing a well designed webcast with traditional learning. *Proceedings of the 2010 ACM conference on Information technology education* (pp. 65-68). Midland, Michigan, USA: ACM.
- Goldberg, D., Nichols, D., Oki, B. M., & Terry, D. (1992). Using collaborative filtering to weave an information tapestry. *Communications of the ACM*, 35(12), 61-70.
- Gonçalves, M. J., Pereira, R. H., & Cota, M. P. (16-19 de 6 de 2010). E-Sharing: Development and Use of Learning Objects Repository. *5th Iberian Conference on Information Systems and Technologies (CISTI)*, (pp. 1-4). Santiago de Compostela.
- Gonzalez-Barbone, V., & Anido-Rifon, L. (2010). From SCORM to Common Cartridge: A step forward. *Computers & Education*, 88-102.
- Good, N., Schafer, J., Konstan, J., Borchers, A., Sarwar, B., Herlocker, J., & Riedl, J. (1999). Combining collaborative filtering with personal agents for better recommendations. *AAAI 99/IAAI '99: Proc. of the 16th National Conf. on Artificial Intelligence* (pp. 439-446). Menlo Park, CA, USA: American Association for Artificial Intelligence.
- Grear, M., Fortuna, B., Mladenic, D., & Grobelnik, M. (2006). k-NN versus SVM in the collaborative. *Data Science and Classification*, 251-260.
- Guedes, D., & Almeida, P. (2010). Integrating podcasts, vodcasts, screencasts and emerging casting technologies in the teaching/learning context higher education: Potentialities, practices and expectations of students and teachers. *2010 5th Iberian Conference on Information Systems and Technologies (CISTI)*, (pp. 1-7).

- Gutiérrez, S., & Pardo, B. (2007). Sequencing in Web-Based Education: Approaches, Standards and Future Trends. In L. Jain, R. Tedman, & D. Tedman (Edits.), *Evolution of Teaching and Learning Paradigms in Intelligent Environment - Studies in Computational Intelligence* (Vol. 62, pp. 83-117). Springer Berlin / Heidelberg.
- Gutiérrez, S., Pardo, A., & Kloos, C. D. (2006). Beyond simple sequencing: Sequencing of learning activities using hierarchical graphs. *Proceedings of the 5th IASTED international conference on Web-based education* (pp. 94-99). Puerto Vallarta, Mexico: ACTA Press.
- Guy, I., & Carmel, D. (2011). Social Recommender Systems. *Israel WWW 2011*.
- Henze, N., & Nejd, W. (6 de 2004). A Logical Characterization of Adaptive Educational Hypermedia. *Hypermedia*, 10(1), 77-113.
- Herlocker, J. L., Konstan, J. A., Borchers, A., & Riedl, J. (1999). An algorithmic framework for performing collaborative filtering. *Proceedings of the Conference on Research and Development in Information Retrieval (SIGIR '99)*, (pp. 230-237).
- Herlocker, J. L., Konstan, J. A., Terveen, L. G., & Riedl, J. T. (2004). Evaluating collaborative filtering recommender systems. *ACM Transactions on Information Systems (TOIS)* (pp. 5-53). ACM.
- Herlocker, J., Konstan, J. A., & Riedl, J. (2002). An Empirical Analysis of Design Choices in Neighborhood-Based Collaborative Filtering Algorithms. *Information Retrieval*, 287-310.
- Hill, W., Stead, L., Rosenstein, M., & Furnas, G. (1995). Recommending and evaluating choices in a virtual community of use. *Proceedings of the SIGCHI conference on Human factors in computing systems* (pp. 194-201). Denver, Colorado, United States: ACM Press/Addison-Wesley Publishing Co.
- Hofmann, T. (2003). Collaborative filtering via Gaussian probabilistic latent semantic analysis. *SIGIR '03: Proc. of the 26th Annual Int. ACM SIGIR Conf. on Research and Development in* (pp. 259-266). ACM.

- Hsu, C.-N., Chung, H.-H., & Huang, H.-S. (2004). Mining skewed and sparse transaction data for personalized shopping recommendation. *Machine Learning*, 35-59.
- Iglesias, A., Martínez, P., Aler, R., & Fernández, F. (2004). Learning Content Sequencing in an Educational . In S. Ben-David, J. Case, & A. Maruoka (Edits.), *Algorithmic Learning Theory - Lecture Notes in Computer Science* (Vol. 3244, pp. 454-463). Springer Berlin / Heidelberg.
- IMS Global Learning Consortium. (2003a). *IMS Simple Sequencing Best Practice and Implementation Guide - Version 1.0 Final Specification*. IMS Global Learning Consortium, Inc.
- IMS Global Learning Consortium. (2003b). *IMS Learning Design Best Practice and Implementation Guide - Version 1.0 Final Specification*. IMS Global Learning Consortium, Inc.
- Jannach, D., Zanker, M., Felfernig, A., & Friedrich, G. (2010). *Recommender Systems - An Introduction*.
- Janssen, J., Tattersall, C., Waterink, W., Berg, B. v., Es, R. v., Bolman, C., & Koper, R. (2005). Self-organising navigational support in lifelong learning: how predecessors can lead the way. *Computers & Education*, 781–793.
- Johnson, L., Adams, S., & Cummins, M. (2012). *The NMC Horizon Report: 2012 Higher Education Edition*. Austin, Texas: The New Media Consortium.
- Karampiperis, P., & Sampson, D. (2005). Adaptive Learning Resources Sequencing in Educational Hypermedia Systems. *Educational Technology & Society*, 8(4), 128-147.
- Khribi, M., Jemni, M., & Nasraoui, O. (2009). Automatic Recommendations for E-Learning Personalization Based on Web Usage Mining Techniques and Information Retrieval. *Educational Technology & Society* , 30–42 .
- Kirkpatrick, D. L., & Kirkpatrick, J. (2006). *Training Programs (3rd ed.)*. San Francisco, CA: Berrett-Koehler Publishers.

- Konstan, J., Miller, B., Maltz, D., Herlocker, J., Gordon, L., & Riedl, J. (1997). GroupLens: Applying collaborative filtering to usenet news. *Communications of the ACM*, 77-87.
- Koper, R. (2005). easing Learner Retention in a Simulated Learning Network Using Indirect Social Interaction. *Journal of Artificial Societies and Social Simulation*, 8, 18-27.
- Koper, R., & Tattersall, C. (2004). New directions for lifelong learning using network technologies. *British Journal of Educational Technology*, 689-700.
- Koren, Y. (2008). Factorization meets the neighborhood: a multifaceted collaborative filtering model. *KDD'08: Proceeding of the 14th ACM SIGKDD Int. Conf. on Knowledge Discovery and Data Mining* (pp. 426–434). New York, NY, USA: ACM.
- Koren, Y., Bell, R., & Volinsky, C. (2009). Matrix factorization techniques for recommender systems. *Computer*, 30-37.
- Koutrika, G., Bercovitz, B., Kaliszan, F., Liou, H., & Garcia-Molina, H. (2009). CourseRank: A Closed-Community Social System Through the Magnifying Glass. *Proc. of the 3rd International AAAI Conference on Weblogs and Social Media (ICWSM'09)*. San Jose, California .
- Krulwich, B. (1997). Lifestyle Finder: Intelligent User Profiling Using Large-Scale Demographic Data. *Artificial Intelligence Magazine*, 37-45.
- Lalonde, C. (2011). *The Twitter experience : the role of Twitter in the formation and maintenance of personal learning networks*. Royal Roads University.
- Lang, K. (1995). NewsWeeder: Learning to Filter Netnews. *Proceedings of the 12th International Machine Learning Conference*, (pp. 331-339).
- Lathia, N., Hailes, S., & Capra, L. (2009). Temporal collaborative filtering with adaptive neighbourhoods. *ACM SIGIR '09* (pp. 796–797). ACM.
- Learning Technology Standards Committee of the IEEE. (2002). *Draft Standard for Learning Object Metadata (1484.12.1)*. New York, NY, USA: IEEE.

- Lehner, F., & Nösekabel, H. (2002). The Role Of Mobile Devices In E-Learning - First Experiences With A Wireless E-Learning Environment. *Proceedings of IEEE International Workshop on Wireless and Mobile Technologies in Education*, (pp. 103-106).
- Lemire, D., & Maclachlan, A. (2005). Slope One Predictors for Online Rating-Based Collaborative Filtering. *Proceedings of the 5th SIAM International Conference on Data Mining*, (pp. 471-480). Newport Beach, CA.
- Li, L. C., Grimshaw, J. M., Nielsen, C., Judd, M., Coyte, P. C., & Graham, I. D. (2009). Evolution of Wenger's concept of community of practice. *Implementation Science*.
- Lieberman, H. (1995). Letizia: an agent that assists web browsing. *Proceedings of the 14th international joint conference on Artificial intelligence - Volume* (pp. 924-929). Morgan Kaufmann Publishers Inc.
- Lin, H.-Y., Tseng, S.-S., Weng, J.-F., & Su, J.-M. (2009). Design and Implementation of an Object Oriented Learning Activity System. *Educational Technology & Society*, 12(3), 248-265.
- Linden, G., Smith, B., & York, J. (2003). Amazon.com recommendations: Item-to-item collaborative filtering. *IEEE Internet Computing*, 76-80.
- Ling, C., & Li, C. (1978). Data mining for direct marketing: Problems and solutions. *Proceedings of the 4th International Conference on Knowledge Discovery and Data Mining*, (pp. 73-79).
- Lombardi, S., Anand, S., & Gorgoglione, M. (2009). Context and customer behavior in recommendation. *Workshop on Context-Aware Recommender Systems*.
- Luis De-Marcos, J. J., Martínez, J. A., Gutiérrez, R. B., & Gutiérrez, M. (2009). A new sequencing method in Web-based education. *Proceedings of the Eleventh conference on Congress on Evolutionary Computation* (pp. 3219-3225). Trondheim, Norway: IEEE Press.

- Maddrell, J. (07 de 11 de 2007). *Open Ed - Week 11: OERs vs Learning Objects*. Obtido em 23 de 3 de 2010, de Designed to inspire: <http://designedtoinspire.com/drupal/node/549>
- Madeira, F., Quaresma, R., & Abreu, S. (2012a). Estratégia híbrida de recomendações sobre um gestor de conteúdos ampliado em ensino formal. *CAPSI 2012 : Conferência da Associação Portuguesa de Sistemas de Informação*. Guimarães: Associação Portuguesa de Sistemas de Informação.
- Madeira, F., Quaresma, R., & Abreu, S. (2012b). A hybrid recommender strategy on an expanded content manager in formal learning. *5th International Conference of Education, Research and Innovation*. Madrid: International Association of Technology, Education and Development.
- Madjarov, I., & Betari, A. (2008). Adaptive Learning Sequencing for Course Customization: A Web Service Approach. *Proceedings of the 2008 IEEE Asia-Pacific Services Computing Conference* (pp. 530-535). IEEE Computer Society.
- Mahmood, T., & Ricci, F. (2009). Improving recommender systems with adaptive conversational strategies. *Proceedings of the 20th ACM conference on Hypertext and hypermedia* (pp. 73-82). Torino, Italy: ACM.
- Manouselis, N., Drachsler, H., Verbert, K., & Duval, E. (2013). *Recommender Systems for Learning*. Springer.
- Manouselis, N., Drachsler, H., Vuorikari, R., Hummel, H., & Koper, R. (2010). Recommender systems in technology enhanced learning. In P. Kantor, F. Ricci, L. Rokach, & B. Shapira (Edits.), *Recommender Systems Handbook: A Complete Guide for Research Scientists & Practitioners* (pp. 387– 415). Berlin: Springer.
- Manouselis, N., Vuorikari, R., & Van Assche, F. (2007). Simulated Analysis of MAUT Collaborative Filtering for Learning Object Recommendation. *Proc. of the Workshop on Social Information Retrieval in Technology Enhanced Learning (SIRTEL 2007)*, (pp. 27-35). Crete, Greece.
- Margaryan, A., Milligan, C., & Douglas, P. (2007). *CDLOR Deliverable 9: Structured Guidelines for Setting up LORs*.

- McNee, S. M., Riedl, J., & Konstan, J. (2006). Accurate is not always good: How Accuracy Metrics have hurt Recommender Systems. *Extended Abstracts of the 2006 ACM Conference on Human Factors in Computing Systems (CHI 2006)*.
- Mell, P., & Grance, T. (2011). *SP 800-145. The NIST Definition of Cloud Computing*. Gaithersburg, MD, United States: U.S. Department of Commerce, National Institute of Standards and Technology.
- Melville, P., & Sindhvani, V. (2010). Recommender Systems. *Encyclopedia of Machine Learning*, 829-838.
- Melville, P., Mooney, R. J., & Nagarajan, R. (2002). Content-Boosted Collaborative Filtering for Improved Recommendations. *Proceedings of the Eighteenth National Conference on Artificial Intelligence(AAAI-2002)*, (pp. 187-192). Edmonton, Canada.
- Mihalcea, R., & Csomai, A. (2007). Wikify!: linking documents to encyclopedic knowledge. *Proceedings of the sixteenth ACM conference on Conference on information and knowledge management* (pp. 233-242). Lisbon, Portugal: ACM.
- Mladenic, D. (1999). Machine learning used by Personal WebWatcher.
- Mott, J. (3 de 3 de 2010). *Envisioning the Post-LMS Era: The Open Learning Network*. Obtido em 29 de 4 de 2011, de Educause review online:  
<http://www.educause.edu/ero/article/envisioning-post-lms-era-open-learning-network>
- Mott, J. (3 de 3 de 2010). *Envisioning the Post-LMS Era: The Open Learning Network*. (Educause) Obtido em 3 de 12 de 2010, de Educause review online:  
<http://www.educause.edu/ero/article/envisioning-post-lms-era-open-learning-network>
- Nadolski, R., Van den Berg, B., Berlanga, A., Drachsler, H., Hummel, H., Koper, R., & Sloep, P. (2009). Simulating Light-Weight Personalised Recommender Systems in Learning Networks: A Case for Pedagogy-Oriented and Rating-Based Hybrid Recommendation Strategies. *Journal of Artificial Societies and Social Simulation (JASSS)*.

- OECD. (2007). *Giving Knowledge for Free: The Emergence of Open Educational Resources*. OECD Publishing.
- Oku, K., Nakajima, S., Miyazaki, J., & Uemura, S. (2006). Context-aware SVM for context-dependent information recommendation. *Proceedings of the 7th International Conference on Mobile Data Management*.
- OLCOS. (2007). *Open Educational Practices and Resources*. Salzburg, Austria: EduMedia Group.
- Oliveira, E. (2008). *MIC-Metodologias de Investigação Científica*. Obtido em 05 de 11 de 2012, de Faculdade de Engenharia da Universidade do Porto: [http://paginas.fe.up.pt/~eol/PRODEI/mic0809\\_files/Teorias.pdf](http://paginas.fe.up.pt/~eol/PRODEI/mic0809_files/Teorias.pdf)
- Oliveira, L., & Moreira, F. (2010). Integration of Web 2.0 applications and content management systems on personal learning environments. *5th Iberian Conference on Information Systems and Technologies (CISTI)*, (pp. 1-5).
- Oppermann, R. (3 de 1994). Adaptively supported adaptability. *Int. J. Hum.-Comput. Stud.*, 40(3), 455-472.
- Oravec, J. A. (4 de 2002). Bookmarking the world: Weblog applications in education. *Journal of Adolescent & Adult Literacy*, 45, pp. 616-621.
- Pan, R., & Scholz, M. (2009). Mind the gaps: Weighting the unknown. *SIGKDD conference on knowledge discovery and data mining*. ACM.
- Panniello, U., Tuzhilin, A., Gorgoglione, M., Palmisano, C., & Pedone, A. (2009). Experimental comparison of pre-vs. post-filtering approaches in context-aware recommender systems. *Proceedings of the 3rd ACM conference on Recommender systems* (pp. 265-268). ACM.
- Paterek, A. (2007). Improving regularized singular value decomposition for collaborative filtering. *Proceedings of the KDD Cup and Workshop*.
- Pazzani, M. J. (1999). A Framework for Collaborative, Content-Based and Demographic Filtering. *Artificial Intelligence Review*, 393-408.

- Pazzani, M. J., & Billsus, D. (2007). Content-Based Recommendation Systems. In P. Brusilovsky, A. Kobsa, & W. Nejdl (Edits.), *The Adaptive Web, LNCS 4321* (Vol. 4321, pp. 325-341). Springer Berlin / Heidelberg.
- Pazzani, M., Billsus, D., Michalski, S., & Wnek, J. (1997). Learning and Revising User Profiles: The Identification of Interesting Web Sites. In *Machine Learning* (pp. 313-331).
- Rafaëli, S., Dan-Gur, Y., & Barak, M. (2005). Social Recommender Systems: Recommendations in Support of E-Learning. *International Journal of Distance Education Technologies*, 29-45.
- Redecker, C. (2009). *Review of Learning 2.0 Practices: Study on the Impact of Web 2.0 Innovations on Education and Training in Europe*. European Commission Joint Research Centre Institute for Prospective Technological Studies .
- Resnick, P., & Varian, H. R. (3 de 1997). Recommender systems. *Communications of the ACM*, 40(3), 56-58.
- Resnick, P., Iacovou, N., Suchak, M., Bergstrom, P., & Riedl, J. (1994). GroupLens: an open architecture for collaborative filtering of netnews. *Proceedings of the 1994 ACM conference on Computer supported cooperative work* (pp. 175-186). Chapel Hill, North Carolina, United States: ACM.
- Ricci, F., Cavada, D., Mirzadeh, N., & Venturini, A. (2006). Case base querying for travel planning recommendation. In D. Fesenmaier, K. Woeber, & H. Werthner (Edits.), *Destination Recommendation Systems: Behavioural Foundations and Applications* (pp. 67-93).
- Ricci, F., Rokach, L., Shapira, B., & Kantor, P. B. (2010). *Recommender Systems Handbook*. New York, NY, USA: Springer-Verlag New York, Inc.
- Riordan, C. O., & Sorensen, H. (s.d.). Information Filtering and Retrieval: An Overview.
- Rocchio, J. (1971). Relevance Feedback in Information Retrieval.
- Rothery, Andrew, & Bell, V. (2006). E-Sharing: Developing Use of E-Repositories and E-Libraries for Learning and Teaching. *Is Information Technology Shaping the*

- Future of Higher Education Proceedings of the 12th International Conference of European University Information Systems* (pp. 123-129). Tartu, Estonia: University of Tartu, Estonia.
- Salakhutdinov, R., Mnih, A., & Hinton, G. (2007). Restricted Boltzmann machines for collaborative filtering. *ICML '07: Proceedings of the 24th international conference on Machine learning* (pp. 791-798). ACM.
- Salton, G., & McGill, M. J. (1986). *Introduction to Modern Information Retrieval*. McGraw-Hill, Inc.: New York, NY, USA.
- Sarker, S., & Wells, J. D. (2003). Understanding mobile handheld device use and adoption. *Communications of the ACM*, 46(12), 35-40.
- Sarwar, B. M., Karypis, G., Konstan, J. A., & Riedl, J. (2000). Analysis recommendation algorithms for E-commerce. *Proceedings of the ACM E-Commerce* (pp. 158-167). Minneapolis, Minn, USA: ACM.
- 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* (pp. 285-295). Hong Kong: ACM.
- Schafer, J. B., Konstan, J. A., & Riedl, J. (2001). E-Commerce Recommendation Applications. *Data Mining and Knowledge Discovery*, 5, 115-153.
- Schafer, J., Frankowski, D., Herlocker, J., & Sen, S. (2007). Collaborative filtering recommender. In P. Brusilovsky, A. Kobsa, & W. Nejdl (Edits.), *The adaptive web - Lecture Notes In Computer Science* (pp. 291-324). Springer Berlin / Heidelberg.
- Seitzinger, J. (31 de 7 de 2006). Be Constructive: Blogs, Podcasts, and Wikis as Constructivist Learning Tools. *Learning Solutions Magazine*, pp. 1-14.
- Seki, K., Matsui, T., & Okamoto, T. (2003). An Adaptive Sequencing Method of the Learning Objects for the e-Learning Environment. *IEICE Transactions on Information and Systems, Pt.1*, 330-344.
- Shani, G., & Gunawardana, A. (2009). Evaluating Recommendation Systems.

- Shardanand, U., & Maes, P. (1995). Social information filtering: algorithms for automating “word of mouth”. *Proceedings of the SIGCHI conference on Human factors in computing systems* (pp. 210-217). Denver, Colorado, United States: ACM Press/Addison-Wesley Publishing Co.
- Sheng, H., Siau, K., & Nah, F. F.-H. (5 de 2010). Understanding the values of mobile technology in education: a value-focused thinking approach. *SIGMIS Database*, 41, 25-44.
- Sheth, B., & Maes, P. (1993). Evolving Agents for Personalized Information Filtering. *Proceedings of the Ninth Conference on Artificial Intelligence for Applications* (pp. 345-352). IEEE Computer Society Press.
- Shih, C. (2011). *The Facebook Era 2nd Ed.* Prentice Hall.
- Smordal, O., Gregory, J., & Langseth, K. (2002). PDAs in medical education and practice. 2002. *Proceedings. IEEE International Workshop on Wireless and Mobile Technologies in Education*, (pp. 140-146).
- Stewart, C., Cristea, R., Brailsford, T., & Ashman, H. (2005). Authoring once, Delivering many’: Creating reusable Adaptive Courseware. *4th IASTED International Conference on Web-Based Education - WBE 2005*, (pp. 21-23). Grindelwald.
- Su, X., & Khoshgoftaar, T. M. (2009). A survey of collaborative filtering techniques. *Advances in Artificial Intelligence*.
- Su, X., Khoshgoftaar, T. M., Zhu, X., & Greiner, R. (2008). Imputation-boosted collaborative filtering using machine learning classifiers. *Proceedings of the 2008 ACM Symposium on applied computing* (pp. 949-950). New York: ACM.
- Szomszor, M., Cattuto, C., Alani, H., Baldassarri, A., Loreto, V., & Servedio, V. D. (2007). Folksonomies, the Semantic Web, and Movie Recommendation. *4th European Semantic Web Conference, Bridging the Gap between Semantic Web and Web 2.0.*, Innsbruck, Austria.
- Takács, G., Pilászy, I., Németh, B., & Tikk, D. (2008). Investigation of various matrix factorization methods for large recommender systems. *Proc. of the 2nd KDD*

*Workshop on Large Scale Recommender Systems and the Netflix Prize Competition.*

- Tang, T., & McCalla, G. (2005). Smart Recommendation for an Evolving E-Learning System: Architecture and Experiment. *International Journal on E-Learning*, 105-129.
- Tintarev, N., & Masthoff, J. (2007). Effective explanations of recommendations: user-centered design. *Proceedings of the 2007 ACM conference on Recommender systems* (pp. 153-156). Minneapolis, MN, USA: ACM.
- Toms, E. G. (2000). Serendipitous Information Retrieval. *Proceedings of DELOS Workshop: Information Seeking, Searching and Querying in Digital Libraries.*
- Tsai, K., Chiu, T., Lee, M., & Wang, T. (2006). A learning objects recommendation model based on the preference and ontological approaches. *Proc. of 6th International Conference on Advanced Learning Technologies (ICALT'06)*. IEEE Computer Society Press.
- Ullrich, C., Borau, K., Luo, H., Tan, X., Shen, L., & Shen, R. (2008). Why web 2.0 is good for learning and for research: principles and prototypes. *Proceedings of the 17th international conference on World Wide Web* (pp. 705-714). Beijing, China: ACM.
- União Europeia. (25 de 5 de 1998). *Sorbonne Joint Declaration*. Obtido em 12 de 6 de 2012, de de Bolonha: estabelecimento do Espaço Europeu do Ensino Superior: [http://www.ond.vlaanderen.be/hogeronderwijs/bologna/documents/MDC/SORBONNE\\_DECLARATION1.pdf](http://www.ond.vlaanderen.be/hogeronderwijs/bologna/documents/MDC/SORBONNE_DECLARATION1.pdf)
- União Europeia. (9 de 4 de 2010). *Processo de Bolonha: estabelecimento do Espaço Europeu do Ensino Superior*. Obtido em 12 de 06 de 2012, de Europa: [http://europa.eu/legislation\\_summaries/education\\_training\\_youth/lifelong\\_learning/c11088\\_pt.htm](http://europa.eu/legislation_summaries/education_training_youth/lifelong_learning/c11088_pt.htm)
- Vig, J., Sen, S., & Riedl, J. (2009). Tagsplanations: explaining recommendations using tags. *Proceedings of the 14th international conference on Intelligent user interfaces* (pp. 47-56). Sanibel Island, Florida, USA: ACM.

- Walker, A., Recker, M., Lawless, K., & Wiley, D. (2004). Collaborative information filtering: A review and an educational application. *International Journal of Artificial Intelligence in Education* , 3-28.
- Wan, L., Zhao, C., & Luo, Q. (2006). Navigation and Sequencing Strategy of Learning Process in Distance Learning Context . *36th ASEE/IEEE Frontiers in Education Conference* (pp. 25-29). San Diego, CA: IEEE.
- Wheeler, S. (12 de 7 de 2010a). *Physiology of a PLE*. Obtido em 29 de 4 de 2011, de steve-wheeler.blogspot.com: <http://steve-wheeler.blogspot.pt/2010/07/physiology-of-ple.html>
- Wheeler, S. (11 de 7 de 2010b). *Anatomy of a PLE*. Obtido em 29 de 04 de 2011, de steve-wheeler.blogspot.com: <http://steve-wheeler.blogspot.pt/2010/07/anatomy-of-ple.html>
- Wheeler, S., & Wheeler, D. (2007). Evaluating Wiki as a tool to promote quality academic writing skills. *ICL2007*, (pp. 1-7). Villach, Austria.
- Wiley, D. (18 de 11 de 2011). *Defining the "Open" in Open Content*. Obtido em 9 de 07 de 2012, de Open Content: <http://opencontent.org/definition/>
- Wu, H., & Bra, P. D. (2001). Sufficient Conditions for Well-Behaved Adaptive Hypermedia Systems. *Proceedings of the First Asia-Pacific Conference on Web Intelligence: Research and Development* (pp. 148-152). Springer-Verlag.
- Zapata, A., Menendez, V. H., Prieto, M., & Romero, C. (2011). A Hybrid Recommender Method for Learning Objects. *International Journal of Computer Applications*.
- Zhang, Y., Callan, J., & Minka, T. (2002). Novelty and redundancy detection in adaptive filtering. *Proc. of the 25th Annual Int. ACM SIGIR Conf. on Research and Development in Information Retrieval* (pp. 81-88). New York, NY, USA: ACM.
- Zitnick, C., & Kanade, T. (2004). Maximum entropy for collaborative filtering. *AUAI '04: Proc. of the 20th Conf. on Uncertainty in Artificial Intelligence* (pp. 636-643). AUAI Press.



# Apêndices

# Apêndice 1 - Modelo de Espaço Vetorial com a ponderação TF-IDF

A formulação matemática para a **similaridade cosseno entre as características de dois documentos**, que usa a similaridade entre dois vetores, é dada por:

$$\text{sim}(d_i, d_j) = \frac{\sum_k w_{k,i} \cdot w_{k,j}}{\sqrt{\sum_k w_{k,i}^2} \cdot \sqrt{\sum_k w_{k,j}^2}} \quad (1)$$

Em que:

$\text{sim}(d_i, d_j)$  representa a função similaridade entre dois documentos,  $i$  e  $j$  (nos SR aplicados quer aos perfil do utilizador como às características representativas dos itens, como aos próprios itens no caso de estes serem textuais)

$w_{k,j}$  representa a importância da palavra  $k$  no documento  $j$

$K$  representa o conjunto de todas as palavras do sistema

$$w_{k,j} = \frac{TF - IDF(t_k, d_j)}{\sqrt{\sum_{s=1}^T TF - IDF(t_s, d_j)^2}}$$

$$TF - IDF(t, d) = TF(t, d) * IDF(t)$$

$$TF(t, d) = \frac{f_{t,d}}{\max_z(f_{z,d})}$$

$TF(t, d)$ : mede a frequência da palavra ou termo  $t$  no documento  $d$

$f_{t,d}$  é o número absoluto de ocorrências da palavra  $t$  no documento  $d$

$\max_z(f_{z,j})$  é a frequência máxima determinada para todas as outras palavras,  $z$ , pertencentes ao documento  $d$

$$IDF(t) = \log \frac{N}{n(t)}$$

$N$  é o número de todos os documentos (recomendáveis)

$n(t)$ : número de documentos de entre os pertencentes a  $N$ , nos quais surge a palavra  $t$  pelo menos uma vez

## Apêndice 2 - Modelo Rocchio

A formulação matemática para a criação de um novo perfil:

$$P_{k+1} = P_k + \beta \sum_{K=1}^{n_1} \frac{R_k}{n_1} - \gamma \sum_{K=1}^{n_2} \frac{S_k}{n_2} \quad (2)$$

Em que:

$P_{k+1}$  é o novo perfil

$P_k$  é o perfil atual

$R_k$  é o vetor que representa um documento relevante  $k$

$S_k$  é o vetor que representa um documento não relevante  $k$

$n_1$  é o número de documentos relevantes

$n_2$  é o número de documentos não relevantes

$\beta$  é a ponderação do retorno positivo

$\gamma$  é a ponderação do retorno negativo

## Apêndice 3 – Cálculo da similaridade

A formulação matemática para o **coeficiente de correlação de Pearson** entre dois **utilizadores** é dada por:

$$w_{u,v} = \frac{\sum_{i \in I} (r_{u,i} - \bar{r}_u) \times (r_{v,i} - \bar{r}_v)}{\sqrt{\sum_{i \in I} (r_{u,i} - \bar{r}_u)^2} \times \sqrt{\sum_{i \in I} (r_{v,i} - \bar{r}_v)^2}} \quad (3)$$

Em que:

$w_{u,v}$  é o valor de correlação entre os utilizadores  $u$  e  $v$

$I$  representa o conjunto de itens que ambos os utilizadores classificaram

$\bar{r}_u$  é o valor médio de classificações que o próprio utilizador  $u$  já fez a outros itens

$r_{u,i}$  representa a avaliação do utilizador  $u$  ao item  $i$

Exemplo baseado na seguinte matriz de avaliações:

Matriz Avaliações	Item 1	Item 2	Item 3	Item 4	Item 5
<b>Utilizador Ativo</b>	1	3	3	2	
<b>Utilizador 1</b>	2	4	2	2	4
<b>Utilizador 2</b>	5	3	3	5	1
<b>Utilizador 3</b>	4	5	2	3	3
<b>Utilizador 4</b>	3	5	5	4	4

Similaridade entre utilizadores (Coeficiente de correlação de *Pearson*):

$$\bar{r}_{u_a} = \frac{9}{4} = 2,25; \bar{r}_{u_1} = \frac{14}{5} = 2,8; \bar{r}_{u_2} = 3,4; \bar{r}_{u_3} = 3,4; \bar{r}_{u_4} = 4,2;$$

$$w_{u_a, u_1} = \frac{(1-2,25) \times (2-2,8) + (3-2,25) \times (4-2,8) + (3-2,25) \times (2-2,8) + (2-2,25) \times (2-2,8)}{\sqrt{(1-2,25)^2 + (3-2,25)^2 + (3-2,25)^2 + (2-2,25)^2} \times \sqrt{(2-2,8)^2 + (4-2,8)^2 + (2-2,8)^2 + (2-2,8)^2}} = 0,49; w_{u_a, u_2} = -0,77; w_{u_a, u_3} = -0,13; w_{u_a, u_4} = 0,99.$$

A formulação matemática para a **similaridade cosseno entre utilizadores** usando o cálculo do cosseno do ângulo formado pelos vetores de frequências, é dada por:

$$w_{u,v} = \frac{\sum_{i \in I} r_{u,i} \times r_{v,i}}{\sqrt{\sum_{i \in I} r_{u,i}^2} \times \sqrt{\sum_{i \in I} r_{v,i}^2}} \quad (4)$$

Em que:

$w_{u,v}$  é o valor de similaridade entre os utilizadores  $u$  e  $v$ ;

$I$  representa o conjunto de itens que ambos os utilizadores,  $u$  e  $v$ , avaliaram;

$r_{u,i}$  representa a avaliação do utilizador  $u$  ao item  $i$

A formulação matemática para o **coeficiente de correlação de Pearson entre dois itens** é dada por:

$$w_{i,j} = \frac{\sum_{u \in U} (r_{u,i} - \bar{r}_i) \times (r_{u,j} - \bar{r}_j)}{\sqrt{\sum_{u \in U} (r_{u,i} - \bar{r}_i)^2} \times \sqrt{\sum_{u \in U} (r_{u,j} - \bar{r}_j)^2}} \quad (5)$$

Em que:

$w_{i,j}$  é o valor de correlação entre os itens  $i$  e  $j$

$U$  representa o conjunto de utilizadores que classificaram ambos os itens

$\bar{r}_i$  é o valor médio de classificações para o item  $i$  pelos utilizadores do conjunto

$U$

A formulação matemática para a **similaridade cosseno ajustada entre dois itens** é dada por:

$$w_{i,j} = \frac{\sum_{u \in U} (r_{u,i} - \bar{r}_u) \times (r_{u,j} - \bar{r}_u)}{\sqrt{\sum_{u \in U} (r_{u,i} - \bar{r}_u)^2} \times \sqrt{\sum_{u \in U} (r_{u,j} - \bar{r}_u)^2}} \quad (6)$$

Em que:

$w_{i,j}$  é o valor de correlação entre os itens  $i$  e  $j$

$U$  representa o conjunto de utilizadores que classificaram ambos itens  $i$  e  $j$

$\bar{r}_u$  é o valor médio de classificações do utilizador  $u$

$r_{u,i}$  é a avaliação ao item  $i$  feita pelo utilizador  $u$ , pertencente ao conjunto de utilizadores  $U$  que classificaram ambos itens,  $i$  e  $j$

Exemplo baseado na matriz de avaliações anterior:

$$\bar{r}_{u_a} = \frac{9}{4} = 2,25; \bar{r}_{u_1} = \frac{14}{5} = 2,8; \bar{r}_{u_2} = 3,4; \bar{r}_{u_3} = 3,4; \bar{r}_{u_4} = 4,2;$$

Similaridade entre itens:

$$w_{i_5, i_1} = \frac{(4-2,8)*(2-2,8)+(1-3,4)*(5-3,4)+(3-3,4)*(4-3,4)+(4-4,2)*(3-4,2)}{\sqrt{(4-2,8)^2+(1-3,4)^2+(3-3,4)^2+(4-4,2)^2} \times \sqrt{(2-2,8)^2+(5-3,4)^2+(4-3,4)^2+(3-4,2)^2}} = -0,79; w_{i_5, i_2} = 0,27; w_{i_5, i_3} = 0,08; w_{i_5, i_4} = -0,92.$$

A formulação do **coeficiente de Dice para a similaridade entre itens** baseada nos seus conteúdos, é dada por:

$$s(d_i, d_j) = \frac{2 \times |palavras(d_i) \cap palavras(d_j)|}{|palavras(d_i)| + |palavras(d_j)|} \quad (7)$$

Em que:

$s(d_i, d_j)$  mede a similaridade entre os documentos  $d_i$  e  $d_j$

$palavras(d_i)$  é o conjunto de palavras-chave presentes no documento  $d_i$

## Apêndice 4 – Cálculo da estimativa da classificação

A abordagem mais simples considera somente a média das classificações existentes e ignora os diferentes níveis de similaridade entre utilizadores.

$$p_{u,i} = \frac{1}{|V_i(u)|} \sum_{j \in V_i(u)} r_{j,i} \quad (8)$$

Em que:

$p_{u,i}$  é classificação estimada do item  $i$  para o utilizador  $u$

$V_i(u)$  é o conjunto de utilizadores, vizinhos mais próximos do utilizador  $u$ , que já avaliaram o item  $i$

$r_{j,i}$  é a classificação registada do item  $i$  pelo utilizador  $j$  (pertencente ao conjunto dos vizinhos mais próximos)

Considerando a similaridade entre utilizadores é usada a fórmula “Soma ponderada das avaliações dos outros utilizadores”:

$$p_{a,i} = \bar{r}_a + \frac{\sum_{u \in U} (r_{u,i} - \bar{r}_u) \times w_{a,u}}{\sum_{u \in U} |w_{a,u}|} \quad (9)$$

Em que:

$p_{a,i}$  é a predição da classificação do item  $i$  para o utilizador ativo,  $a$

$w_{a,u}$  é o valor de similaridade entre o utilizador  $a$ , e outro utilizador  $u$

$\bar{r}_a$  representa a média de classificações que o utilizador  $a$  já efetuou

$\bar{r}_u$  representa a média de classificações que o utilizador  $u$  já efetuou a todos os itens diferentes de  $i$

$w_{a,u}$  representa a ponderação da similaridade entre os utilizadores  $a$  e  $u$

$U$  representa o conjunto de todos os utilizadores, ou do conjunto dos seus  $k$  vizinhos mais próximos, que já avaliaram o item  $i$

Exemplo:

Considerando a matriz de avaliações do exemplo do apêndice 3 e o correspondente cálculo de similaridades entre utilizadores (pelo coeficiente de correlação de *Pearson*), a predição do item 5 para o utilizador ativo é a seguinte (considerando somente os 2,  $K=2$ , utilizadores vizinhos, mais similares,  $\{u_1, u_4\}$ ):

$$p_{a,i_5} = \bar{r}_a + \frac{\sum_{u \in \{u_1, u_4\}} (r_{u,i_5} - \bar{r}_u) \cdot w_{a,u}}{\sum_{u \in \{u_1, u_4\}} |w_{a,u}|} = 2,25 + \frac{(4-2,8) \times 0,49 + (4-4,2) \times 0,99}{(0,49+0,99)} = 2,51$$

Considerando a similaridade entre itens, é usada a fórmula “Média simples ponderada”:

$$p_{a,i} = \frac{\sum_{n \in N} r_{a,n} \times w_{i,n}}{\sum_{n \in N} |w_{i,n}|} \quad (10)$$

Em que:

$p_{a,i}$  é a predição da classificação do item  $i$  para o utilizador ativo,  $a$

$w_{i,n}$  é o valor de similaridade entre o item  $i$  e outro item  $n$

$r_{a,n}$  representa a classificação do utilizador ativo,  $a$ , ao item  $n$

$N$  representa o conjunto de todos os itens, ou o conjunto de  $k$  itens mais vizinhos (mais similares), que o utilizador ativo já avaliou

Exemplo:

Considerando a matriz de avaliações do exemplo do apêndice 3 e o correspondente cálculo de similaridades entre itens (pelo cosseno ajustado), a predição do item 5 para o utilizador ativo é a seguinte (considerando somente os 2,  $K=2$ , itens vizinhos, mais similares,  $\{i_2, i_3\}$ ):

$$p_{a,i_5} = \frac{\sum_{n \in \{i_2, i_3\}} r_{a,n} \cdot w_{i_5,n}}{\sum_{n \in \{i_2, i_3\}} |w_{i_5,n}|} = \frac{3 \times 0,27 + 3 \times 0,08}{(0,27+0,08)} = 3$$

## Apêndice 5 – Métricas de avaliação

Tabela - Classificação dos possíveis resultados de uma recomendação

ITEM	Recomendado	Não recomendado
Usado	Verdadeiro-Positivo (VP)	Falso-Negativo (FN)
Não usado	Falso-Positivo (FP)	Verdadeiro-Negativo (VN)

### Métricas de uso das recomendações

Quando as avaliações incidem sobre uma escala binária, ou transformada como tal (relevante ou não relevante, por exemplo) as medidas mais populares são a precisão e cobertura.

A medida Precisão mede a probabilidade de um item recomendado ser usado (ou selecionado). Esta medida permite aferir a precisão do processo de predição das preferências do utilizador. A sua formulação é a seguinte:

$$P = \frac{VP}{VP + FP} \quad (11)$$

Em que:

$VP$  representa o número de itens recomendados e selecionados

$FP$  representa o número de itens recomendados e não selecionados

$VP + FP$  representa o número de itens recomendados

Cobertura ou rácio dos verdadeiros-positivos – Indica quantos dos itens relevantes para o utilizador (seleccionados) foram recomendados pelo sistema, permitindo perceber a utilidade das recomendações apresentadas ao utilizador. Dito de outra forma, mede a probabilidade de um item seleccionado ser relevante. A sua formulação é a seguinte:

$$C = RVP = \frac{VP}{VP + FN} \quad (12)$$

Em que:

$VP$  representa o número de itens recomendados e seleccionados

$FN$  representa o número de itens seleccionados mas não recomendados

$VP + FN$  representa o número de itens seleccionados

A métrica  $F_1$  calcula a média harmónica da precisão e da cobertura, permitindo uma análise comparativa agregada mais fácil através de uma única métrica:

$$F_1 = 2 \cdot \frac{P \cdot C}{P + C} \quad (13)$$

O rácio dos verdadeiros-negativos indica-nos a percentagem de itens não recomendados que não são da preferência do utilizador, tendo por isso sido corretamente avaliados:

$$RVN = \frac{VN}{VN + FP} \quad (14)$$

Em que:

$VN$  representa o número de itens corretamente omitidos (não recomendados e não seleccionados)

$FP$  representa o número de itens recomendados e não seleccionados

$VN + FP$  representa o número de itens não seleccionados ou usados

O rácio dos falsos-positivos indica-nos a percentagem de itens não relevantes para os utilizadores, mas que foram recomendados pelo sistema:

$$RFP = \frac{FP}{FP + VN} \quad (15)$$

Em que:

$FP$  representa o número de itens recomendados e não selecionados

$VN$  representa o número de itens corretamente omitidos (não recomendados e não selecionados)

$FP + VN$  representa o número de itens não selecionados ou usados

A métrica Exatidão indica-nos a percentagem dos itens que foram bem classificados, permitindo-nos ter um indicador geral exatidão do sistema:

$$E = \frac{VP + VN}{VP + VN + FP + FN} \quad (16)$$

Em que:

$VP$  representa o número de itens recomendados e selecionados

$VN$  representa o número de itens corretamente omitidos (não recomendados e não selecionados)

$VP + VN$  representa o número de itens corretamente selecionados porque foram recomendados e que forma corretamente não selecionados porque não foram recomendados

$FP$  representa o número de itens recomendados e não selecionados

$FN$  representa o número de itens selecionados mas não recomendados

$VP + VN + FP + FN$  representa o número total de itens (selecionados ou não)

## Métricas de Precisão da Predição

Quando a escala de avaliações possuem diversos valores, são normalmente usadas as medidas de taxa de erro.

A medida MAE (do inglês: “Mean Absolute Error”) mede a média das diferenças absolutas entre as estimativas de recomendação (propostas pelo SR) e os valores reais recolhidos pelos utilizadores, relativamente à avaliação dos itens. Tem a seguinte formulação:

$$MAE = \frac{\sum_{i=1}^N |p_i - r_i|}{N} \quad (17)$$

Em que:

$p_i$  é a avaliação estimada pelo SR

$r_i$  é a avaliação real verificada pelo utilizador

$N$  é o conjunto total de pares de valores existentes de  $p_i$  e  $r_i$

A medida RMSE (do inglês: “Root Mean Square Error”) é similar à medida MAE, mas dá uma maior ênfase às diferenças maiores entre as avaliações, estimada e real.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (p_i - r_i)^2} \quad (18)$$

### Métricas de Precisão das Listas (posição)

A métrica Rank Score é um rácio entre o posicionamento verificado dos itens e o melhor posicionamento teórico possível:

$$rank\ score = \frac{\sum_{i \in h} 2^{-\frac{posição(i)-1}{\alpha}}}{\sum_{i=1}^T 2^{-\frac{i-1}{\alpha}}} \quad (19)$$

Em que:

$h$  é o conjunto de itens recomendados selecionados

$posição$  é o número indicativo da ordem do item na lista

$T$  é o conjunto de todos os itens relevantes

$\alpha$  é um fator exponencial de redução (“*ranking half life*”)

A métrica “*Lift index*” divide a lista de posições em 10 decis iguais e pondera as seleções com base na seguinte formulação:

$$liftindex = \begin{cases} \frac{1.S_1 + 0,9.S_2 + \dots + 0,1.S_{10}}{\sum_{i=1}^{10} S_i} & \text{se } |h| > 0 \\ 0 & \text{noutros casos} \end{cases} \quad (20)$$

Em que:

$h$  é o conjunto de itens recomendados selecionados

$$\sum_{i=1}^{10} S_i = |h|$$

O grupo de métricas de ganho acumulado (CG, do inglês “Cumulative Gain”) inclui várias medidas, tais como a DCG (“Discount Cumulative Gain”) e a nDCG (“normalized Discount Cumulative Gain”). A ideia principal destas medidas é acumular o valor de classificação real dos itens recomendados (quanto maior for esse ganho acumulado, mais interessante será a lista de itens para o utilizador). A medida DCG reduz a relevância de cada item de acordo com uma função logarítmica, valorizando mais os primeiros itens e valorizando menos os últimos. A medida nDCG consiste no rácio entre o ganho acumulado e o ganho ideal, resultando num valor entre 0 e 1.0. A formulação da medida DCG é a seguinte:

$$DCG_p = rel_1 + \sum_{i=2}^{pos} \frac{rel_i}{\log_2 i} \quad (21)$$

Em que:

$DCG$  é o ganho acumulado com desconto

$rel_i$  é a relevância (classificação real do item) da recomendação da posição  $i$

$pos$  representa o número de itens na lista

## Apêndice 6 – Questionário de avaliação

Questão	Tipo de Resposta
1. Considera importante que um aluno possa publicar conteúdos para os seus colegas (tal como o professor faz)?	Escala <i>Likert</i> 1-5
2. Considera relevante a funcionalidade que permite definir os pré-requisitos?	Escala <i>Likert</i> 1-5
3. Considera relevante que o aluno possa indicar o nível de satisfação e o tempo de estudo após conclusão de cada conteúdo?	Escala <i>Likert</i> 1-5
4. Considera relevante que os alunos possam definir um perfil que influenciará a estratégia de recomendações?	Escala <i>Likert</i> 1-5
5. Considera o sistema de recomendação fácil de usar?	Escala <i>Likert</i> 1-5
6. Considera que este sistema pode ajudar o aluno na seleção de conteúdos, designadamente quando o seu número é elevado (por exemplo, mais de 300)?	Escala <i>Likert</i> 1-5
7. Deixou de selecionar algum conteúdo por este ter sido publicado por outro aluno?	Sim/Não
8. Quando selecionava os conteúdos, considerava a estimativa de avaliação calculada pelo sistema de recomendação?	Sim/Não
9. Quando selecionava os conteúdos, considerava o tempo de estudo indicado pelo sistema de recomendação?	Sim/Não
10. Compreendeu que o seu registo dos valores de nível de satisfação e tempo de estudo influenciava as próximas recomendações para os outros alunos?	Sim/Não
11. Ordene por ordem crescente de importância os seguintes critérios, quando faz as escolhas para selecionar os conteúdos: a) Valor estimado de nível de satisfação; b) Ser um novo conteúdo; c) Tipo de relacionamento; d) Número de seleções; e) Média do nível de satisfação; f) Média do tempo de estudo; g) Tempo de estudo de defeito	Ordem



---

**Contactos:**

Universidade de Évora  
**Instituto de Investigação e Formação Avançada - IIFA**  
Palácio do Vimioso | Largo Marquês de Marialva, Apart. 94  
7002-554 Évora | Portugal  
Tel: (+351) 266 706 581  
Fax: (+351) 266 744 677  
email: [iifa@uevora.pt](mailto:iifa@uevora.pt)