

Estratégia Híbrida de Recomendações sobre um Gestor de Conteúdos Ampliado em Ensino Formal

CAPSI'2012

Filipe Montez Coelho Madeira¹, Rui Filipe Cerqueira Quaresma², Salvador Pinto Abreu³

1) Instituto Politécnico de Santarém, Santarém, Portugal

filipe.madeira@esg.ipsantarem.pt

2) Universidade de Évora, Évora, Portugal

quaresma@uevora.pt

3) Universidade de Évora, Évora, Portugal

spa@di.uevora.pt

Resumo

Este artigo tem por objetivo apresentar um Modelo para Recomendação Personalizada de conteúdos de aprendizagem, baseado numa estratégia de recomendação híbrida e no perfil de cada aluno. Incluímos uma proposta para a similaridade entre alunos que reflete os seus interesses em termos das avaliações pretendidas e da proximidade das sequências de atividades de aprendizagem dos diversos alunos. Este modelo prevê, igualmente, a inclusão de novos conteúdos por parte dos alunos e a definição de relacionamentos com os conteúdos existentes. São abordadas as motivações que nos levaram à presente proposta, alguns conceitos e trabalhos relacionados, assim como a arquitetura e desenho da solução, entretanto alvo de protótipo. Por fim são tecidas algumas conclusões.

Palavras-chave: Personalização da Sequenciação de Atividades de Aprendizagem, Relacionamento entre Conteúdos, Sistema de Recomendação, Filtragem Colaborativa, Aprendizagem Colaborativa, Ensino Formal, *Moodle*.

1. Introdução

As inovações tecnológicas e a consistente investigação e experimentação de novos métodos e técnicas conduzem a aprendizagem para novos cenários onde o espaço e o tempo assumem diferentes significados. Com a Internet, a disponibilização abundante de recursos educativos tornou-se uma realidade e torna árdua a sua seleção. Com as aplicações sociais, as redes de relacionamentos ficaram maiores e mais fáceis de criar e manter. Com a computação na nuvem, vai ser mais fácil aceder aos recursos (no tempo, no espaço e usando múltiplos dispositivos terminais). O ensino à distância (mesmo como complemento do ensino presencial) tem assumido relevância crescente.

Outra tendência do ensino é a centralização do processo de aprendizagem no próprio aluno, onde o conhecimento é criado ou construído pelo próprio e não como resultado, essencialmente, da sua transmissão [Seitzinger 2006]. Neste ambiente assente na colaboração, na participação social (como fator motivador) e na interatividade entre os vários agentes, o conhecimento surge como resultado de uma construção social, referenciada no modelo de aprendizagem construtivista [Sheng et al. 2010]. A centralização da aprendizagem no aluno modifica o papel

do professor e das organizações de ensino. Novas tecnologias, novas práticas pedagógicas e novas ferramentas de suporte são exigidas. Diferentes alunos, com diferentes características, competências, disponibilidades e objetivos, procuram a aprendizagem que lhes seja mais adequada. Diferentes conteúdos e diferentes caminhos de aprendizagem (sequenciamento das suas atividades) são alguns dos requisitos para que tal possa acontecer.

A preocupação central deste artigo é a maximização da aprendizagem, num contexto formal, no Ensino Superior, em que é normal existir um conjunto de conteúdos preparados e/ ou sugeridos pelos professores que lecionam um dado módulo (ou unidade curricular) de um curso, de suporte e como complemento à formação presencial. 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 web, 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 existentes e em uso.

Como resposta a algumas das limitações acima referidas, propomos uma solução que permite a inclusão de novos conteúdos pelos alunos, junto 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 o uso de uma estratégia de recomendações híbrida que combina técnicas de recomendação personalizadas com o perfil de cada aluno.

Em seguida, na secção 2, são apresentados alguns trabalhos relacionados com a adaptabilidade dos sistemas de apoio ao ensino, incluindo a referência a sistemas de recomendação usados no mesmo âmbito. Na secção 3 apresenta-se um modelo para um gestor de conteúdos ampliado adaptado à inclusão de novos conteúdos e à recomendação personalizada dos mesmos. Faz-se ainda uma breve descrição do ambiente e plataforma de desenvolvimento do protótipo, que irá ser usada na avaliação experimental e cujos resultados pretendemos publicar oportunamente. Finalmente, na última secção são apresentadas as considerações finais e o trabalho futuro.

2. Enquadramento Conceptual e Trabalhos Relacionados

Iniciamos esta secção com a descrição de alguns conceitos relacionados com a sequenciação e navegação em sistemas de ensino mais ou menos adaptativos. Depois abordamos o desenho de sistemas adaptativos de suporte ao ensino e de seguida são referidos alguns trabalhos que procuraram estudar o efeito da interação social nas escolhas dos alunos. Por fim, abordamos os sistemas de recomendação e a aplicabilidade de alguns desses sistemas no suporte à aprendizagem.

2.1 Sequenciação e Navegação Adaptativas

Os conceitos de sequenciação e navegação associados aos conteúdos de aprendizagem são temas que merecem a atenção de investigadores e entidades de normalização. Embora com diferentes definições, 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.

As normas *SCORM Sequencing and Navigation* [Advanced Distributed Learning 2009] e *IMS Simple Sequencing Specification* [IMS-SS 2003] constituem dois trabalhos relevantes das organizações de normalização, para os implementadores de sistemas de gestão de aprendizagem, que visam a normalização da representação e codificação do sequenciamento dos

objetos de aprendizagem e dos eventos de navegação a suportar por esses sistemas. O processo de sequenciamento pode ser assente em modelos estáticos ou adaptativos. Nos primeiros, é no desenho do curso (ou do evento de aprendizagem) que são estabelecidos os possíveis sequenciamentos (com as regras que os determinam) que cada aluno poderá seguir. Nestes modelos estáticos, 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.

2.2 Sistemas Adaptativos

Sobre os modelos adaptativos, [Oppermann 1994] refere que os sistemas hipermedia adaptativos para o ensino devem ser capazes de “adaptar as suas próprias características automaticamente de acordo com as necessidades dos utilizadores”. 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. A combinação destas diferentes formas surge em diversos trabalhos. 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.

Alguns dos sistemas hipermedia educativos considerados adaptativos foram inspirados na arquitetura AHAM - Adaptive Hypermedia Application Model [De Bra et al. 1999]. Esta arquitetura sugere vários modelos. O modelo domínio considera os objetivos de aprendizagem e os correspondentes conceitos associados a esses objetivos. No modelo utilizador é implementado o estado do conhecimento do aluno. No gestor de conteúdos são guardados os conteúdos educativos, as relações (de dependência) entre eles e os conceitos associados. É no modelo adaptativo que, com recurso a regras, são determinados os conceitos necessários para o aluno assim como os correspondentes conteúdos a usar. O sucesso da adaptabilidade deste modelo está na correta e completa definição das regras de adaptação, uma vez que a existência de inconsistências e lacunas nas regras poderá gerar sequências incompletas de conceitos. [Luis De-Marcos et al. 2009] usaram regras combinadas com algoritmos de otimização para geração de sequenciamento adaptativo. Outras soluções excluem as regras e baseiam-se somente em algoritmos [Seki et al. 2003; Karampiperis e Sampson 2005], ou recorrem a avaliações aos alunos em diferentes etapas da aprendizagem para se tornarem adaptativos [Madjarov e Betari 2008; Lin et al. 2009].

2.3 Interação Social

A influência do comportamento e das contribuições de outros utilizadores, sejam eles alunos ou professores, nos sistemas educativos tem vindo a aumentar, potenciadas pelas tecnologias Web2.0, onde os conteúdos são criados, alterados, partilhados, anotados e classificados pelos seus utilizadores. Esta tendência tem impulsionado o surgimento de redes 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/>). A interação social como fator influenciador do sequenciamento dinâmico das atividades de aprendizagem, tem vindo a ser abordada nalguns trabalhos, quer considerando as interações dentro de um grupo [Iglesias et al. 2004], quer propondo as próximas atividades concluídas com sucesso por outros alunos [Koper 2005], como recorrendo a anotações (indicação de quantos alunos já realizaram e quantos terminaram com sucesso uma dada atividade) [Gutiérrez e Pardo 2007], entre outros exemplos de aplicação.

2.4 Sistemas de Recomendação

Os sistemas de recomendação também se baseiam na interação social. São muito usados na Internet nos atuais sistemas de vendas de livros, filmes, músicas, entre outros artigos. O seu principal objetivo é o de filtrar a informação que poderá ter interesse para cada utilizador. Baseiam-se essencialmente no comportamento de outros utilizadores (com mensagens tipo: "quem comprou este artigo, também comprou os seguintes...") e incluem vulgarmente informações tais como classificações e etiquetas ('tags') sobre os itens que pretendem recomendar. O modo como a informação é filtrada permite distinguir entre duas abordagens principais: filtragem cognitiva ou baseada em conteúdos e filtragem colaborativa ou social. A combinação destas técnicas, eventualmente com outras não colaborativas, origina soluções designadas por híbridas. As recomendações colaborativas (sociais) baseiam-se em itens que outros utilizadores considerados similares (gostos, preferências, situações, ...) avaliaram no passado ("diz-me o que é popular entre os meus pares"). Quando baseadas no conteúdo dos itens, as recomendações usam as características desses itens que foram selecionados anteriormente e do perfil do utilizador para aferir similaridades e propor sugestões ("mostra-me mais do que eu gosto, baseado naquilo que foram os meus gostos no passado"). As soluções híbridas procuram melhorar a fiabilidade do sistema e resolver as desvantagens da utilização de uma só técnica de recomendação. Certos estudos defendem que as estratégias híbridas produzem recomendações mais fiáveis quando comparadas com o uso isolado de uma só técnica de recomendação [Melville et al. 2002; Pazzani 1999; Soboro e Nicholas 2000].

No domínio das tecnologias de suporte ao ensino, foram propostos diversos sistemas de recomendação de conteúdos de aprendizagem, que usam dados obtidos de forma explícita ou implícita. O sistema Altered Vista [Walker et al. 2004] faz recomendações de endereços web avaliados por professores e alunos. No sistema de filtragem colaborativa de [Rafaeli et al. 2004] é possível selecionar os utilizadores de quem se aceita recomendações. Algumas propostas usam múltiplos critérios para efetuar a filtragem colaborativa [Manouselis et al. 2007]. Vários optaram por sistemas híbridos [Tang e McCalla 2005; Drachsler et al 2008].

Outras áreas de investigação relacionadas com os sistemas de recomendação comparam a sua utilização no suporte à aprendizagem com a sua aplicação noutros domínios [Drachsler et al. 2009], em ambientes informais e formais de ensino [Manouselis et al. 2010] e propõem modelos para avaliação da sua aplicabilidade [Herlocker et al. 2004].

3 Estratégia Híbrida de Recomendações sobre um Gestor de Conteúdos Ampliado em Ensino Formal

O sistema proposto contempla um subsistema que permite a adição de novos conteúdos por parte dos alunos onde habitualmente só os professores o fazem (num sistema de suporte à aprendizagem em ensino formal) e um outro que propõe recomendações aos conteúdos ainda não realizados pelos alunos (ver figura 1).

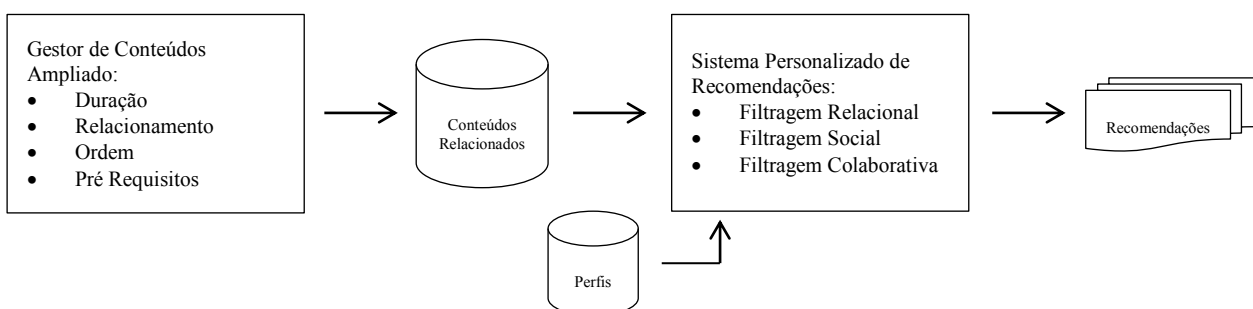


Figura 1 – Arquitetura do modelo proposto

De realçar que num ensino formal, os alunos ao inscreverem-se 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 foram igualmente consideradas nos requisitos que existirão no acesso a esse curso (condições de acesso ao ensino superior, eventuais frequências de outras unidades curriculares, módulos, etc.). 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. Neste artigo, por conteúdo, consideramos um conceito amplo, mais próximo da atividade de aprendizagem, podendo representar um documento, um endereço para um recurso alojado na web, um questionário, uma ficha de exercícios, etc..

3.1 Gestor de Conteúdos Ampliado

A ampliação do gestor de conteúdos é conseguida num processo com várias fases, que se inicia com a submissão dos novos conteúdos, a definição de uma proposta para a sua ordem no sequenciamento, a indicação de pré-requisitos ou precedências formais (para outros conteúdos), o estabelecimento opcional do seu relacionamento com outros conteúdos, a sua validação e final publicação (ver figura 2).




Figura 2 – Fases da Publicação de Novos Conteúdos

Todas as 4 fases correspondem a funcionalidades acessíveis a professores. Os alunos têm acesso às funcionalidades das fases 1 e 2 (embora não definam a ordem dos conteúdos nem possam indicar eventuais conteúdos pré-requisitos). O relacionamento entre conteúdos permitirá assinalar conteúdos melhorados, complementares ou opcionais o que facilita a identificação de todos os conteúdos associados a um mesmo tópico. Quem publica o conteúdo indica uma estimativa do tempo de estudo necessário para esse conteúdo. Só após aprovação, os novos conteúdos ficam disponíveis para publicação e posterior acesso.

3.2 Sistema de Recomendações Híbrido

Um dos argumentos importantes para a nossa proposta 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. O subsistema de apoio ao aluno tem como propósito recomendar a cada aluno e em cada etapa da sua aprendizagem uma lista ordenada dos conteúdos ainda não efetuados, por ordem decrescente de relevância. Para tal, propomos uma estratégia de recomendações híbrida, em cascata, onde cada técnica de recomendação vai refinando as recomendações da anterior (ver figura 3). A lista final ordenada tenta prever ou estimar a classificação dos conteúdos que ainda não foram abordados e 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 .

As técnicas de recomendação são baseadas nos interesses dos alunos, referidos no seu perfil. Neste perfil de aluno consideramos o nível de satisfação mínimo (numa escala de 1 a 5), a duração máxima de estudo, a dimensão da cadeia de sequenciamento (ou seja, quais e quantos os conteúdos anteriormente selecionados, bem como a sua ordem de seleção) e a avaliação mínima desejável dos outros alunos, os quais cada aluno pretende privilegiar em termos de recomendação. Consideramos que estes valores devem ser explicitados por cada aluno no seu

perfil e não determinados ou inferidos implicitamente a partir da utilização do sistema. Um aspeto relevante está relacionado com o significado dos valores do perfil de cada aluno, já que estes refletem os seus interesses e não o seu perfil de utilização. Por exemplo, o facto de um aluno ter uma duração média de estudo de 30 minutos para cada conteúdo não significa que ele não tenha disponibilidade e interesse em ocupar mais tempo com cada conteúdo, pelo que no seu perfil poderá definir uma duração muito superior.

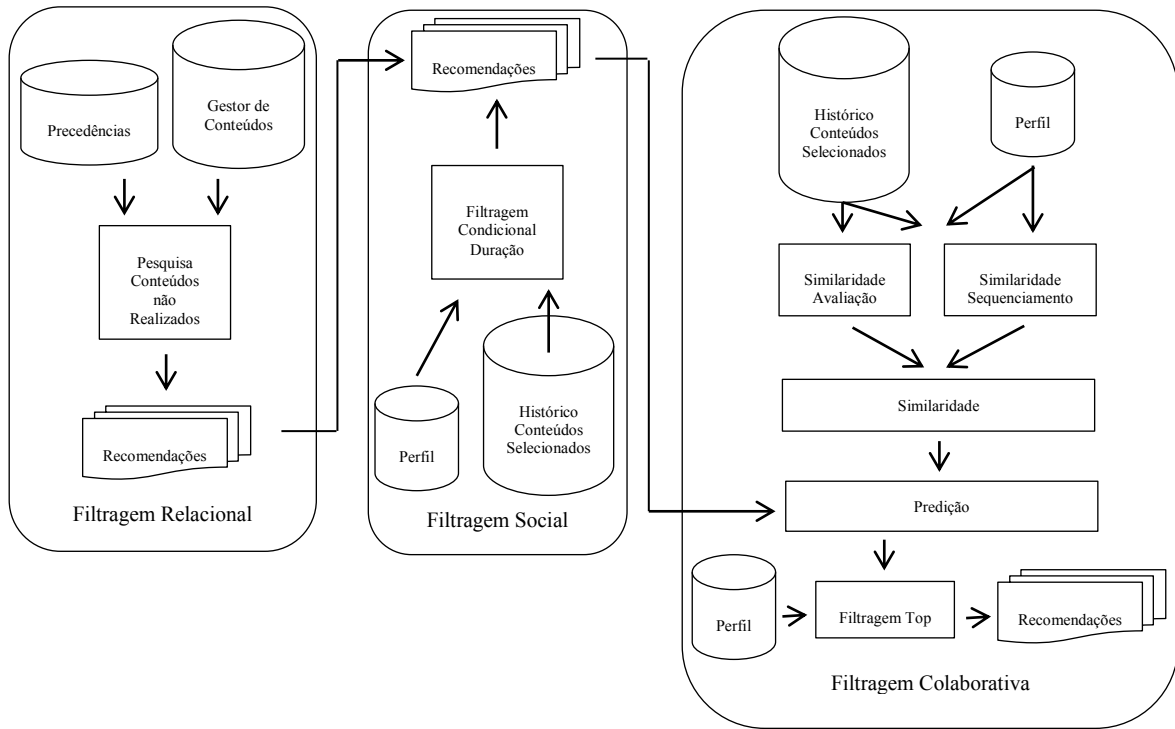


Figura 3 – Estratégia Híbrida de Recomendação

Antes de obter uma nova recomendação, é verificado se não existem conteúdos por finalizar, por parte do aluno requerente. Verificada essa condição, é iniciada a filtragem relacional onde são determinados os conteúdos não realizados, por interrogação direta ao gestor de conteúdos. Por exemplo, da tabela 1, a lista de conteúdos resultante, nesta fase, para o aluno a_1 , é formada pelos conteúdos $\{c_3, c_5, c_6\}$.

| Aluno (perfil) | Conteúdos | | | | | | Sequência | Avaliação |
|----------------------------------|-----------------------|-----------------------|-----------------------|-----------------------|-----------------------|-----------------------|----------------------|-----------|
| | c_1 (d=50, sl=3) | c_2 (d=30, sl=4) | c_3 (d=60, sl=4) | c_4 (d=40, sl=4) | c_5 (d=50, sl=4) | c_6 (d=50, sl=5) | | |
| a_1 (d=55, sl=4, g=17, n=3) | d=50, sl=4 | d=20, sl=5 | | d=40, sl=3 | | | c_1, c_2, c_4 | 14 |
| a_2 (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_5, c_1, c_2, c_4 | 13 |
| a_3 (d=30, sl=4, g=15) | d=60, sl=3 | | | d=40, sl=3 | d=60, sl=5 | | c_4, c_1, c_5 | 15 |
| a_4 (d=40, sl=4, g=14) | | d=60, sl=3 | | d=40, sl=3 | d=40, sl=5 | d=45, sl=4 | c_5, c_6, c_2, c_4 | |

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

Tabela 1 – Lista de conteúdos selecionados pelos alunos

Na fase 2, 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 (filtragem social). Como solução para o problema existente quando um dado conteúdo ainda não tiver sido selecionado, inclui-se a duração sugerida (se o tiver sido) pelo autor (professor ou aluno) na publicação do conteúdo, no cálculo dessa média. No caso em que a duração estimada não tenha sido indicada pelo professor ou aluno, nem o respetivo conteúdo tenha sido selecionado, a nossa opção foi manter a sua inclusão na lista. A lista que resulta só inclui os conteúdos com uma duração média inferior ou igual à duração definida no perfil do aluno. A duração média de um dado conteúdo c (\bar{d}_c), é obtida pela seguinte formulação:

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

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. Para o exemplo da tabela 1 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, 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 seria composta pelos conteúdos $\{c_5, c_6\}$.

A etapa seguinte (fase 3) inicia-se com o cálculo do valor de similaridade entre os alunos (definido entre um mínimo de 0 e um máximo de 1). O modelo propõe uma avaliação multicritérios, com ponderação igual para cada uma das duas métricas consideradas, a avaliação e o tamanho da sequência de conteúdos. No primeiro caso, a avaliação definida no perfil do aluno estabelece a avaliação mínima desejável para os outros alunos. Para os alunos com uma avaliação superior ou igual é-lhes atribuído o máximo valor de similaridade. Abaixo da avaliação definida, a métrica considera a seguinte formulação:

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

Em que: $sim^g_{a_i, a_j}$ 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 e g_j é a avaliação que o aluno a_j obteve. Considerando o nosso exemplo da tabela 1, $sim^g_{a_1, a_2} = 0,76$ [$1 - (17-13)/17$]; 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 segunda métrica usa o tamanho da sequência definida no perfil do aluno. Consideramos que a seleção dos mesmos conteúdos e pela mesma ordem, no passado, confere uma maior proximidade entre os alunos. O valor n definido no perfil de cada aluno estabelece relativamente ao último conteúdo estudado, quantos e quais os anteriores conteúdos que serão considerados na avaliação da métrica. Assim, um outro aluno que tenha selecionado exatamente os mesmos n conteúdos e exatamente pela mesma ordem, em qualquer posicionamento na sua sequência total de aprendizagem, terá uma similaridade máxima. Para um novo aluno, sem conteúdos selecionados, esta métrica não é calculada. A formulação completa desta métrica é a seguinte:

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

Em que: $sim^s_{a_i, a_j}$ é a métrica que avalia a similaridade-sequencia entre os alunos a_i e a_j ;

$$\Delta(c_{k,j}) = \begin{cases} 1 & pos_j(c_{k+1,i}) - pos_j(c_{k,i}) = 1; \exists c_{k,j} \\ 0 & \text{noutros casos} \end{cases}; \exists c_{k,j} = \begin{cases} 1 & \text{se } c_k \text{ tiver sido selecionado por } a_j \\ 0 & \text{noutros casos} \end{cases}$$

$\Delta(c_{k,j})$ 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 . Considerando novamente o exemplo da tabela 1, a similaridade-sequencia 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 $sim^s_{a_1,a_4} = \frac{2+1}{5} = 0,6$

A similaridade total entre dois alunos é obtida pela média aritmética de ambas as métricas, ou pelo valor da outra métrica quando uma for nula.

Considerando o exemplo da tabela 1, $sim_{a_1,a_2} = 0,88$, $sim_{a_1,a_3} = 0,64$ e $sim_{a_1,a_4} = 0,6$.

Por fim, para concluir a fase de filtragem colaborativa, pretende-se, para os conteúdos da lista resultante da fase 2, determinar a predição do nível de satisfação para o aluno a_i . Para a obter, usamos a função habitual das técnicas *memory-based* [Breese et al. 1998]:

$$p_{a_i,c_k} = \begin{cases} \overline{sl}_{a_i} + \frac{\sum_{j \in J} (sl_{a_j,c_k} - \overline{sl}_{a_j}) * sim_{a_i,a_j}}{\sum_{j \in J} sim_{a_i,a_j}} & \text{se } \overline{sl}_{a_i} \neq 0 \\ \frac{\sum_{j \in J} (sl_{a_j,c_k} * sim_{a_i,a_j})}{\sum_{j \in J} sim_{a_i,a_j}} & \text{se } \overline{sl}_{a_i} = 0 \\ sl_{prof,c_k} & \text{se } \sum_{j \in J} sl_{a_j,c_k} = 0 \text{ Ou } p_{a_i,c_k} = 0 \end{cases} \quad (5)$$

Em que: p_{a_i,c_k} é a predição do nível de satisfação para o aluno 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 e \overline{sl}_{a_j} é a média dos níveis de satisfação do aluno a_j . Considerando o exemplo da tabela 1, $p_{a_1,c_5} = 4 + \frac{((3-3) * 0,88) + ((5-3,67) * 0,64) + ((5-3,75) * 0,6)}{(0,88 + 0,64 + 0,6)} = 4,75$ e $p_{a_1,c_6} = 4,08$.

Na formulação (5) estão previstas várias situações de arranque, quando um novo aluno ainda não efetuou nenhuma avaliação, um novo conteúdo ainda não foi avaliado, ou ainda nos casos em que o valor obtido tenha sido nulo. Nesses casos consideramos para predição do nível de satisfação de um dado conteúdo, o valor atribuído pelo professor.

Do exemplo da tabela 1, $p_{a_1,c_3} = 4$ (nível de satisfação atribuído pelo professor).

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 acima ou igual ao indicado no perfil serão apresentados ao aluno. 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.

Para o nosso exemplo, 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.

3.3 Protótipo

Foi efetuado um protótipo que consistiu no desenvolvimento de um módulo sobre o sistema de gestão de aprendizagem Moodle (versão 2.2.1), usando o servidor web Apache (versão 2.2.21), o sistema de gestão de base de dados MySQL (versão 3.4.9) e a linguagem de programação PHP (versão 5.3.8). Estamos em fase de testes sobre o sistema desenvolvido e pretendemos iniciar a sua avaliação experimental a muito curto termo, num ambiente real de Ensino Superior.

4 Considerações Finais e Trabalho Futuro

Este artigo descreve um sistema virtual de aprendizagem a aplicar num ambiente formal, que prevê a inclusão de conteúdos por parte de alunos. Propomos ainda que os conteúdos possam ser relacionados entre si. Para manter o controlo sobre a aprendizagem de cariz mais formal, a publicação e divulgação dos novos conteúdos fica dependente da aprovação pelos professores responsáveis. A manutenção dos conteúdos e da informação que lhes é associada, por vários anos (periodicidade superior à habitual semestralidade existente em ambientes formais no Ensino Superior), vai permitir por um lado, termos mais conteúdos e, por outro, poder reutilizar os dados das interações dos alunos que frequentaram o curso em períodos anteriores. Consideramos ainda que este sistema ampliado, onde o próprio aluno inclui novos conteúdos, trará motivação à aprendizagem sem descaracterizar o atual modelo presencial. Em resumo, consideramos aspetos diferenciadores a possibilidade de inclusão de novos conteúdos pelos alunos, o tipo de relacionamentos entre conteúdos e a reutilização de conteúdos e informações associadas.

Como suporte à decisão do aluno num sistema com um amplo número de conteúdos, potenciando a adequação das suas escolhas aos seus interesses, propomos um modelo baseado numa estratégia de recomendação híbrida que considera alguns dados do seu perfil (duração, sequenciamento, nível de satisfação dos conteúdos e avaliação dos alunos). Entendemos que os critérios que incluímos no perfil não constituem uma solução única, mas antes uma solução personalizada, que pretendemos testar como solução dinamizadora de diferentes sequenciamentos e de experiências únicas de aprendizagem. Existirão, certamente, outros critérios que podem ser incluídos na estratégia de recomendação, como por exemplo, o nível de dificuldade dos conteúdos ou a sua validade. O principal aspeto diferenciador da estratégia de recomendação adotada é a proposta para a similaridade entre alunos, que reflete os interesses do aluno (perfil) no cálculo das métricas similaridade-avaliação (maior valorização dos alunos com avaliações superiores ou iguais às definidas no seu perfil) e similaridade-sequenciamento (onde é valorizado a realização dos mesmos conteúdos e a ordem com que estes foram realizados).

Pretendemos com este trabalho analisar o nível de envolvimento do aluno na publicação de novos conteúdos, a diversidade de caminhos seguidos pelos vários alunos e a utilidade das técnicas de recomendação propostas. Interessa-nos igualmente testar o comportamento das métricas propostas, analisar, medir e avaliar sobre a sua adequabilidade e sobre a qualidade das predições (através de métricas, tais como a *Mean Absolute Error*). Iremos procurar otimizar o modelo proposto ou pelo menos identificar as suas limitações. A próxima etapa deste estudo será a avaliação experimental do protótipo num caso real.

5 Referências

- Advanced Distributed Learning (ADL), *Sharable Content Object Reference Model (SCORM®) 2004 4th Edition Sequencing and Navigation (SN)*, Version 1.1, 2009.
- Breese, J. S., Heckerman, D. e Kadie, C., “Empirical Analysis of Predictive Algorithm for Collaborative Filtering”, *Proceedings of the 14 th Conference on Uncertainty in Artificial Intelligence*, (1998), 43-52.
- De Bra, P., Houben, G. J., e Wu, H., “AHAM: A Dexter based Reference Model for Adaptive Hypermedia”, *ACM Conference on Hypertext and Hypermedia*, (1999), 147-156.
- Drachsler H., Hummel H. G. K., Koper R., “Personal recommender systems for learners in lifelong learning: requirements, techniques and model”, *International Journal of Learning Technology*, 3, 4 (2008), 404-423.
- Drachsler, H., Hummel, H.G.K. e Koper, R., “Identifying the Goal, User model and Conditions of Recommender Systems for Formal and Informal Learning”. *J. Digit. Inf.*, 10, 1 (2009).

- Gutiérrez, S., Pardo, B., “Sequencing in Web-Based Education: Approaches, Standards and Future Trends”, in Jain, Lakhmi and Tedman, Raymond and Tedman, Debra (Eds.), *Evolution of Teaching and Learning Paradigms in Intelligent Environment Studies*, 62, Springer, Berlin / Heidelberg, 2007, 83-117.
- Herlocker J.L., Konstan J.A., Terveen L.G. e Riedl J.T., “Evaluating collaborative filtering recommender systems”, *ACM Transactions on Information Systems*, 22, (2004), 5–53.
- Iglesias, A., Martínez, P., Aler, R., e Fernández, F., “Learning Content Sequencing in an Educational Environment According to Student Needs”, *ALT'04*, (2004), 454-463.
- IMS Global Learning Consortium, *IMS Simple Sequencing Best Practice and Implementation Guide*, http://www.imsglobal.org/simplesequencing/ssv1p0/imsss_bestv1p0.html#1500598 , (11 de Novembro de 2011), 2003.
- Lin, H.-Y., Tseng, S.-S., Weng, J.-F., e Su, J.-M., “Design and Implementation of an Object Oriented Learning Activity System”, *Educational Technology & Society*, 12, 3 (2009), 248–265.
- Luis De-Marcos, J., J. Martínez, J., A. Gutiérrez, R. B. e Gutiérrez, M., “A new sequencing method in web-based education”, *Eleventh conference on Congress on Evolutionary Computation (CEC'09)*, (2009), 3219-3225.
- Karampiperis, P., Sampson, D., “Adaptive learning resources sequencing in educational hypermedia systems”, *Educational Technology & Society*, 8, (2005), 128-147.
- Koper, R., ”Increasing Learner Retention in a Simulated Learning Network Using Indirect Social Interaction”, *Journal of Artificial Societies and Social Simulation*, 8, 2 (2005).
- Madjarov, I., Betari, A., “Adaptive Learning Sequencing for Course Customization: A Web Service Approach”, *Asia-Pacific Services Computing Conference, APSCC '08*, (2008), 530-535.
- Manouselis, N., Vuorikari, R. e Van Assche, F., “Simulated Analysis of MAUT Collaborative Filtering for Learning Object Recommendation”, *Workshop on Social Information Retrieval in Technology Enhanced Learning (SIRTEL 2007)*, (2007), 17-20.
- Manouselis N., Drachsler H., Vuorikari R., Hummel H. e Koper R., “Recommender systems in technology enhanced learning”, in P. Kantor, F. Ricci, L. Rokach & B. Shapira (Eds.), *Recommender Systems Handbook: A Complete Guide for Research Scientists & Practitioners*, Springer, Berlin, 2010, 387– 415.
- Melville, P., Mooney, R. J. e Nagarajan, R., “Content-boosted collaborative filtering for improved recommendations”, *Proceedings of 18th National Conference on Artificial Intelligence*, (2002), 187-192.
- Oppermann, R., “Adaptively supported adaptability”, *Int. J. Hum.-Comput. Stud.*, 40, 3 (1994), 455-472.
- Pazzani, M. J., “A framework for collaborative, content-based and demographic filtering”, *Artificial Intelligence Review*, 13, 5 (1999), 393-408.
- Rafaeli S., Barak M., Dan-Gur Y. e Toch E., “QSIA – a Web-based environment for learning, assessing and knowledge sharing in communities”, *Computers & Education*, 43, (2004), 273–289.
- Seitzinger, J., “Be Constructive. Blogs, Podcasts, and Wikis as Constructivist Learning Tools”, *Learning Solutions Magazine*, <http://www.learningsolutionsmag.com/articles/220/be->

constructive-blogs-podcasts-and-wikis-as-constructivist-learning-tools/pageall, (23 de Outubro de 2010), 2006.

- Seki, K., Matsui, K., e Okamoto, T., “An Adaptive Sequencing Method of the Learning Objects for the e-Learning Environment”, *IEICE Transactions on Information and Systems*, (2003), 330-344.
- Sheng, H., Siau, K. e Nah, F.F., “Understanding the Values of Mobile Technology in Education: A Value-Focused Thinking Approach”, *ACM SIGMIS Database*, 41, 2 (2010), 25-44.
- Soboro, I. M., Nicholas, C. K., “Combining content and collaboration in text filtering”, *Proceedings of the IJCAI Workshop on Machine Learning in Information Filtering*, (2000), 86-91.
- Tang, T. Y., McCalla, G., “Smart recommendations for an evolving e-learning system”, *International Journal on E-Learning*, 4, 1 (2005), 105-129.
- Walker, A., Recker, M., Lawless, K., e Wiley, D., “Collaborative information filtering: A review and an educational application”, *International Journal of Artificial Intelligence in Education*, 14, 1 (2004), 3–28.