Um Modelo para Recomendação de Objetos de Aprendizagem Baseado em Similaridade de Sessões

Tiago Wiedemann¹, Jorge L. V. Barbosa¹, Sandro J. Rigo¹

¹Universidade do Vale do Rio dos Sinos (UNISINOS) Av. Unisinos, 950 - São Leopoldo - RS - Brazil

tiagowrs@gmail.com, {jbarbosa,rigo}@unisinos.br

Abstract. This article proposes a model for recommending Learning Objects (LO) based on analysis of similarity between historical queries in object repositories. The proposed model receives the sequence of objects viewed during the current user session and locates sessions which LO sequences are similar to current session. Then the objects in similar sessions are recommended to the current user. We developed a prototype applied to a real scenario and the results obtained showed the feasibility of the proposal.

Resumo. Este artigo propõe um modelo para recomendação de Objetos de Aprendizagem (OA) baseado na análise de similaridade entre históricos de consultas realizadas em repositórios de objetos. O modelo proposto recebe a sequência de OA consultados durante a sessão atual do usuário e localiza sessões cujas sequências de OA consultados sejam similares à sequência da sessão corrente. Os OA encontrados nas sessões similares são então recomendados ao usuário. Foi desenvolvido um protótipo aplicado a um cenário real e os resultados alcançados mostraram a viabilidade da proposta.

1. Introdução

Um Objeto de Aprendizagem (OA) é qualquer entidade ou recurso que possa ser utilizado no aprendizado auxiliado por computador. Podem ser textos, conteúdo multimídia, apresentações, programas ou qualquer outro tipo de conteúdo digital. O objetivo da disponibilização destes objetos na *web* é a reutilização dos mesmos em diferentes contextos educacionais, reduzindo os custos de produção de objetos educacionais [Wiley 2002].

Com o aumento da quantidade de OA disponibilizados, assim como o próprio crescimento da *web*, tornou-se necessário a criação de bancos de dados organizados para seu armazenamento e catalogação. Estes bancos de dados disponíveis na *web* são chamados de "Repositórios" [Audino and Nascimento 2012]. Os repositórios permitem a disponibilização de OA para estudantes e educadores de forma individual ou organizados em grupos temáticos. Um exemplo de repositório é Banco Internacional de Objetos Educacionais¹, mantido pelo MEC.

Porém, mesmo com a organização dos OA em repositórios dedicados, a localização de objetos que se adequem às necessidades dos usuários ainda é uma tarefa complexa, em virtude do volume de informações. Para solucionar este problema surgiram os sistemas de recomendação, que visam auxiliar a busca por OA que se adequem ao

¹http://objetoseducacionais2.mec.gov.br/

perfil do usuário [Cazella et al. 2009]. Por perfil de usuário, entende-se uma estrutura que contenha informações sobre as preferências, comportamento e contexto do usuário [Ghosh and Dekhil 2009]. De maneira geral um sistema de recomendação é capaz de indicar recursos úteis aos usuários ou grupos, através de uma avaliação que procura determinar o quão útil uma determinada indicação é para o usuário [Primo et al. 2010].

Na área educacional, a utilidade de uma indicação ou recurso pode ser estimada a partir do conteúdo de cada objeto em conjunto com o perfil do usuário que está realizando a consulta. Por exemplo, [Al-Khalifa 2008] propõe um algoritmo de recomendação que analisa o perfil de cada usuário em conjunto com o histórico de todos os OA já acessados pelo mesmo e o *ranking* dado pelo usuário a cada objeto.

No entanto, a análise baseada no perfil considera todo o histórico de OA consultados pelo usuário, ou ainda características gerais do seu perfil, como a área de atuação. Esta abordagem pode não atender as espectativas do usuário, uma vez que não leva em consideração os seus interesses de aprendizagem atuais. Isto tem levado os pesquisadores a estuderem abordagens de recomendação de OA sensíveis ao contexto [da Silva et al. 2011].

Com base no exposto, este artigo propõe um modelo para sistemas de recomendação de OA denominado **ReBaSS** (REcomendação BAseada em Similaridade de Sessões), que considera a similaridade entre a sequência de objetos consultados durante a sessão atual do usuário com as sequências armazenadas no histórico de sessões do repositório.

Este artigo está dividido em 6 seções. A seção 2 apresenta uma breve introdução às técnicas de análise de similaridade entre sequências. Na seção 3 são descritos os trabalhos relacionados. A seção 4 apresenta o modelo do ReBaSS. A seção 5 descreve os experimentos realizados. Por fim, a seção 6 apresenta os resultados obtidos e sugere algumas linhas de trabalhos futuros.

2. Análise de similaridade

Na área de descoberta de conhecimento em bases de dados a tarefa de clusterização é a que possui uma relação mais próxima com o conceito de similaridade. A clusterização, ou agrupamento, tem como objetivo particionar os registros de uma base de dados em subconjuntos chamados *clusters*, de tal forma que os elementos que compõem um *cluster* compartilhem um conjunto de propriedades que permitam distingui-los dos demais *clusters*. O resultado ótimo desta tarefa consiste em obter a maior similaridade *intra-cluster* e a maior distância *inter-cluster* [Goldschmidt and Passos 2005].

Porém, quando se trata de analisar a similaridade entre duas sequências a tarefa se torna mais complexa, pois é necessário avaliar não apenas os atributos dos objetos mas também a ordem na qual os objetos aparecem na sequência. Alguns trabalhos, como [Abraham and Lal 2012] e [García-Díez et al. 2011] denominam este problema como "Alinhamento de Sequências". [Skopal and Bustos 2011] descrevem algumas técnicas de análise de similaridade que podem ser aplicadas neste domínio como a Edit Distance, a Longest Common Subsequence e a Sequence Alignment Distance.

Outra técnica conhecida é a *Dynamic Time Warping (DTW)* [Berndt and Clifford 1994], que é utilizada na análise de similaridade em séries temporais, como por exemplo a análise do histórico de preços de ações e o reconhecimento de fala. Considerando-se duas séries temporais $S = \{s_1, s_2, ..., s_i, ..., s_n\}$ e

 $T=\{t_1,t_2,...,t_j,...,t_m\}$, a DTW alinha ambas as séries na forma de um $grid\ n \times m$, onde n e m são os tamanhos das respectivas séries e cada ponto $\{i,j\}$ do grid corresponde a um alinhamento entre os elementos das séries. O valor de cada ponto é obtido a partir de uma função de distância δ entre os pontos, como por exemplo o quadrado da diferença $(\delta(i,j)=(i-j)^2)$. O cálculo da distância das sequências consiste em utilizar técnicas de programação dinâmica para encontrar o caminho $W=\{w_1,w_2,...,w_k\}$ através do grid que corresponda ao menor somatório de distâncias individuais, o que é formalmente definido como $DTW(S,T)=min_w\left[\sum\limits_{k=1}^p\delta(w_k)\right]$.

3. Trabalhos relacionados e Contribuições

[Zapata et al. 2013] propõem um *framework* denominado *DELPHOS* para auxiliar os usuários na realização de consultas personalizadas em repositórios. O *framework* adota uma abordagem híbrida, que combina as abordagens Colaborativa, ao analisar o histórico dos OA mais acessados e a avaliação dos usuários, Baseada em Conteúdo, ao calcular o grau de similaridade entre dois OA, e Demográfica ao calcular a similaridade entre usuários.

[Cazella et al. 2012] propõem um modelo denominado **RECoaComp** (REComendador de objetos de aprendizagem baseado em Competências), que tem como objetivo filtrar os OA de um repositório de acordo com as competências a construir, sinalizadas no perfil do usuário. Neste modelo, o professor primeiramente seleciona os objetos que deseja utilizar, identificando a lista de competências que cada OA ajuda a desenvolver. Em seguida, os alunos realizam uma auto-avaliação em relação as competências identificadas pelo professor. Finalmente, o sistema sugere os OA de acordo com as competências de cada aluno. Este modelo também calcula e armazena a lista de usuários similares para cada usuário. Para o sistema de recomendação, alunos similares significam alunos que costumam avaliar o conteúdo dos objetos de maneira semelhante. O que permite prever se um aluno deve receber a recomendação de um determinado OA ou não.

[Rocha et al. 2010] propõem um módulo de recomendação de OA integrado ao ambiente virtual AMADEUS². O algoritmo de recomendação apresentado neste trabalho representa os metadados dos OA na forma de vetores, onde os termos presentes em cada descrição correspondem as dimensões do vetor, e a frequência de termos corresponde ao valor de cada dimensão. Sobre esta representação é aplicada a técnica *k-nearest neighbors* para filtrar os objetos a serem recomendados.

Os trabalhos relacionados utilizam como base para a análise de similaridade o conjunto total de características dos objetos ou o histórico completo de objetos acessados pelo usuário. Esta técnica pode gerar recomendações que não atendam as necessidades do usuário em relação aos seus interesses atuais. Para casos como este alguns trabalhos propõem uma abordagem para recomendação de OA sensível ao contexto [da Silva et al. 2011].

Outra questão a ser analisada é quanto ao desempenho das técnicas apresentadas. [Nunes and Cazella 2011], por exemplo, afirmam que a Filtragem Colaborativa possui

²http://amadeus.cin.ufpe.br/

um desempenho $\Omega(n^2)$, e mesmo a recomendação Baseada em Conteúdo pode tornar-se inviável em função da quantidade de OA disponíveis no repositório, ou exigir um cálculo prévio da similaridade entre os OA, antes que qualquer recomendação possa ser feita.

Tendo em vista estas questões, o modelo proposto utiliza como base para análise de similaridade, apenas a sequência de OA acessados durante a sessão atual do usuário. Este modelo possui as seguintes características, que são suas contribuições em relação aos trabalhos relacionados:

- 1. a quantidade de OA consultados em uma sessão normalmente é pequena, o que melhora o desempenho da análise de similaridade;
- a sequência de OA da sessão atual carrega, de forma implícita, qual o interesse do usuário no momento, o que permite uma recomendação mais precisa em relação ao contexto atual do usuário;
- 3. a sessão atual pode trazer, também de forma implícita, o contexto atual do usuário, como por exemplo, qual curso ou disciplina ele está cursando no momento, quem são seus colegas de classe, entre outras informações inferíveis;
- 4. aplica uma técnica simplificada que pode ser facilmente adaptada a modelos mais complexos.

4. Modelo proposto

O modelo proposto utiliza a técnica conhecida como *DTW* para analisar a similaridade entre a sequência de OA consultada durante a sessão atual do usuário e o conjunto completo de sequências armazenadas nos históricos de acessos do repositório de OA. Cada sequência de OA consultada é considerada uma série temporal artificial [Matuschek et al. 2008].

A Figura 1 ilustra a arquitetura do modelo, que é composta por 5 camadas. A primeira camada corresponde a aplicação que implementará o modelo como, por exemplo, um módulo no portal *web* de um repositório. A segunda camada é responsável por realizar a recomendação de OA para uma sessão. A aplicação cliente utiliza o componente *Recommender* especificando qual componente da camada de acesso aos dados será utilizado para carregar os dados das sessões; qual a quantidade máxima de sessões que deverão ser analisadas; e a localização do repositório de objetos. Em seguida é feita uma chamada ao método *recommend* passando a sequência de OA da sessão atual e a quantidade de OA que devem ser recomendados. A terceira camada é responsável por realizar a análise de similaridade entre a sessão atual e as sessões armazenadas no repositório. A quarta camada realiza o acesso ao repositório, abstraindo os dados em uma representação interna de OA e sessões. Por fim, a quinta camada representa o armazenamento físico do repositório.

O modelo utiliza os componentes da camada de acesso aos dados para obter as sequências das sessões armazenadas no repositório, e a camada de análise de similaridade para calcular a distância de cada sessão em relação a sessão corrente. A camada de representação então organiza as sessões obtidas em ordem crescente de distância, desconsiderando sessões cujo valor da distância seja igual a zero. A razão disto é que o valor zero indica uma sequência de OA iguais aos da sessão atual, e portanto não haverá nestas sequências nenhum OA novo a ser recomendado. Por fim, o componente *Recommender* percorre a lista de sessões, selecionando os OA que não constam na lista de OA da sessão atual, até atingir o limite de OA a serem recomendados, retornando-os à aplicação de recomendação.

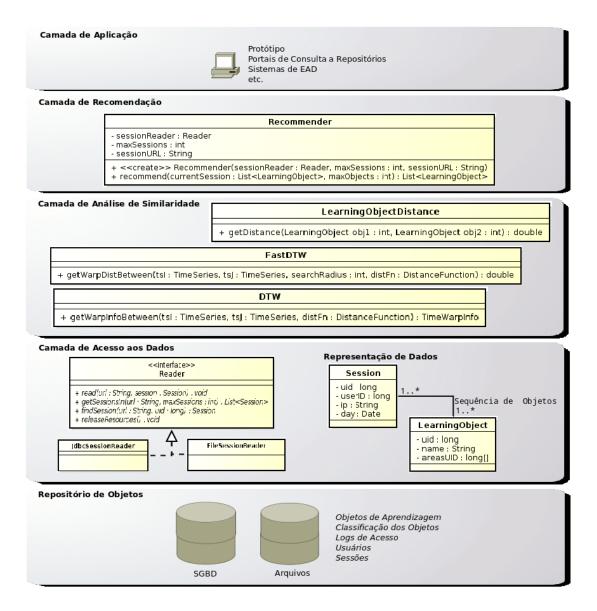


Figura 1. Arquitetura do ReBaSS

Para calcular a função de distância δ entre os OA foi desenvolvida uma técnica que compara a área temática dos objetos, retornado um valor entre (0..1) conforme a distância encontrada. Esta técnica baseia-se no trabalho de [Abraham and Lal 2012] e calcula a similaridade em uma hierarquia de áreas temáticas através da comparação binária entre os níveis, conforme a equação:

$$\delta_{OA}(x,y) = 1 - \frac{X \cap Y}{maxLength(X,Y)}$$

Onde (x,y) são os OA a serem comparados e (X,Y) são as respectivas hierarquias da área temática de cada objeto. A Tabela 1 exemplifica o cálculo da distância entre dois OA distintos obtidos a partir do Banco Internacional de Objetos Educacionais. A função de distância implementada pela técnica consiste em uma comparação binária entre as hierarquias das áreas temáticas dos OA, dividindo-se a quantidade de áreas iguais pelo tamanho da maior hierarquia. Uma característica desta técnica é que, assim como o trabalho de [Abraham and Lal 2012], o algoritmo continua calculando a comparação

binária somente enquanto encontrar correspondência entre os níveis das duas hierarquias. O objetivo deste controle é reduzir a quantidade de falsos positivos durante a comparação. Por exemplo, se um objeto X está vinculado à área "Ciências::Física:Teoria Atômica" e um objeto Y está vinculado à área "Ciências::História da Ciência::Teoria Atômica", então a similaridade entre eles ocorre somente no topo da hierarquia (Ciências). Por fim, caso os objetos sendo comparados possuam o mesmo identificador único (uid), significa que trata-se do mesmo objeto, e portanto pode-se considerar que o valor da distância é zero, sem a necessidade de calcular a similaridade entre as áreas temáticas.

Tabela 1. Cálculo de distância entre objetos de aprendizagem

Objeto	Área Temática						
\overline{x}	Educação Básica::Ensino Médio::Química::Modelos de constituição						
y	Educação Básica::Ensino Médio::Química::Propriedades das substâncias						
	Comparação Binária: 1 :: 1 :: 0						
	$\delta_{OA}(x,y) = 1 - \frac{3}{4} \Rightarrow 0,25$						

Uma vez definida a função de distância, é utilizada a técnica *DTW* para calcular a similaridade das sequências de OA acessados durante a sessão atual em relação as sessões armazenadas nos históricos de uso do repositório. Pode-se optar por limitar a quantidade de sessões comparadas, considerando-se por exemplo, somente as sessões mais recentes, ou ainda as sessões de usuários com perfis mais similares aos do usuário atual. A técnica irá retornar as sessões mais similares à sessão atual em relação a sequência de OA consultados.

Obtida a lista de sessões similares, o último passo do processo de recomendação consiste em obter a lista de OA presentes nas sessões similares, descartando-se aqueles que já estão presentes na sessão atual. Os objetos que passarem por esta seleção são então recomendados ao usuário.

5. Implementação e Avaliação

Para a avaliação do modelo proposto foi implementado um protótipo desenvolvido em linguagem JAVA. O repositório foi armazenado em um banco de dados PostgreSQL. Para implementação da técnica *DTW* foi utilizado o *framework OpenSource* FastDTW³ [Salvador and Chan 2007], que foi adaptado para utilizar a função de distância usada no ReBaSS. Os experimentos foram conduzidos em um Notebook DELL VostroTM com processador Intel CoreTM i5 2.40GHz com 6GB de memória RAM, e sistema operacional Ubuntu Linux 12.04 64-bits com *kernel* versão 3.2.0-51.

Os dados para realização do experimento foram obtidos a partir dos *logs* de acesso ao sistema *Moodle*⁴ do curso de Sistemas de Informação das Faculdades Integradas de Taquara/RS⁵, referentes ao período de Agosto/2012 a Agosto/2013. Foram considerados os registros da tabela *mdl_log* referentes aos acessos de alunos aos materiais disponibilizados pelos professores. Estes materiais podem ser considerados exemplos de OA [da Silva et al. 2011] e são descritos na tabela *mdl_resource* a partir da qual

³http://code.google.com/p/fastdtw/

⁴http://moodle.org

⁵http://fit.faccat.br

foi obtida a descrição de cada objeto. Por fim, foi considerado como área temática de cada OA, o código de identificação do curso e do *course_module* armazenados respectivamente nos campos *course* e *cmid* da tabela *mdl_log*, criando assim uma hierarquia "Curso::*Course_Module*" para identificação da área temática de cada objeto.

A Figura 2 ilustra a estrutura dos dados utilizados para avaliação. A tabela *mdl_log* não possui originalmente um identificador da sessão do usuário. Para realizar o experimento, foi criada artificialmente uma tabela de sessões e um identificador de sessão. Para construção da tabela de sessões, os dados foram agrupados por Usuário (*userid*), IP e Data do acesso. Os campos "dataHora" e "dia" foram criados para auxiliar neste processo.

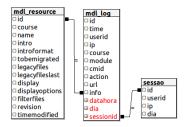


Figura 2. Estrutura de dados utilizada para avaliação

Através deste critério, foram obtidas 11.039 sessões de usuários em 33.778 registros de acessos a OA. A Figura 3 mostra a distribuição da quantidade de registros (eixo y) por sessão de usuário (eixo x). Percebe-se nesta figura que a maior sessão identificada possui 154 registros, porém a maioria das sessões possuem menos do que 25 registros.

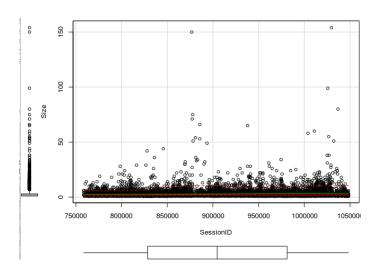


Figura 3. Quantidade de registros de acesso por sessão

O protótipo seleciona uma das sessões disponíveis no banco de dados e, a partir da sequência de OA desta sessão, identifica as sessões similares e realiza a recomendação de novos objetos. O protótipo foi configurado para recomendar três OA para a sessão selecionada. O resultado gerado pelo protótipo é um relatório do processamento indicando as sessões mais similares, os OA recomendados e o tempo de processamento.

A Figura 4 mostra o resultado da recomendação para a sessão de número [1044725], vinculada ao usuário de número [399]. Esta sessão possui quatro registros de

acesso, referentes a três OA identificados respectivamente pelos códigos [3183], [2761], e [290]. O componente de recomendação analisou 11.039 sessões, a uma taxa de 400 a 500 sessões por segundo, em cerca de 24 segundos. A sessão de número [1043715] foi a mais similar à sessão corrente, com um valor de distância de 2.0 segundo a técnica DTW. Por fim, foram recomendados os três OA de números [2529], [1043] e [292].

Ao analisar o primeiro objeto recomendado, de número [2529] cuja descrição é "Exemplo de saída de protótipo" e cuja área temática é identificada por "42::4156", percebe-se que não é possível identificar semelhanças com nenhum dos objetos presentes na sessão atual do usuário. Porém ao analisar a sessão de origem desta recomendação, de número [1044676] e cujos registros são mostrados na Figura 5, percebe-se que a sequência de OA é similar aos objetos da sessão [1044725]. Pode-se então deduzir que os interesses de aprendizagem do usuário durante a sessão [104467] eram similares aos interesses do usuário da sessão corrente. Partindo desta possibilidade, o protótipo então recomenda os OA da sessão [1044676] que ainda não tenham sido consultados na sessão corrente.

```
run:
Sessão Original:
          ..: 1044725
  User ID.: 399
  IP.....: 200.132.2.240
  Dia....: 06/08/2013
Objetos da Sessão:
  1. [3183] Tanenbaum: Tradução/resumo do Cap. 1 |90::5439|

    [2761] Projeto Pedagógico Curso (Sistemas para Internet) |1::4637|
    [290] aula 1 - Conceitos fundamentais de Bancos de Dados |13::435|
    [290] aula 1 - Conceitos fundamentais de Bancos de Dados |13::435|

Iniciando Recomendação...
Retrieving Sessions: 11039 sessions found! 735,00ms
     * Finished Block: Block [1000 sessions] [2seg 652,00ms ] Total [2seg 652,00ms ] Avg [500,50 ses/sec]
  1. Similar Session: id=[1043715] distance=[2.0]
  2. Similar Session: id=[1044622] distance=[2.0]
  getSimilarSessions(4): 24seg 239.00ms
  getNewObjects(similarSessions=11038, current=4, maxObjects=3): 0,00ms
Objetos Recomendados:
  1. [2529] Exemplo de saída de protótipo |42::4156| origem=[session=1044676]
  2. [1043] aula 2 - conceitos fundamentais de bancos de dados |13::1914| origem=[session=808227]
      [292] aula 2 - introdução - modelagem conceitual |13::437| origem=[session=808227]
(3 objetos)
CONSTRUÍDO COM SUCESSO (tempo total: 24 segundos)
```

Figura 4. Resultado do processamento

	sessionid bigint		datahora timestamp without time zone					resource_name character varying(255)
1	1044676	1444	2013-08-06	22:30:12	42	4156	2529	Exemplo de saída de protótipo
2	1044676	1444	2013-08-06	22:51:15	13	435	290	aula 1 - Conceitos fundamentais de Bancos de Dados
3	1044676	1444	2013-08-06	22:51:16	13	435	290	aula 1 - Conceitos fundamentais de Bancos de Dados

Figura 5. Registros de acesso da sessão número 1044676

Por fim, para avaliar a escalabilidade do modelo foi realizado um teste selecionando-se a maior sessão armazenada, com 154 registros de acesso. A quantidade de sessões processadas por segundo não sofreu alteração significativa em função da quantidade de OA da sessão atual, mantendo-se sempre uma média em torno de 435 sessões/segundo mesmo ao utilizar as maiores sessões disponíveis na base de dados.

6. Conclusões e Trabalhos Futuros

Este artigo apresentou um modelo para recomendação de OA baseado na similaridade entre sequências de consultas realizadas em cada sessão de usuário. O modelo proposto

utiliza a técnica denominada *Dynamic Time Warping* para calcular a similaridade entre a sequência de objetos consultados durante a sessão atual de um usuário e o conjunto de sessões armazenados nos *logs* de acesso à um repositório. Foi desenvolvida uma função para o cálculo da distância entre OA, inspirada no trabalho de [Abraham and Lal 2012]. São recomendados os objetos que pertencerem às sessões mais similares e que ainda não tenham sido acessados durante a sessão atual.

Foi desenvolvido um protótipo para avaliação do modelo proposto, utilizando o cenário real de acessos ao sistema de EAD do curso de Sistemas de Informação de uma faculdade. Conforme demonstrado na seção 5, o modelo provou ser capaz de recomendar OA potencialmente úteis ao interesse atual do usuário mesmo que os dados que descrevam os objetos não possuam nenhuma similaridade.

Como trabalhos futuros propõe-se o estudo da utilização de outras técnicas de análise de similaridade em sequências visando a comparação em relação a técnica *DTW* utilizada neste artigo, bem como o aperfeiçoamento da função de cálculo de distância entre objetos proposta.

Por fim, a identificação de sessões similares poderá auxiliar em outras aplicações, como por exemplo a formação automática de grupos de estudos conforme o grau de similaridade entre os alunos, ou ainda a construção de perfis de estudantes conforme seu histórico de interesses.

7. Agradecimentos

Os autores agradecem à CAPES e ao CNPq pelo apoio ao desenvolvimento desta pesquisa. Os autores também agradecem ao Prof. Dr. Marcelo Azambuja, coordenador do curso de Sistemas de Informação das Faculdades Integradas de Taquara, e a Rodrigo Henrich, analista de suporte, pela disponibilização dos dados de acesso que permitiram a realização dos experimentos descritos neste artigo.

Referências

- Abraham, S. and Lal, P. S. (2012). Spatio-temporal similarity of network-constrained moving object trajectories using sequence alignment of travel locations. *Transportation Research Part C: Emerging Technologies*, 23(0):p. 109–123. Data Management in Vehicular Networks.
- Al-Khalifa, H. S. (2008). Building an arabic learning object repository with an ad hoc recommendation engine. In *Proceedings of the 10th International Conference on Information Integration and Web-based Applications & Services*, iiWAS '08, pages 390–394, New York, NY, USA. ACM.
- Audino, D. F. and Nascimento, R. d. S. (2012). Objetos de aprendizagem—diálogos entre conceitos e uma nova proposição aplicada à educação. *Revista Contemporânea de Educação*, 5(10).
- Berndt, D. and Clifford, J. (1994). Using dynamic time warping to find patterns in time series. In *Proceedingsof the AAAI-94 Workshop on Knowledge Discovery in Databases*, page 229–248.
- Cazella, S. C., Behar, P., Schneider, D., da Silva, K. K., and Freitas, R. (2012). Desenvolvendo um sistema de recomendação de objetos de aprendizagem baseado em

- competências para a educação: relato de experiências. In *Anais do Simpósio Brasileiro de Informática na Educação*, volume 23.
- Cazella, S. C., Reategui, E. B., Machado, M., and Barbosa, J. L. V. (2009). Recomendação de objetos de aprendizagem empregando filtragem colaborativa e competências. In *Anais do Simpósio Brasileiro de Informática na Educação*, volume 1.
- da Silva, L. C. N., Mendes Neto, F. M., and Jácome Júnior, L. (2011). Mobile: Um ambiente multiagente de aprendizagem movel para apoiar a recomendacao sensivel ao contexto de objetos de aprendizagem. In *Anais do Simpósio Brasileiro de Informática na Educação*, volume 1.
- García-Díez, S., Fouss, F., Shimbo, M., and Saerens, M. (2011). A sum-over-paths extension of edit distances accounting for all sequence alignments. *Pattern Recognition*, 44(6):1172 1182.
- Ghosh, R. and Dekhil, M. (2009). Discovering user profiles. In *Proceedings of the 18th international conference on World wide web*, WWW '09, pages 1233–1234, New York, NY, USA. ACM.
- Goldschmidt, R. and Passos, E. (2005). *Data mining: um guia prático*. Elsevier, Rio de Janeiro, RJ, 4 edition.
- Matuschek, M., Schlüter, T., and Conrad, S. (2008). Measuring text similarity with dynamic time warping. In *Proceedings of the 2008 international symposium on Database engineering & applications*, IDEAS '08, pages 263–267, New York, NY, USA. ACM.
- Nunes, M. A. S. and Cazella, S. C. (2011). O que sua personalidade revela? Fidelizando clientes web através de Sistemas de Recomendação e traços de personalidade. Minicursos do Webmedia. SBC. Capítulo, 5.
- Primo, T. T., Vicari, R. M., and da Silva, J. M. C. (2010). Rumo ao uso de metadados educacionais em sistemas de recomendação. In *Anais do Simpósio Brasileiro de Informática na Educação*, volume 1.
- Rocha, R., Franco, R., Barros, R. S., Dantas, E. R. G., Azevedo, R. R. d., Dias, G. A., and Gomes, A. S. (2010). Amadeus recommends: um sistema de recomendação para objetos de aprendizagem. In *Anais do Workshop de Informática na Escola*, volume 1, pages 1457–1460.
- Salvador, S. and Chan, P. (2007). Toward accurate dynamic time warping in linear time and space. *Intelligent Data Analysis*, 11(5):561–580.
- Skopal, T. and Bustos, B. (2011). On nonmetric similarity search problems in complex domains. *ACM Comput. Surv.*, 43(4):34:1–34:50.
- Wiley, D. A. (2002). The instructional use of learning objects. http://reusability.org/read/. Acesso em 27 de Setembro de 2013.
- Zapata, A., Menéndez, V., Prieto, M., and Romero, C. (2013). A framework for recommendation in learning object repositories: An example of application in civil engineering. *Advances in Engineering Software*, 56(0):1 14.