

ABORDAGENS BASEADAS EM MINERAÇÃO DE DADOS EM SISTEMAS DE TUTORIA INTELIGENTE

Orlando Bisacchi Coelho

Faculdade de Computação e Informática – Universidade Presbiteriana Mackenzie

Rua da Consolação, 930 – 01302-907– São Paulo – SP – Brazil

orlandoc@mackenzie.br

Resumo

Este artigo revê um subconjunto representativo das principais abordagens adaptativas que tem sido utilizadas no desenvolvimento de Sistemas de Tutoria Inteligente, principalmente as baseadas em Redes Neurais Artificiais. Em seguida, discute os pontos de contato entre a pesquisa em Sistemas de Tutoria Inteligente, os algoritmos de aprendizagem de Redes Neurais Artificiais e as técnicas de Mineração de Dados. Ao final, defende a posição de que a pesquisa em Mineração de Dados, com base em algoritmos de Redes Neurais Artificiais, aplicada a Sistemas de Tutoria Inteligente, é uma linha de pesquisa bastante promissora.

PALAVRAS CHAVE. Mineração de Dados, Sistemas de Tutoria Inteligente, Redes Neurais Artificiais.

Área Principal. *Softcomputing* para Descoberta de Conhecimento, Gerenciamento de Conhecimento e Tomada de Decisão.

Abstract

This paper begins by reviewing a representative subset of the main adaptive approaches used in the project of Intelligent Tutoring Systems. Then, the contact points between research in Intelligent Tutoring Systems, Artificial Neural Networks and Data Mining are discussed. Finally, it is argued that research on Data Mining, based on Artificial Neural Network algorithms and applied to Intelligent Tutoring Systems, is a very promising research area.

KEYWORDS. Data Mining, Intelligent Tutoring Systems, Artificial Neural Networks.

Main Area. *Softcomputing* for Knowledge Discovery, Knowledge Management and Decision Making.

1. Introdução

Um *Sistema de Tutoria Inteligente* (STI) é um sistema de aprendizagem mediado pelo computador que se distingue por desenvolver um modelo do estudante e adaptar a apresentação do material didático às necessidades do estudante. A estrutura padrão de um Sistema Tutor Inteligente (STI) é descrita na Figura 1 (Prentzas e Hatzilygeroulis, 2002).

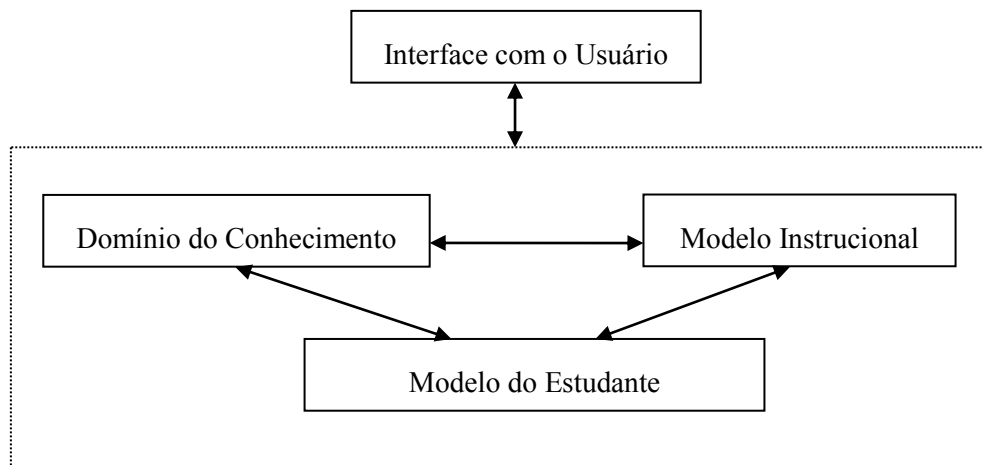


Figura 1. Estrutura padrão de um Sistema de Tutoria Inteligente.
 Adaptada de (Prentzas e Hatzilygeroulis, 2002).

O bloco *Domínio do Conhecimento* corresponde ao conteúdo educacional que se disponibiliza ao aprendizado dos vários estudantes ao longo do curso. Faz parte desse conteúdo um conjunto de *unidades de curso*: teoria, exemplos, atividades e exercícios que dão forma ao conteúdo pedagógico. Também faz parte do Domínio de Conhecimento a *rede de conceitos* que conecta os conceitos que estão instanciados nas unidades de curso e retrata as relações entre os conceitos; por exemplo, as relações de pré-requisito entre conceitos. A rede de conceitos materializa a estrutura pedagógica do curso.

O *Modelo do Estudante* é uma representação do usuário do sistema que captura seus conhecimentos, suas dúvidas e suas aptidões. Entre os aspectos de cada estudante que interage com o sistema que se pretende capturar no modelo do estudante podemos citar:

- *background* a respeito do estudante;
- seu nível de conhecimento, a cada momento, do conteúdo que se quer ensinar;
- suas habilidades de aprendizado e preferências em termos de estratégias de ensino e do tipo de apresentação do material educacional que mais lhe beneficia;
- seu objetivo de aprendizagem corrente e
- a história das suas interações com o sistema.

O *Modelo Instrucional* (ou Modelo Pedagógico) é o responsável pela concretização do processo de ensino. Ele constrói o plano de ensino para cada aluno, dando corpo a uma estratégia de ensino. Para isso ele leva em consideração as necessidades e preferências do estudante e o histórico de interações do usuário – derivados do Modelo do Estudante – e o conteúdo pedagógico, representado pela rede de conceitos. Ele também utiliza o Modelo do Estudante para selecionar as estratégias de ensino melhor adequadas para cada estudante em cada momento do seu particular processo de ensino-aprendizagem, de acordo com as suas preferências de tipo de apresentação do material de ensino. O Modelo Instrucional é também o responsável pela avaliação do aprendizado do aluno. A partir de cada avaliação, ele replaneja o processo de ensino. E também atualiza o Modelo do Estudante, em termos de nível de conhecimento, preferência de apresentação do material, objetivo de aprendizagem corrente e histórico de interações.

Nessa visão, o Domínio do Conhecimento é estático, no sentido de que, uma vez projetado para uma dada disciplina e um conjunto-alvo de alunos em potencial, ele não precisa sofrer alterações automaticamente¹. Já o Modelo do Estudante e o Modelo Instrucional necessariamente devem ser adaptativos.

Minimamente, o Modelo do Estudante deve ser atualizado de forma a capturar o histórico de interações e o nível de conhecimento e o objetivo corrente de aprendizagem. Técnicas não adaptativas podem ser utilizadas na construção do Modelo do Estudante (Schiaffino e Amandi, 2009). Por exemplo, a obtenção de informação explicitamente fornecida pelo usuário, a observação de suas ações e *feedback* fornecido pelo usuário. Ou a construção de um conjunto de estereótipos que representam conjuntos de potenciais usuários do STI.

Abordagens não adaptativas também podem ser usadas no projeto do Modelo Instrucional. Por exemplo, as baseadas em Planejamento (Nkambou e Kabanza, 2001), em Sistemas de Recomendação e Filtragem Colaborativa (Tang e McCalla, 2003), Ontologias (Karampiperis e Sampson, 2004), ou Raciocínio Baseado em Casos (Funk e Conlan, 2009).

Entretanto, recentemente, uma série de técnicas adaptativas vem sendo usadas com o objetivo de desenvolver Modelos do Estudante e Instrucional mais poderosos. Esse é um dos objetivos do presente trabalho: discutir o uso de técnicas adaptativas no projeto de Sistemas Tutores Inteligentes, e uma dessas técnicas em particular detalhe: Redes Neurais Artificiais. Na próxima seção discutiremos algumas técnicas adaptativas que tem sido usadas no projeto dos STIs. Na seção seguinte focaremos nas técnicas baseadas em Redes Neurais Artificiais. Por fim, discutiremos como o paradigma adaptativo, exemplificado pelas Redes Neurais Artificiais, leva, num desenvolvimento natural, a considerar o uso de abordagens baseadas em Mineração de Dados no desenvolvimento dos novos Sistemas Tutores Inteligentes.

2. Técnicas Adaptativas em Sistemas de Tutoria Inteligente

Uma técnica pode ser dita adaptativa quando ela incorpora um algoritmo que, de forma autônoma, isto é, independente de controle externo, seja capaz de alterar os parâmetros e as estruturas de dados que controlam o próprio algoritmo, de modo a operar sempre de forma mais apropriada, mesmo num ambiente mutável. Uma das vantagens de se usar técnicas adaptativas no projeto de um STI vem da possibilidade de lidar com uma ampla gama e quantidade de estudantes, de diversos *backgrounds*, que tem objetivos educacionais e estratégias de aprendizado as mais diversificadas (Brusilovsky, 1998).

A construção e manutenção de um Modelo do Estudante mais sofisticado se beneficiam da utilização de abordagens adaptativas (Schiaffino e Amandi, 2009). Por um lado, do ponto de vista do STI, cada nova interação do estudante com o sistema deve possibilitar a oportunidade de construção ou revisão do Modelo do Estudante. Além de permitir uma atualização do nível de conhecimento do estudante, cada interação deve possibilitar ao sistema *aprender* as preferências do estudante em relação a estratégias de ensino e ao tipo de apresentação do material educacional que ele prefere. E essa informação, sempre atualizada, vai ser essencial para o bom funcionamento do Modelo Instrucional.

Da mesma forma que o Modelo do Estudante, o Modelo Instrucional também deve ser encarado como um sistema que se beneficia, em seu projeto, do uso de técnicas adaptativas. Conforme Schiaffino e Amandi (2009), abordagens adaptativas podem ser usadas para:

- definir o próximo conceito a ser ensinado;

¹ Porém, (Crampes et al, 2006) apresenta um exemplo de como uma representação de conhecimento pode ser adaptativa.

- escolher a próxima tarefa educacional a ser apresentada;
- fornecer apoio adaptativo à colaboração, o que consiste, por exemplo, na identificação de grupos de estudantes que irão colaborar no processo de aprendizagem comum;
- fornecer suporte adaptativo à navegação, ajudando o estudante na navegação pelo material educacional e
- adaptar o conteúdo multimídia que será apresentado ao aluno a seus objetivos e nível de aprendizagem.

Deve-se notar que as duas últimas tarefas listadas acima cabem dentro do referencial teórico da hipermídia adaptativa (Brusilovsky, 1996) – o estudo de técnicas que adaptam o material hipermídia às necessidades de navegação do usuário; sendo que no caso particular o material é de cunho educacional.

Ao permitir individualizar o sequenciamento do material instrucional, tanto em termos de conceitos como em termos de atividades, adaptando-o a cada estudante, o Modelo Instrucional permite um aproveitamento muito melhor da situação educacional por parte de cada estudante. Da mesma forma, a análise inteligente das soluções de problemas desenvolvidas pelos alunos – que permite identificar os conceitos deficientes e as atividades mais apropriadas para aprendê-los para cada aluno – e o apoio interativo à solução de problemas são tornadas possíveis nos STI construídos com técnicas adaptativas. Um exemplo nesse sentido é descrito em (Gamboa, 1999), onde Redes Bayesianas são usadas para aprender os conceitos já aprendidos pelo estudante e, a partir disso, definir qual conceito deve ser introduzido.

3. Técnicas Baseadas em Redes Neurais Artificiais em Sistemas de Tutoria Inteligente

Algumas das técnicas adaptativas mais bem-sucedidas são baseadas em *Redes Neurais Artificiais* (RNA). As Redes Neurais Artificiais são sistemas computacionais inspirados no Sistema Nervoso Central (Haykin, 2009). Elas abstraem, em alto nível, algumas das características do Sistema Nervoso Central, entendido então como um sistema computacional. O processamento maciçamente paralelo, baseado em um grande número de unidades computacionais capazes de processamento tão somente numérico e muito simples, que estão maciçamente conectadas ente si, através de conexões que tem pesos – parâmetros numéricos adaptáveis – são algumas características básicas das RNAs. Cada uma dessas unidades tem um nível de ativação – um valor numérico que é um análogo da frequência média com que um neurônio biológico emite um pulso elétrico. Assim como no Sistema Nervoso Central, cada unidade recebe informação (ativação) proveniente de uma grande quantidade de outras unidades. Da mesma forma, a conexão de uma unidade A para uma unidade B pode ser ou excitatória ou inibitória, dependendo como a ativação da unidade A influencia a ativação da unidade B. Se quanto mais ativa a unidade A mais ativa fica B então a conexão de A para B é excitatória. Se quanto mais ativa A menos ativa B ficar então a conexão é inibitória. Dado um par de unidades A e B, em que A se conecta a B, a influência de A sobre B pode ser maior ou menor; mais ou menos excitatória ou inibitória. Para capturar isso, associamos a cada par de unidades, onde A se conecta a B, um peso: um valor numérico que é positivo se a conexão é excitatória; negativo se ela é inibitória e tanto maior em módulo quanto maior for a influência de A sobre B. Cada unidade numa RNA recebe ativação de várias unidades e calcula uma média ponderada das várias ativações recebidas, onde essa ponderação é feita pelos pesos associados às conexões das unidades para ela. A partir dessa ponderação, a ativação da unidade é calculada, por meio de uma função de ativação não linear. Dessa forma, cada unidade comporta-se como um integrador não linear de múltiplas informações recebidas, as quais informações podem ser inclusive

contraditórias. E, a partir de todas essas informações recebidas, a unidade toma uma decisão: pulsar com uma determinada frequência.

O aspecto mais importante das Redes Neurais Artificiais é que elas são sistemas computacionais adaptativos. Isto é, dados exemplos de uma tarefa que a RNA deve executar, existem algoritmos de aprendizagem neural (mais ou menos inspirados no aprendizado biológico) que fazem com que os pesos da rede sejam adaptados de forma a realizar com bastante acerto a tarefa, sem que para tal precisemos um algoritmo que descreve *como* a tarefa deve ser realizada. Isto é, assim como no Sistema Nervoso Central, a RNA autonomamente se adapta ao meio-ambiente (o conjunto de exemplos a que ela tem acesso, que pode até ser mutável ao longo do tempo), de forma a desempenhar uma dada tarefa de forma apropriada.

Existem resultados teóricos que provam que, a princípio, qualquer tarefa que pode ser realizada por um computador tradicional pode ser realizada por uma rede neural artificial (Siegelman e Sontag, 1991); isto é, alguns sistemas neurais artificiais tem poder de computação universal. As RNAs têm sido usadas em uma ampla gama de aplicações práticas, nas áreas mais distintas. Em Sistemas Tutores Inteligentes, as redes neurais artificiais vem começando a serem utilizadas, como técnicas que permitem a construção de sistemas adaptativos.

Por exemplo, Vendlinski e Stevens (2000) usam uma RNA do tipo Mapa Auto-organizado (SOM) (Kohonen, 1989), para agrupar estudantes pela maneira como eles tentam resolver certos problemas pré-definidos.

Martins e colegas usam redes neurais artificiais para definir a apresentação do material instrucional ao aluno de acordo com seu nível atual de conhecimento, seus padrões prévios de navegação no STI baseado na Web e, principalmente, o estilo de aprendizagem do aluno (Martins et al, 2003).

(Dorça et al, 2009) descreve uma RNA treinada pelo algoritmo LVQ (SOM, 1989) para classificar cada aluno quanto à adequação do material didático que lhe vem sendo apresentado. Para isso, leva-se em consideração o grau de acerto das respostas aos testes, o tempo gasto em respondê-los, o tempo gasto nas páginas, a quantidade de operações de *scroll* em páginas e a participação do aluno em *chats* ou fóruns. De acordo com a classificação obtida para o aluno, o material instrucional a ser apresentado é escolhido.

Entretanto, o trabalho mais sofisticado em termos de bom uso das técnicas específicas de Redes Neurais Artificiais e, certamente, um dos pioneiros no uso de RNAs em Sistemas de Tutoria Inteligente, é o reportado em (Harp et al, 1993). Os autores se propõem a desenvolver um modelo do estudante baseado em RNAs. Para tal eles usam uma rede SOM. Essa rede recebe como entrada uma especificação, em forma tabular, das respostas que cada aluno produz para uma série de questões. E produz um agrupamento dos alunos baseado em suas similaridades em termos de conhecimentos e habilidades. O objetivo dos autores é usar a RNA como ferramenta para criar um Modelo do Estudante universal. Isto é, um componente do STI que permita, a partir de alguns dados facilmente adquiríveis de um aluno qualquer, gerar, na saída da RNA, uma representação do conhecimento do estudante que seja suficiente para informar as decisões do Módulo Instrucional.

Um dos aspectos mais interessantes do trabalho de Harp e colegas é a visão de que uma forma de criar um modelo de um dado aluno é tomar por base um vasto conjunto de estudantes. A partir desse conjunto, características que distinguem (ou agregam) os membros do conjunto podem ser extraídas. E, a partir dessas características, um modelo de cada particular aluno pode ser obtido. Esse é exatamente o ponto de vista adotado em *Mineração de Dados*, uma área da Ciência da Computação que busca extrair sentido, conhecimento, a partir de grandes bases de dados. Pode-se argumentar, a princípio, que a área de Sistemas Tutoriais Inteligentes pode se beneficiar da abordagem em termos de Mineração de Dados implícita em (Harp et al,

1993). Explicitar essa atitude e delinear algumas possibilidades a serem exploradas é o objetivo da próxima seção.

4. Explorando a Aplicação de Técnicas de Mineração de Dados a Sistemas de Tutoria Inteligente

Assim como a área de pesquisa de Sistemas Tutores Inteligentes decorreu da combinação entre Informática Educacional e Inteligência Artificial, a área de Mineração de Dados (Han e Kamber, 2006) surgiu com a aproximação entre as áreas de Banco de Dados e Inteligência Artificial. O objetivo da área é, dada uma base de dados de grande porte, descobrir, extrair e explicitar conhecimento que está presente na base de forma implícita. Isto é, induzir conhecimento novo a partir dos dados presentes na base. Os algoritmos de Mineração de Dados buscam identificar padrões nos dados e, quando possível, extrair regras a partir desses padrões.

As principais tarefas computacionais que podem ser realizadas usando técnicas de Mineração de Dados são:

- a identificação de associações entre itens na base de dados que aparecem com regularidade;
- o agrupamento de itens na base que são similares entre si;
- a classificação de um novo item em uma dentre as classes já pré-definidas;
- regressão – a descoberta de relações numéricas entre os itens;
- previsão de valores futuros para itens na base que variam ao longo do tempo e
- a visualização de uma massa de informação, contida na base, de forma tal que possa ser interpretável por humanos.

Para todas as tarefas descritas acima – menos a primeira² – as redes neurais artificiais são uma das melhores ferramentas que existem. Nesse sentido, muitos algoritmos de aprendizagem neural são usados para mineração de dados (Bigus, 1996).

Muitos, provavelmente a maioria dos Sistemas Tutores Inteligentes hoje são sistemas baseados na Web (no duplo sentido de que usam tecnologia Web e são acessíveis via Web). Como o caráter adaptativo, seja no Modelo do Estudante seja no Modelo Instrucional, está presente na grande maioria deles, hoje em dia boa parte dos STIs podem ser caracterizados como Sistemas Educacionais Adaptativos Baseados na Web (Brusilovsky, 1998). O fato de esses sistemas serem baseados na Web a princípio faz com que eles tenham que se adaptar a usuários de mais variados perfis do que se eles fossem sistemas isolados da rede. Além do mais, ao longo do tempo, é muito provável que eles venham a ser expostos a uma ampla gama de interações com usuários. Essas interações, uma vez projetados sistemas de coleta e armazenamento apropriados, podem gerar bases de dados de porte significativo sobre as quais pode-se rodar algoritmos de Mineração de Dados, de modo a extrair conhecimento dessas bases. E é nesse sentido que a Mineração de Dados pode contribuir para o projeto dos STIs contemporâneos³.

² Redes Neurais Artificiais não são as únicas técnicas usadas em Mineração de Dados. Técnicas Estatísticas e técnicas desenvolvidas na Inteligência Artificial Simbólica, dentro da subárea de Inteligência de Máquina, também são usadas.

³ Entretanto, não é de modo algum essencial que o STI seja um sistema baseado na Web para que valham as conclusões do presente artigo. Essencial é que o sistema seja adaptativo e tenha uma quantidade de acessos e interações de porte razoável.

Quando se usa um algoritmo de aprendizagem neural como o SOM para identificar alunos que tem características semelhantes entre si – por exemplo, de modo a identificar grupos homogêneos de alunos numa turma – ou se usa uma RNA treinada pelo algoritmo *backpropagation* (Rumelhart, Hinton e Williams, 1986) para tentar prever o desempenho futuro de um aluno, as características dos alunos que serão usadas pelo algoritmo de aprendizagem neural para tal não são pré-escolhidas pelo projetista. As próprias características que o algoritmo irá utilizar, bem como a importância relativa de uma característica sobre a outra, são automaticamente, autonomamente estabelecidas pelo próprio algoritmo. Desta forma, ao tratar o desenvolvimento do Modelo do Estudante como um problema de Mineração de Dados, elimina-se a dificuldade de ter de *projetar*, manualmente, o Modelo do Estudante. Isto é, torna-se desnecessário escolher um conjunto de características que, em conjunto, serão as constituintes do Modelo do Estudante. Ao invés disso, a escolha dessas características e o balanceamento de quais características são mais importantes passam a ser *determinados automaticamente* pelo algoritmo adaptativo.

O mesmo raciocínio se aplica ao desenvolvimento do Modelo Instrucional. Como discutido anteriormente, o MI se beneficia sobremaneira de uma abordagem adaptativa. Uma solução baseada em Mineração de Dados prescindiria da escolha manual de sobre quais características se daria a adaptação. Por exemplo, num tal referencial teórico, não é preciso pré-definir se o mapeamento de estudante material educacional hipermédia terá que capturar ou não o número de *scrolls* de tela ou o número médio de minutos gasto em cada página e, principalmente, qual peso relativo dar a cada uma dessas informações. Será o algoritmo o responsável por identificar as características relevantes.

Assim como uma série de aplicações, nas mais variadas áreas, passaram a depender de métodos adaptativos, tais como as RNAs, para um salto de qualidade em termos de desempenho, pode-se argumentar que a aplicação de uma abordagem de Mineração de Dados deverá trazer aos Sistemas de Tutoria Inteligente ganhos significativos.

5. Conclusão

Pelas razões aqui expostas, parece razoável argumentar que a aplicação de técnicas de Mineração de Dados aos Sistemas de Tutoria Inteligente contemporâneos é uma tendência irreversível. A polinização cruzada entre as áreas permite entrever oportunidades de pesquisa bastante atraentes.

Um rascunho superficial para uma possível abordagem concreta consistiria, primeiro, em identificar um STI que esteja em uso, com um número razoável de usuários. A partir disso, escolher uma tarefa de mineração de dados que seja relevante para o sistema em questão, que implique em um ganho de qualidade significativo. E criar condições, então, para que os dados coletados durante o uso do sistema sejam apropriados para que neles se possa, posteriormente, executar um algoritmo de mineração de dados apropriado para a tarefa (baseado em redes neurais ou não). Por fim, rodar o algoritmo e analisar as repostas obtidas, extraindo então o conhecimento adicional que represente o ganho de qualidade pretendido para o STI.

O uso Mineração de Dados com fins educacionais não se mostra promissor somente em relação aos Sistemas de Tutoria Inteligentes. Essa abordagem é extremamente adequada no caso de qualquer situação em que uma massa de dados possa servir de material para extrair conhecimento que possa auxiliar o processo de ensino-aprendizagem. Uma outra classe de ambientes computacionais com fins educacionais que parece extremamente promissora para o desenvolvimento aqui delineado é a dos ambientes virtuais de aprendizagem (Dillenbourg, 2000).

Referências

- BAKER, R. S. J. D.**, Data Mining for Education, em McGaw, B., Peterson, P., Baker, E. (Eds.) *International Encyclopedia of Education (3rd edition)*, vol. 7, pp. 112-118. Oxford, UK: Elsevier, 2010.
- BAKER, R. S. J. D.**, Mining Data for Student Models, em Nkmabou, R., Mizoguchi, R., & Bourdeau, J. (Eds.) *Advances in Intelligent Tutoring Systems*, pp. 323-338. Secaucus, NJ: Springer, 2010.
- BAKER, R. S. J. D. e YACEF, K.** (2009), The State of Educational Data Mining in 2009: A Review and Future Visions. *Journal of Educational Data Mining*, 1 (1), 3-17.
- BARUQUE C. B., AMARAL, M. A., BARCELLOS, A., FREITAS, J. C. e LONGO, C. J.** (2007), *Analysing users' access logs in Moodle to improve elearning*. Proc. of the 2007 Euro American Conference on Telematics and Information Systems, ACM, New York, USA.
- BIGUS, J.**, *Data Mining with Neural Networks*. New York: McGraw-Hill, 1996.
- BRUSILOVSKY, P.** (1996), Methods and techniques of adaptive hypermedia. *User Modeling and User Adapted Interaction*, v 6, n 2-3, pp. 87-129.
- BRUSILOVSKY, P.** (1998), *Adaptive Educational Systems on the World-Wide-Web: A Review of Available Technologies*. Proc. Intelligent Tutoring Systems, Workshop WWW-Based Tutoring, 4th. International Conference on Intelligent Tutoring Systems.
- CASTRO, F., VELLIDO, A., NEBOT, À. e MUGICA, F.**, Applying Data Mining Techniques to e-Learning Problems, em L. Jain, R. Tedman, D. Tedman (Eds.) *Evolution of Teaching and Learning Paradigms in Intelligent Environment*, Springer, pp. 183-221, 2007.
- CRAMPES, M., RANWEZ, S., VILLERD, J., VELICKOVSKI, F., MOONEY, C., EMERY A. e MILLE N.** (2006), Concept Maps for Designing Adaptive Knowledge Maps. *Information Visualization* 5: 211.
- CRIPPS, A.** (1996), *Using Artificial Neural Nets to Predict Academic Performance*. Proc. 1996 ACM Symposium on Applied Computing, ACM, New York.
- DILLENBOURG, P.** (2000), *Virtual learning environments*. EUN Conference 2000: Learning in the new millennium: Building new education strategies for schools. Workshop on Virtual Learning Environments.
- DORÇA, F., LOPES, C., FERNANDES, M. e LOPES, R.** (2009), Adaptativity Supported by Neural Networks in Web-Based Educational Systems. *Journal of Education, Informatics and Cybernetics, Vol 1* (2).
- FUNK, P e CONLAN, O.** (2002), *Using Case-Based Reasoning to Support Authors of Adaptive Hypermedia Systems*. European Workshop on Case-Based Reasoning, EWCBR 2002.
- GAMBOA, H.** (1999), *Aprender a aprender*. Fourth Workshop on Biomedical Engineering, Ana Fred (Ed.), IST, DEEC, agosto.
- HAN, J. e KAMBER, M.**, *Data Mining: Concepts and Techniques*, 2nd. edition, Morgan Kaufmann, 2006.
- HARP, S. A., SAMAD, T. e VILLANO, M.**, *Modeling Student Knowledge with Self-Organizing Maps*. AL-TR-1992-0114, Air Force Materiel Command, Brooks Air Force Base, Texas, USA, February, 1993.

- HAYKIN, S.**, *Neural Networks and Learning Machines*. Upper Saddle River: Pearson Education, 2009.
- KARAMPIPERIS, P. e SAMPSON, D.** (2004), *Adaptive Instructional Planning using Ontologies*. ICALT '04 Proc. of the IEEE International Conference on Advanced Learning Technologies IEEE Computer Society Washington, DC, USA.
- KOHONEN, T.**, *Self-Organizing and Associative Memory*, 3rd ed. Heidelberg: Springer, 1995.
- MARTINS, W., MEIRELES, V., MELO, F. R. e NALINI, L. E.** (2003), *Estilos de Aprendizagem em Educação a Distância*. Anais do 10^o. Congresso Internacional ABED de Educação a Distância. Porto Alegre: ABED.
- NKAMBOU, R. e KABANZA, F.** (2001), Designing Intelligent Tutoring Systems: A Multiagent Planning Approach. *ACM SIGCUE Outlook*, 27, Issue 2, March.
- JUNEMANN, M A P., LAGOS, P. S. e ARRIAGADA, R. C.** (2007), *Neural Networks to Predict Schooling Failure/Success*. Proc. of IWINAC (2) 2007: 571-579.
- PRENTZAS, J. e HATZILYGEROUDIS, I.** (2002), *Intelligent Educational Systems with Individualized Learning*, Proc. of the 4th International Workshop on Computer Science and Information Technology (CSIT-02), 18-20 September, Patras, Greece.
- ROMERO, C. e VENTURA, S.** (2007), Educational data mining: A survey from 1995 to 2005. *Expert Systems with Applications*, Volume 33, Issue 1, pages 135-146, July.
- ROMERO, C. e VENTURA, S.** (2010), Educational data mining: A Review of the State of the Art. *IEEE Transactions on Systems, Man, and Cybernetics, Part C: Applications and Reviews*, Vol. 40 (6): 601 – 618, Nov..
- ROMERO, C., VENTURA, S. e GARCÍA, E.** (2008), Data mining in course management systems: Moodle case study and tutorial. *Computers and Education*, 51(1), 368–384.
- ROMERO, C., VENTURA, S., ESPEJO, P. G. e HERVAS, C.** (2008), Data Mining Algorithms to Classify Students. In Proceedings of the 1st International Conference on Educational Data Mining, pp. 8-17.
- RUMELHART, D. E., HINTON, G. E. e WILLIAMS, R. J.** (1986), *Learning Internal Representations by Error Propagation*, em D. E. Rumelhart, J. L. McClelland and the PDP Research Group (eds.) *Parallel Distributed Processing*, Vol. 1.
- SCHIAFFINO, S. e AMANDI, A.** (2009), *Intelligent User Profiling*. Artificial Intelligence, Berlin: Springer-Verlag.
- SIEGELMANN, H. T. e SONTAG, E. D.** (1991), Turing Computability with Neural Networks, *Applied Mathematics Letters*, 4(6), 1991, pp. 77-80.
- TANG, T.Y. e 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 (AIED 2003).
- VENDLINSKI, T. e STEVENS, R.**, The Use of Artificial Neural Nets (ANN) to Help Evaluate Student Problem Solving Strategies, em B. Fishman & S. O'Connor-Divelbiss (Eds.), Fourth International Conference of the Learning Sciences (pp. 108-114). Mahwah, NJ: Erlbaum, 2000.