
Um Framework para Mineração de Dados Educacionais Baseado em Serviços Semânticos

Tarsis Marinho¹, Diego Dermeval¹, Rafael Ferreira¹, Lucas M. Braz¹,
Ig Ibert Bittencourt¹, Evandro B. Costa¹, Henrique Pacca L. Luna¹

¹Instituto de Computação – Universidade Federal de Alagoas (UFAL)
Maceió – AL – Brasil

{tarsis.ms, diegodermeval, rafaelmello, lmonteirobraz, ig.ibert, ebcosta, hpluna}@gmail.com

Abstract. *This paper proposes a framework for providing educational activities for adaptation encapsulated in semantic web services. It aims to provide: i) reuse of data mining techniques, ii) educational semantic web services, and iii) automatic discovery, composition, and invocation of semantic web services. A case study has been developed to evaluate the feasibility of the proposed framework.*

Resumo. *Este artigo propõe um arcabouço para prover atividades educacionais de adaptação encapsuladas em Serviços Web Semânticos. Ele busca prover: i) a reutilização de técnicas de mineração de dados; ii) serviços web semânticos educacionais e iii) descoberta automática, composição e invocação de serviços web semânticos. Um estudo de caso foi desenvolvido para avaliar a viabilidade do arcabouço proposto.*

1. Introdução

Ambientes *e-Learning* armazenam um grande volume de dados sobre seus usuários. Esses são coletados automaticamente pelos servidores web que gravam todas as ações dos usuários enquanto os mesmos navegam pelo ambiente e realizam atividades. Tais dados podem ser uma grande e importante fonte de informação para professores e desenvolvedores. Eles podem ser utilizados para, por exemplo, identificar possíveis dificuldades dos alunos, aperfeiçoar a estrutura dos ambientes *e-Learning* e de seus cursos e fornecer um acompanhamento individualizado para os estudantes.

No entanto, dado o volume de dados armazenado, a análise deles em busca de informações úteis é uma tarefa complexa e dispendiosa para professores e desenvolvedores. Assim, faz-se necessário o uso de uma abordagem que os auxilie nesse processo. Neste contexto, a mineração de dados apresenta-se como uma boa solução, contribuindo para esta tarefa de análise de dados.

A mineração em ambientes educacionais tem sido usada em diferentes perspectivas, entre elas: recomendar conteúdo [Markellou et al. 2005], [Zaiane 2002] e [Tang and McCalla 2003], aperfeiçoar ambientes *e-Learning* [Zaane and Zaiane 2001] e [Tang et al. 2000] e modelar perfis de estudantes [Tang and McCalla 2002].

As duas principais abordagens presentes na literatura no uso da mineração de dados em ambientes *e-Learning* são: i) adaptação do ambiente existente, na qual os desenvolvedores precisam modificar o ambiente, incluindo suas funcionalidades, para dar

suporte à utilização de mineração de dados. Entretanto, os desenvolvedores precisam ter conhecimento específico sobre as técnicas de mineração de dados para poder implementá-las; ii) usar ferramentas de mineração educacionais, onde educadores podem usar ferramentas independentes do ambiente de aprendizagem e que oferecem funcionalidades de mineração. Contudo, nesta abordagem o próprio educador usará as informações obtidas pela ferramenta de forma não automática, ou seja, ele irá usar os dados para tomar decisões como recomendar a leitura de um material adicional a um aluno que tem dificuldade em um determinado domínio.

Em [Romero and Ventura 2007] destacam como linhas de pesquisa futuras em mineração de dados educacionais: i) Padronização dos métodos e dados, onde as ferramentas e técnicas são úteis apenas aos seus desenvolvedores. Não existem ferramentas gerais ou reutilização de ferramentas e/ou técnicas que possam ser aplicadas a qualquer ambiente educacional. Assim, a padronização dos dados e técnicas são necessárias; ii) Integração com ambientes *e-Learning*: Ferramentas precisam ser integradas a ambientes educacionais de forma simples. Todas as tarefas relacionadas à mineração devem ser executadas como uma única atividade, para que *feedbacks* e resultados obtidos possam ser aplicados diretamente nos ambientes.

Este trabalho propõe um arcabouço, chamado SEDAM (*Semantic Educational Data Mining*), para mineração de dados educacionais baseados em serviços semânticos. Sendo assim, ocorrerá a reutilização e a padronização de técnicas e ferramentas, pois, tal arcabouço provê: i) Técnicas de mineração: disponibiliza técnicas de mineração, pré-processamento e pós-processamento através de serviços semânticos, dessa forma ambientes poderão reutilizá-las sem se preocupar com implementação; ii) serviços educacionais: serviços que irão prover aos ambientes educacionais funcionalidades da mineração de dados com enfoque educacional; iii) Automatização dos processos: irá prover a composição, descoberta e invocação de serviços educacionais automaticamente. Deste modo, a ferramenta proposta promove a simplicidade na integração entre mineração de dados com enfoque educacional e ambientes *e-Learning*. Assim, os *feedbacks* e resultados obtidos podem ser aplicados diretamente nos ambientes de maneira automática e sem precisar da intervenção direta do professor.

Este artigo está organizado como se segue. Na Seção 2 são apresentados os trabalhos relacionados, suas características e limitações. Na Seção 3 é apresentada a arquitetura da ferramenta proposta. Na Seção 4 é apresentado um estudo de caso que demonstra o uso da ferramenta proposta em um ambiente *e-Learning* para a recomendação de alunos para uma resolução colaborativa. Por fim, é apresentada a conclusão e proposta de trabalhos futuros na Seção 5.

2. Trabalhos Relacionados

Nesta seção são discutidos alguns trabalhos relacionados ao SEDAM, ressaltando-se suas características e limitações.

TADA-Ed [Merceron 2005] é uma plataforma de mineração de dados dedicada aos professores, permitindo-lhes visualizar e minerar os exercícios on-line dos estudantes com o intuito de descobrir padrões pedagogicamente relevantes. Esta ferramenta inclui alguns algoritmos de classificação, agrupamento e regras de associação adaptados da biblioteca disponibilizada pelo Weka [Weka 2009] e contém facilidades de pré-processamento dos

dados. Porém, nessa abordagem o próprio educador deve analisar sua base de dados no TADA-Ed para poder obter informações relevantes que auxiliem o processo pedagógico e possam ser aplicados ao ambiente. Desta forma, o custo necessário para realizar a mineração será elevado dado à necessidade de interferência direta do professor tanto no processo da mineração dos dados quanto na análise dos resultados obtidos com ela.

[Silva and Vieira 2002] discute como os recursos de *data warehouse* e *data mining* podem ser usados para a avaliação de ensino a distância e propõe o ambiente *MultiStar* para descoberta de conhecimento em *data warehouse* para suportar tal avaliação. Tal abordagem provê uma mineração mais precisa, pois é feita a partir de um armazém de dados, entretanto, da mesma forma que o TADA-Ed, o processo de mineração é custoso, dada a necessidade de interferência direta dos usuários interessados em usar o sistema.

[Zaiane 2002] sugere a implementação de um sistema de recomendação automático para ambientes de aprendizagem web que levam em conta os perfis dos estudantes on-line, seus históricos de acesso e os padrões de navegação coletivos. Tal trabalho propõe uma abordagem para construir um agente de software que usa técnicas de mineração de dados, como regras de associação para gerar um modelo que representa o comportamento dos usuários on-line e usa esse modelo para sugerir atividades ou atalhos a um determinado estudante. Apesar desse sistema realizar a mineração e utilizar as informações obtidas de forma automática, essa abordagem está limitada pela única funcionalidade que o agente pode executar, que é a recomendação de atalhos e atividades para o estudante.

A utilização da ferramenta proposta neste trabalho aparece como uma solução para as limitações dos trabalhos acima, pois a presente ferramenta disponibiliza serviços web semânticos de mineração de dados educacionais, o que possibilita a redução do custo de adaptação dos ambientes *e-Learning* para o uso da mineração de dados em ambientes educacionais. O SEDAM é também facilmente expansível, podendo ser adicionados a ele serviços web semânticos que implementam novas funcionalidades. Outra vantagem é que o método para acesso deste novo serviço semântico é o mesmo das outras funcionalidades já existentes, bastando especificar a nova saída requerida.

3. O Arcabouço Proposto

Este trabalho propõe um arcabouço, chamado SEDAM (Semantic Educational Data Mining), para mineração de dados educacionais baseados em serviços semânticos com enfoque educacional. Esta ferramenta enfatiza três aspectos. Primeiro, reuso de técnicas de mineração. Segundo, prover serviços semânticos de mineração que podem ser usados por ambientes *e-Learning*. Terceiro, garante a descoberta, composição e invocação automática de serviços semânticos. A Figura 1 apresenta a arquitetura do arcabouço e seus componentes. A arquitetura é composta por quatro camadas: *Tools*, *Web Services*, *Service Manager* e Ontologia. Tais camadas serão descritas nas subseções abaixo.

3.1. Tools

Esta camada irá prover os algoritmos de mineração que serão usados pelas camadas superiores para realizar o processo de mineração. Ela é composta por várias ferramentas de mineração. Tais ferramentas fornecem os algoritmos de mineração e pré-processamento que serão utilizados para atingir os objetivos da mineração educacional. É necessário




Figura 1. Arquitetura do Arcabouço Proposto

que cada uma delas possua uma descrição semântica em OWL¹, de forma que suas funcionalidades possam ser utilizadas pelas camadas superiores. Nesta proposta, foi utilizada a ferramenta WEKA, no entanto, é importante notar que a utilização de *Web Services* proporciona a utilização de várias ferramentas ao mesmo tempo, e que a arquitetura se torna facilmente expansível para a adição de novas ferramentas (ex.: DBMiner, Clementine). O WEKA foi escolhido, por ser amplamente utilizado na comunidade científica e na indústria, possuir uma documentação bastante abrangente e ser de fácil utilização.

O WEKA é uma coleção de algoritmos de aprendizagem de máquina que se destinam a problemas comuns em mineração de dados, como: regressão, classificação, regras de associação e seleção de atributo [Weka 2009]. Ele inclui ainda ferramentas para pré-processamento dos dados, criação de modelos de aprendizagem e análise dos resultados e desempenho de um classificador [Witten and Frank 2005]. Todas as funcionalidades do WEKA estão acessíveis através de uma simples e intuitiva interface gráfica. Além disso, o WEKA provê uma API que permite utilizar os seus algoritmos e ferramentas diretamente em código Java, o que possibilita a criação de aplicações que o utilizem.

3.2. Service Manager

Service Manager é um *Web Service* que tem a responsabilidade de descobrir, compor e invocar os serviços semânticos disponíveis. Este processo é uma aplicação cliente, na qual só se necessita saber os parâmetros de entrada e saída do serviço que se quer invocar.

A operação do *Service Manager* é baseado no algoritmo *matchmaking* [Calado et al. 2009], a partir dos parâmetros fornecidos ao algoritmo, ele tem o papel de buscar e compor os serviços necessários para que o serviço desejado seja devidamente executado.

3.3. Web Services

Os *Web Services* podem ser utilizados por qualquer aplicação que tenha acesso a web e que seja capaz de entender e processar mensagens no formato XML, independentemente de sistema operacional, servidor web ou até mesmo a linguagem de programação na qual o *Web Service* foi implementado [Newcomer and Lomow 2004].

Esta camada arquitetural fornece uma abstração dos requisitos implementados nas ferramentas de mineração. Através desta camada, os ambientes educacionais não necessitam implementar os algoritmos de mineração, bastando apenas utilizar os serviços

¹<http://www.w3.org/2004/OWL/>

disponíveis, diminuindo a complexidade e o tempo de desenvolvimento desse tipo de sistema. Além disso, diminui-se o acoplamento entre esses ambientes/ferramentas das aplicações, pois fazem uso dos algoritmos de mineração, independentemente da ferramenta que os implementam.

Os tipos de serviços disponíveis nesta camada são:

- *Web Services* educacionais - fornecem recursos fundamentais para garantir o objetivo de um sistema educacional, facilitando algumas atividades educacionais, como a integração de conteúdos, a descoberta de recursos educacionais, personalização de conteúdos e interfaces, a colaboração, a recomendação, a resolução de problemas, diagnósticos, entre outros;
- *Web Services* de mineração - fornecem a implementação dos algoritmos responsáveis por executar as tarefas de mineração, por exemplo *Apriori* ou o *ID3*;
- *Web Services* de suporte - atividades que não tem fins educacionais, mas que são necessárias para o uso dos algoritmos de mineração, tais como: conversas, pesquisa na web, eliminação de ruídos, detecção de dados inconsistentes, entre outros.

3.4. *Semantic Web Services*

De acordo com [Payne and Lassila 2004], *Semantic Web Services* são definidos como sendo um aperfeiçoamento das descrições dos *Web Services* através do uso de anotações semânticas, o que possibilita um alto grau de automação na descoberta, composição, monitoramento e invocação. A introdução de semântica aos *Web Services* faz com que tais serviços possam ser processados pela máquina. Dessa forma, é possível a criação de agentes de software capazes de descobrir, compor e invocar os serviços automaticamente. Além disso, a descoberta se torna bem mais precisa, visto que não é mais feita de maneira sintática, mas sim semântica. Sendo assim, esta camada é responsável por mapear os *Web Services* disponíveis a partir da camada inferior adicionando semântica aos mesmos obtendo-se com isso todas as vantagens oferecidas pelos *Semantic Web Services*.

Para exemplificar, suponhamos a necessidade de se obter regras de associação a partir de uma base de dados qualquer. Para realizar tal tarefa, é necessário que se faça, além do pré-processamento dos dados, conversão para o formato ARFF² e a execução de algum algoritmo de associação, como o *Apriori*. Utilizando *Web Services* tradicionais, em cada uma dessas etapas seria necessário alguma intervenção humana. Ao descrever tais *Web Services* semanticamente, é possível configurar um agente de software capaz de buscar, compor e invocar esses serviços de forma automática e transparente. Nesse artigo, para a descrição semântica dos serviços, foi utilizada a OWL-S [Martin et al. 2004]. Recomendação do W3C³, a OWL-S tem sido bastante utilizada pela comunidade científica.

3.5. Ontologia

As ontologias fornecem uma representação formal do conhecimento. Dessa forma, uma ontologia que descreve semanticamente aspectos conceituais e operacionais relacionados com a mineração de dados pode ser reutilizada por outras ontologias que descrevem ferramentas de mineração e pré-processamento de dados. A ontologia proposta descreve

²Formato aceito pelo WEKA

³World Wide Web Consortium - <http://www.w3c.org>

algumas tarefas e técnicas de mineração de dados, além de especificar os parâmetros de entrada e saída de tais algoritmos de aprendizagem.

Abaixo segue uma breve descrição das classes da ontologia:

- *DataMining*: é uma classe genérica que representa a mineração de dados (sub-área de Inteligência Artificial) na ontologia.
- *DataMiningTasks*: representa as tarefas de mineração de dados, como: associação, agrupamento, classificação e outras técnicas que também podem ser modeladas.
- *DataMiningTechniques*: classe mãe de todas as técnicas separadas por tipo de tarefa.
 - *AssociationTechniques*: As técnicas que realizam associação devem ser subclasses dessa classe. Exemplo: Algoritmo *Apriori*.
 - *ClusterTechniques*: As técnicas que realizam clusterização devem ser subclasses desta classe. Exemplo: *K-means*.
 - *ClassifyTechniques*: As técnicas que realizam classificação devem ser subclasses desta classe. Exemplo: *C4.5*.
- *Parameters*: representa os parâmetros de entrada e saída dos algoritmos de aprendizagem que podem vir a ser representados na ontologia.

Para especificar uma técnica é necessário instanciar a ontologia descrita, isso transforma a tarefa de descobrir e interpretar ela uma atividade processável pela máquina.

4. Estudo de Caso

Esta seção apresenta um estudo de caso a fim de avaliar a viabilidade do arcabouço proposto. Nele se aplica recomendação para sugerir estudantes que vão interagir com o objetivo de resolver problemas colaborativamente. Foi utilizado o FraW, tutor de fração na web, para realizar o estudo proposto e o processo de recomendação colaborativa utilizado por ele faz uso dos serviços disponibilizados pelo SEDAM. Na Seção 4.1 o FraW é descrito, com foco em como a recomendação de estudante acontece e na Seção 4.2 é detalhado como ocorre o processo de recomendação utilizando a arquitetura proposta.

4.1. FraW

O FraW é um sistema tutor inteligente para ajudar estudantes a aprenderem operações de fração mediante uma abordagem pedagógica de aprendizagem baseada em resolução de problemas. Tal sistema está habilitado a resolver problemas propostos pelos estudantes, inclusive explicando passo a passo a sua solução. Além disso, o sistema pode avaliar as soluções apresentadas pelos estudantes aos problemas propostos, bem como oferecer ajuda nos erros que venham a ocorrer no processo de elaboração da solução [Sibaldo et al. 2008].

O FraW foi reconstruído utilizando a MASSAYO [Bittencourt et al. 2009] e foram acrescentadas novas funcionalidades a ele, como a resolução de problemas colaborativos, que é o módulo em que foi realizado o estudo de caso.

A resolução de problemas colaborativos agrupa alunos que já passaram por um determinado assunto para juntos resolverem o problema com o estudante que está atualmente na matéria em questão. Os estudantes indicados são: um que tenha sido aprovado com boa nota, para ajudar os alunos, e outros dois que foram aprovados com notas intermediárias, para que eles possam voltar e aprender mais sobre determinado assunto.

4.2. Recomendação utilizando SEDAM

Para recomendar seria necessário percorrer todos os alunos que já passaram pelo currículo para saber as notas deles e escolher alunos com os níveis indicados. No entanto, essa busca exigiria um alto custo de processamento e de tempo para ser realizada, visto a quantidade de alunos que existem cadastrados no tutor. Dessa forma, foi utilizado um algoritmo de agrupamento que divide os alunos em três grupos, alunos com notas entre 7-8, 8-9 e 9-10. Então é recomendado um estudante de cada grupo criado.

Ao invés de utilizar uma solução própria, que necessitaria de implementação de algoritmos de mineração e pré-processamento dos dados, ele pode fazer uso dos algoritmos de ferramentas consolidadas como o WEKA, apenas invocando os serviços disponibilizados pelo SEDAM.

Para utilizar o SEDAM o desenvolvedor precisa realizar a adaptação do ambiente, ela consiste basicamente em: i) implementar o processo de invocação do *Service Manager* – o processo de invocação é simples, pois o *Service Manager* é um serviço web tradicional; ii) Adaptar o ambiente para tratar o retorno do serviço invocado – o desenvolvedor deve adaptar o ambiente de modo que o mesmo possa utilizar a saída retornada.

O SEDAM disponibiliza alguns serviços de transformação como: i) List2ARFF - este serviço recebe como entrada uma lista composta pelos históricos de acesso dos usuários. ii) OWL2ARFF - Serviço que realiza consulta nas ontologias e transforma os dados em um arff. Caso o ambiente que deseja utilizar o SEDAM utilize outra fonte de dados é necessário estender o SEDAM incluindo um serviço web semântico que realize a transformação dos dados em um ARFF ou em uma Lista.

A adaptação realizada no FraW para utilização do SEDAM consistiu na inclusão de um link que realiza a invocação do service manager e a criação de uma página web que trata a saída, exibindo os alunos retornados. Não foi necessário criar um novo serviço web semântico de transformação para recuperar os dados disponíveis através de ontologias e gerar um ARFF, pois o mesmo já estava implementado no SEDAM.

A Figura 2 apresenta o processo de composição e invocação realizada pelo service manager após a invocação feita pelo FraW.



Figura 2. Composição dos Serviços

Em seguida são descritas as etapas para realizar a recomendação.

1. O estudante clica no link para realização da resolução colaborativa de problema. (Figura 3).
2. O FraW invoca o *Service Manager* passando como parâmetro de entrada o usuário para o qual se deseja recomendar, e de saída, um conjunto de três estudantes para resolver o problema.
3. Depois de realizar a descoberta e composição dos serviços, baseados nos parâmetros de entrada e saída, o *Service Manager* invoca o primeiro serviço,



Figura 3. Tela do FraW - Link para resolução colaborativa de problema

OWL2Arff, esse serviço realiza a transformação dos dados disponibilizados nas ontologias do FraW em um formato que é aceito pelos algoritmos do WEKA, o ARFF. O serviço procura nas ontologias do FraW os alunos que já concluíram o assunto que o estudante está aprendendo, passado como parâmetro de entrada, e cria um arquivo ARFF contendo o nome do estudante e a sua nota naquele currículo. A saída deste serviço é o diretório onde o ARFF foi criado.

4. Depois de gerar o arquivo ARFF, o *Service Manager* seleciona o serviço *simpleK-means* - técnica de agrupamento. Esse serviço agrupa os estudantes por nível e retorna o grupos que foram formados.
5. Por fim, o *Service Manager* executa o serviço de recomendação, que tem como entrada os grupos de estudantes gerados pelo serviço anterior, recupera um aluno de cada grupo e retorna ao *Service Manager* os alunos selecionados. O resultado final retornado pelo *Service Manager* ao ambiente é tratado e apresentado em uma tela que mostra os estudantes sugeridos, com isso eles podem começar a resolver o problema colaborativamente (Figura 4).




Figura 4. Tela do FraW - Recomendação dos estudantes

O estudo de caso apresentado destaca as vantagens e limitações no uso do SEDAM como a disponibilização de mineração de dados educacionais a ambientes e-Learning. Tais vantagens são listadas a seguir: i) reuso – desenvolvedores não necessitarão implementar algoritmos de mineração visto que tais algoritmos já estarão disponíveis pela ferramenta; ii) fácil adaptação de Ambientes e-Learning para o uso mineração de dados

educacionais; iii) as diversas funcionalidades de educacionais fornecidas pelo SEDAM podem ser acessadas por meio de uma mesma invocação, bastando ao desenvolvedor alterar os parâmetros de entrada e a saída desejada para utilizar uma outra funcionalidade educacional; iv) extensibilidade – novas funcionalidades educacionais podem ser facilmente incluídas com a adição de novos serviços semânticos. Sob uma perspectiva da engenharia de software, o gerenciador de serviços equivale ao ponto congelado do framework (*frozen spot*) e os serviços semânticos os pontos de variabilidade da aplicação.

Além disso, o SEDAM disponibiliza as fases de processamento dos dados e mineração de dados educacional. Entretanto, o mecanismo de pré-processamento é disponibilizado apenas para utilização de ontologias e entrada dos dados em formato de lista. É importante frisar que tais mecanismos de pré-ponto congelado do framework (*frozen spot*) e os serviços semânticos os pontos de variabilidade de processamento não foram disponibilizados, pois cada aplicação tem seu formato de persistência dos dados, não sendo viável a implementação de serviços genéricos que executem tal funcionalidade. Contudo, os desenvolvedores podem adicionar serviços para realizar o pré-processamento de acordo com seus interesses.

5. Conclusão e Trabalhos Futuros

O trabalho apresentou um arcabouço para mineração de dados educacionais baseados em serviços semânticos. Esta ferramenta proporciona aos desenvolvedores a facilidade na criação e/ou adaptação de ambientes *e-Learning* para uso da mineração de dados no apoio educacional, pois ela disponibiliza, através de serviços semânticos, funcionalidades como: recomendação de conteúdo para os alunos, recomendação de usuários para colaboração, ajuda a modelar os perfis dos estudantes, entre outros. Tais funcionalidades podem ser utilizadas pelos ambientes apenas invocando o *Service Manager* e adaptando a saída dos serviços ao ambiente.

Foi mostrado um estudo de caso, em um ambiente educacional real, para demonstrar a viabilidade do SEDAM, desde o processo de invocação até a descoberta e composição dos serviços semânticos.

Como trabalhos futuros pretende-se: i) concluir o desenvolvimento da ferramenta visto que a mesma encontra em fase de protótipo, ii) incluir novas ferramentas, aumentando as funcionalidades disponibilizadas, iii) desenvolver novos estudos de casos em diferentes domínios.

Referências

- Bittencourt, I. I., Costa, E., Silva, M., and Soares, E. (2009). A computational model for developing semantic web-based educational systems. *Knowledge-Based Systems*, 22:302–315.
- Calado, I., Barros, H., and Bittencourt, I. I. (2009). An approach for semantic web services automatic discovery and composition with similarity metrics. pages 694–695.
- Markellou, P., Mousourouli, I., Spiros, S., and Tsakalidis, A. (2005). Using semantic web mining technologies for personalized e-learning experiences. *Web-Based Education*, pages 461–826.

-
- Martin, D., Burstein, M., Hobbs, E., Lassila, O., McDermott, D., McIlraith, S., Narayanan, S., Parsia, B., Payne, T., Sirin, E., Srinivasan, N., and Sycara, K. (2004). Owl-s: Semantic markup for web services. Technical report.
- Merceron, Agathe; Yacef, K. (2005). Tada-ed for educational data mining. *Interactive Multimedia Electronic Journal of Computer-Enhanced Learning*, 7.
- Newcomer, E. and Lomow, G. (2004). *Understanding SOA with Web Services (Independent Technology Guides)*. Addison-Wesley Professional.
- Payne, T. R. and Lassila, O. (2004). Guest editors' introduction: Semantic web services. *IEEE Intelligent Systems*, 19(4):14–15.
- Romero, C. and Ventura, S. (2007). Educational data mining: A survey from 1995 to 2005. *Expert Systems with Applications*, 33(1):135 – 146.
- Sibaldo, M. A. A., Neves, A. F. R., Medeiros, F. M., Bittencourt, I. I., and Barros Costa, E. (2008). Fraw - ambiente interativo de aprendizagem para o domínio de fração via web. *Simpósio Brasileiro de Informática na Educação*.
- Silva, D. and Vieira, M. (2002). Using data warehouse and data mining resources for on-going assessment in distance learning. In *IEEE international conference on advanced learning technologies*, pages 40–45.
- Tang, C., Yin, H., Li, T., Lau, R. W. H., Li, Q., and Kilis, D. (2000). Personalized courseware construction based on web data mining. In *WISE '00: Proceedings of the First International Conference on Web Information Systems Engineering (WISE'00)-Volume 2*, page 2204, Washington, DC, USA. IEEE Computer Society.
- Tang, T. and McCalla, G. (2003). Smart recommendation for an evolving e-learning system. *Workshop on Technologies for Electronic Documents for Supporting Learning, International Conference on Artificial Intelligence in Education*, pages 699–710.
- Tang, T. Y. and McCalla, G. (2002). Student modeling for a web-based learning environment: a data mining approach. In *Eighteenth national conference on Artificial intelligence*, pages 967–968, Menlo Park, CA, USA. American Association for Artificial Intelligence.
- Weka (2009). Disponível em <http://www.cs.waikato.ac.nz/ml/weka/>. Acessado em 31 de Agosto de 2009.
- Witten, I. H. and Frank, E. (2005). *Data Mining: Practical Machine Learning Tools and Techniques (Second Edition)*. Morgan Kaufmann.
- Zaane, E. O. and Zaiane, O. R. (2001). Web usage mining for a better web-based learning. In *In Proc. of Conference on Advanced Technology for Education*, pages 60–64.
- Zaiane, O. R. (2002). Building a recommender agent for e-learning systems. In *ICCE '02: Proceedings of the International Conference on Computers in Education*, page 55, Washington, DC, USA. IEEE Computer Society.