

Sistemas inteligentes na organização de conteúdos didáticos personalizados

Francisco Ramos de Melo
Mestre em Engenharia Elétrica e de Computação -
Universidade Federal de Goiás
Professor da Faculdade Latino Americana de Anápolis
Professor da Universidade Federal de Goiás - Goiânia
e-mail: franciscor@latinoamericana.edu.br

Viviane Meireles
Mestre em Engenharia Elétrica e de Computação -
Universidade Federal de Goiás
Coordenadora e professora do curso de Ciência da
Computação da Faculdade Latino Americana - Anápolis
Professora da Universidade Federal de Goiás - Goiânia
e-mail: meireles@latinoamericana.edu.br

Sirlon Diniz de Carvalho
Mestre em Engenharia Elétrica e de Computação -
Universidade Federal de Goiás
Professor da Faculdade Latino Americana - Anápolis
Professor da Universidade Federal de Goiás - Goiânia
e-mail: diniz@latinoamericana.edu.br

Weber Martins
Doutor em Dphil In Electronics Artificial Neural
Networks - University of York, YORK, Inglaterra
Professor da Universidade Federal de Goiás - Goiânia
e-mail: weber@pireneus.eee.ufg.br

Lauro Eugênio Guimarães Nalini
Doutor em Psicologia - Universidade de Brasília
Professor da Universidade Federal de Goiás - Goiânia
e-mail: legn@ucg.br

Resumo

Este artigo apresenta a utilização de técnicas de inteligência artificial para personalizar conteúdos didáticos em ambientes de ensino não presencial. Para tal, é utilizado um meio de identificar e generalizar o padrão do aprendiz perante um sistema tutor inteligente (STI), tendo por base uma rede neural artificial (RNA). Conforme o padrão identificado pela RNA, é pré-estabelecido o caminho que pretende ser o mais adequado ao perfil do aprendiz. Para considerar o desempenho momentâneo deste aprendiz, foi implementado um sistema de regras fornecidas por especialistas, caracterizando como um sistema inteligente híbrido. A combinação destas duas técnicas, possibilitou a apresentação de um conteúdo didático personalizado e reativo aos diferentes momentos da leitura deste conteúdo. Os resultados apresentados demonstraram o grande potencial do sistema como ferramenta facilitadora em ambientes de ensino/aprendizagem não presencial.

Palavras-chave: educação a distância, estilos de aprendizagem, tipos psicológicos, redes neurais artificiais, sistemas tutores inteligentes.

Abstract

This paper presents the use of artificial intelligence's techniques on personalized course contents in distant learning environments. In order to pursuit this target, it is employed an instrument to identify and generalize the learner pattern by an intelligent tutorial system (ITS), based on artificial neural network. According to the pattern identified by the neural network, it is defined the way which is well adjusted to the learner style. To consider the performance of the learning in a specific moment, it was implemented a set of specialist's rules, leading to a hybrid intelligent system. The integration of these two techniques has made possible the building of a personalized and reactive course content that is suited to different moments of the reading of this material. Results have demonstrated the great potential of the system as a facilitator tool in environments of adult education and distant learning.

Key-words: distant education, styles of learning, psychological types, artificial a neural net, intelligent tutorial system.

Inteligência Artificial

A automatização de sistemas utilizando computadores tem sido empregada nas mais diversas áreas de atuação, proporcionando maior velocidade e precisão na execução de tarefas e no processamento de dados. Num sistema de computação convencional, a solução do problema é desenvolvida de acordo com a criatividade do programador diante do problema exposto. Desta forma, estruturas são criadas para tratar a situação conforme as possibilidades visualizadas. Diante de uma nova situação, o sistema construído poderá falhar devido ao fato dessa situação não ter sido prevista por quem tenta desenvolver a solução. Nos sistemas de computação inteligente são criados mecanismos que permitem encontrar soluções para situações novas ou não previstas pelo programador. Desta forma, a qualidade das soluções está diretamente ligada ao conhecimento da situação problemática apresentada e ao adequado desenvolvimento de uma solução computacional (algoritmo). Assim, para entradas de dados não previstas, mesmo pertencendo à classe intermediária das implementadas, pode não haver resposta, ocasionando falhas em momentos críticos [MELO 2003].

O paradigma dos sistemas inteligentes introduziu uma importante mudança nas aplicações computacionais. Os sistemas inteligentes, de forma mais generalizada, imitam a forma humana de pensar. São estruturados de tal forma que, após o período de “aprendizagem”, são capazes de generalizar os padrões de entrada do problema e emitir uma resposta, mesmo para os pontos não previstos (conhecidos) anteriormente. De uma forma geral, podemos dizer que um sistema inteligente é composto de três elementos básicos: sensores, atuadores e o sistema, conforme ilustrado na Figura 1. O sensor é o elemento de entrada, por onde o sistema “percebe” o mundo, enviando esta percepção para o sistema que busca, na sua organização, uma solução a ser apresentada nos elementos atuadores (saída) [NORVIG 1997].

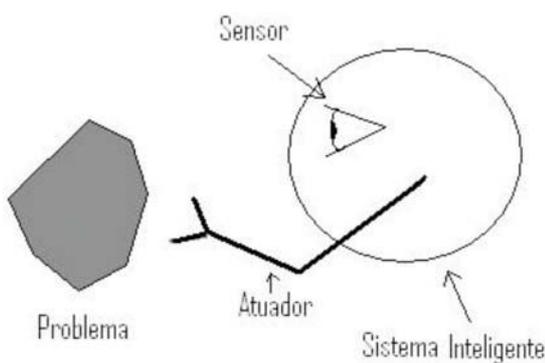


Figura 1 - Representação de um Sistema Inteligente

As técnicas para implementar a Inteligência Artificial (IA) são classificadas em duas categorias: a clássica e a conexionista. A IA clássica, também denominada de simbólica, procura organizar os processos de produção de conhecimento em regras e outras formas correlatas que possam ser automaticamente organizadas e apresentadas pelo sistema diante das situações (NORVIG 1997). Já a IA conexionista, onde predomina a utilização de Redes Neurais Artificiais (RNAs) (HAYKIN 2000), procura organizar o conhecimento em células e suas combinações. Seu funcionamento é semelhante ao funcionamento do cérebro humano e como esta é a estrutura predominante neste trabalho desenvolvido, convém detalhar um pouco mais o seu funcionamento.

As Redes Neurais Artificiais (RNAs) imitam a maneira do cérebro humano processar informações. As RNAs são estruturas de processamento distribuído e paralelo viabilizadas, principalmente, por meio de software (programa) de computador ou hardware (HAYKIN 2000). Para entender seu funcionamento, devemos entender como funciona o neurônio biológico.

A estrutura do neurônio biológico é ilustrada na Figura 2. Esta célula tem três seções distintas e inter-relacionadas: i) componente que recebe os impulsos nervosos, constituída pelos dendritos; ii) o corpo da célula que recebe os impulsos através dos dendritos e transforma-os em outro tipo de impulso nervoso, e iii) o axônio que transmite o impulso gerado pelo corpo da célula para outros neurônios. A conexão feita entre o axônio de um neurônio e o dendrito de outro neurônio é denominada “sinapse”. As sinapses formam as ligações entre os neurônios compondo, assim, as redes neurais. As sinapses funcionam como válvulas, sendo capazes de controlar a transmissão de impulsos (fluxo de informação) entre os neurônios na rede neural. O efeito das sinapses é variável e esta variação implementa a capacidade de adaptação ao neurônio (FAUSETT 1994).

Na implementação de RNAs deste trabalho foi utilizado o modelo proposto de neurônio artificial (nodo), cuja estrutura e funcionamento é similar ao neurônio biológico. A Figura 3 ilustra o modelo do nodo. Podemos observar que os dendritos são formados pelas entradas (x_1, x_2, \dots, x_n) e são combinadas com os pesos (w_1, w_2, \dots, w_n), responsáveis pelo reforço ou atenuação do estímulo. O corpo do nodo é o local onde os estímulos são somados (“ ”) e, caso atinjam um valor pré-estabelecido pela função limiar (Q), produzirão um valor de saída, conforme a função de ativação utilizada (MCCULLOCH 1943) e (TAFNER 1995).

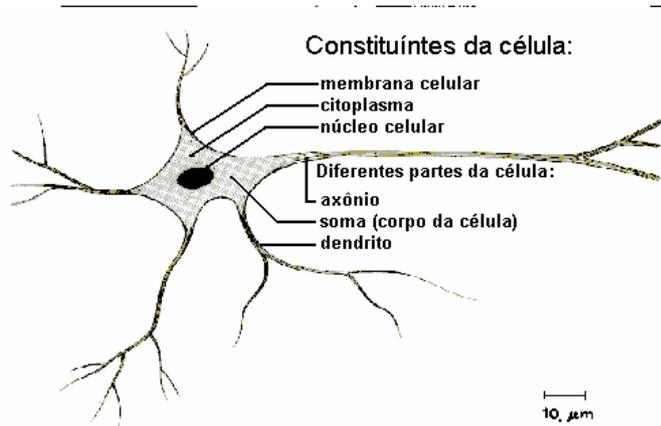


Figura 2 - Estrutura do neurônio biológico

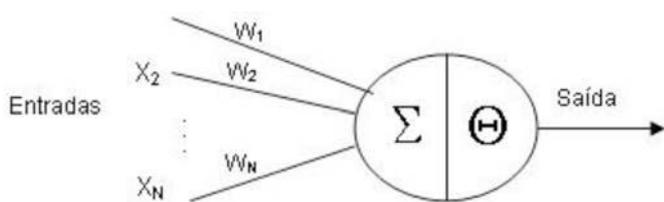


Figura 3 - Estrutura do neurônio artificial

O neurônio artificial, analogamente ao que ocorre no cérebro, se interconecta com outros neurônios, formando a rede neural artificial, como ilustrado na Figura 4. Assim, é possível criar estruturas para generalização de padrões através de variadas entradas, produzindo uma ou mais saídas que poderão representar uma ação ou objeto do mundo real (padrão) como resposta aos diferentes dados apresentados na entrada. A fase de aprendizado (normalmente descrita como “treinamento da rede”) trata do ajuste adequado dos pesos, possibilitando a retenção das características de padrões conhecidos e, inclusive, o emprego da rede na generalização/classificação de novos padrões (HAYKIN 2000).

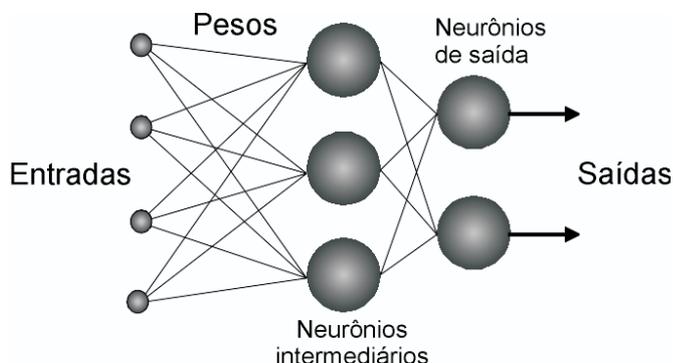


Figura 4 - Rede Neural Artificial (RNA)

Em termos gerais, uma RNA possui o seguinte funcionamento: após especificada a estrutura (como os

neurônios serão interconectados), uma série de exemplos (conjunto de treinamento) é apresentada para treinar a RNA no reconhecimento dos padrões. Como mencionado acima, este treinamento é denominado de “fase de aprendizagem” da rede. Nesta fase, os pesos das entradas de cada neurônio são ajustados, conforme os exemplos apresentados, permitindo a adaptação da rede. Ao final desta fase, a rede estará “treinada” e capacitada a reconhecer os padrões que lhe forem apresentados, bem como capacitada a identificar novos padrões, classificando-os dentro de um dos padrões previamente “aprendidos”. Assim, a rede não dirá que o novo padrão não existe, mas, sim, conforme suas características adquiridas, que o padrão se assemelha a algum dos padrões que ela conhece (FAUSETT 1994) (TAFNER 1995).

Para aplicação específica baseada em redes neurais artificiais são necessárias diversas etapas, ilustradas na Figura 5. A coleta dos dados reúne informações que serão utilizados nas fases de treinamento e de validação. No pré e pós-processamento dos dados, acontece a formatação dos dados do padrão tradicional para o utilizado pela RNA e vice-versa. O projeto da estrutura da rede compreende a definição de detalhes da RNA. No treinamento, uma amostra representativa da população que se deseja fazer a classificação é utilizada para a “aprendizagem”. Quanto mais representativa for a amostra, melhor será a capacidade de resposta da rede na identificação de novos padrões. Após o treinamento, avalia-se a rede com outra amostra, denominada “conjunto de validação”, extraída da mesma população do conjunto de treinamento. A partir desta amostra, verifica-se o índice de resposta da rede aos padrões apresentados. Se o índice estiver dentro de limites esperados (pré-estabelecidos), a rede estará pronta para utilização. Depois de treinadas e validadas, as redes neurais são utilizadas para tarefas de classificação, otimização ou auto organização, dependendo da natureza do problema a ser tratado. Classificar um dado individual é associar esse dado a uma classe de padrões já conhecida pela rede. A tarefa de associação faz o reconhecimento do dado individual baseado em aspectos deste ou de outros dados individuais. A tarefa de otimização procura encontrar soluções ótimas, atendendo a um conjunto de restrições. Por fim, a auto organização conduz a rede a organizar os dados individuais adaptando-se a detecção especializada de cada dado no futuro (FU 1994), (ROSENBLATT 1958) e (RUMELHART 1986).

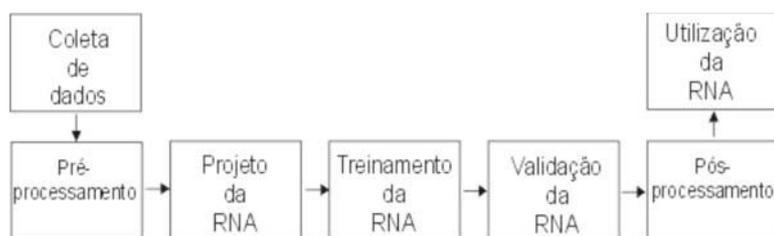


Figura 5 - Etapas de um projeto baseado em RNA

Evolução tecnológica da educação à distância

Ao tratar de Educação, devemos considerar sua natureza, sua influência nas transformações mundiais, sem dissociá-la do contexto social, político, econômico da sociedade. Na história evolutiva humana, os progressos tecnológicos são induzidos pelos processos de aprendizagem e transmissão de conhecimento (HORTON 2000).

A primeira forma de transmissão de conhecimentos, denominada “presencial”, caracteriza-se pela necessidade da presença física e simultânea do educador e educando. Necessidade que impede indivíduos de serem alunos ou professores de cursos de muita importância para a expansão de conhecimentos. Diante dos limites impostos pelo ensino presencial surge, a partir de três fatos, um meio de transmissão de conhecimento não presencial. O primeiro dos fatos acontece com a evolução dos serviços de correios na Europa no começo do século passado e, mais formalmente, com a expansão das tecnologias de rádio e televisão a partir de meados dos anos 30. O segundo fato decorre da necessidade de levar instrução a contingentes populacionais cada vez maiores e mais diversos com arranjos de custo reduzido. A partir de 1940, educadores e psicólogos desenvolveram alternativas instrucionais baseadas na idéia de que a presença física do agente transmissor junto aos aprendizes, em determinados momentos do processo ensino-aprendizagem, não causaria prejuízos para a captação de conhecimentos. O conjunto de técnicas, instrumentos, procedimentos e programas que, gradativamente, surgiu destes fatos constituiu o campo de investigação e tecnologia educacional que veio a ser denominado “Ensino à Distância” (EAD). Sem as limitações impostas pelo modelo presencial, o EAD tem permitido massiva disseminação de conhecimentos, favorecendo, portanto, a popularização do ensino (SHERRY 1996).

Desde a sua diferenciação no contexto da Educação, a EAD tem sido respaldada por experiências significativas realizadas em todo o mundo. Mediante a uma variedade de programas, provedores de instrução,

metodologias e tecnologias de comunicação, diferentes pesquisadores têm usado intercambiavelmente as expressões “educação à distância” e “aprendizagem à distância”. Há, contudo, algum consenso relativo a quais são as características definidoras do EAD: a) a separação do agente transmissor e do aprendiz no tempo e/ou no espaço (PERRATON 1988), b) o controle voluntário do ritmo de aprendizagem pelo aprendiz ao invés de pelo agente transmissor à distância, e c) a comunicação não-contígua entre o aprendiz e o agente transmissor, que é, então, mediada por sistemas multimídia, impressoras, ou alguma forma de tecnologia de transdução da informação na sua forma eletrônica para uma forma processável pelos sentidos humanos (JONASSEN 1992).

Por volta dos anos 60, os cientistas da EAD passam a contar com a possibilidade de ampla utilização de computadores na Educação. Parcela considerável das aplicações educacionais que vieram a utilizar esta tecnologia foi classificada como “Instrução Assistida por Computador” (IAC; expressão traduzida do Inglês “Computer-Assisted Instruction” (CAI); (PARK 1987). O modelo IAC está baseado no paradigma da Instrução Programada (IP), que é definido, dentre outros aspectos, a) pela partição criteriosa, em quadros (frames) e blocos do conteúdo a ser ensinado, considerados fatores tais como a natureza do conteúdo, o repertório de conhecimentos do aprendiz sobre conteúdos mais ou menos relacionados ao que está programado para ser ensinado, o estágio de desenvolvimento lingüístico do aprendiz, o nível de escolarização, etc.; b) o arranjo da apresentação dos quadros considerado o nível de dificuldade de cada um, de forma que a seqüência de apresentações é organizada dos quadros mais fáceis para os mais difíceis; c) a possibilidade de progressão auto-controlada no sentido do quadros iniciais para o finais de um bloco, ou seja, o aprendiz pode determinar o ritmo em que quer aprender, e d) o que ocorre como conseqüência da resposta do aprendiz e funciona como evento que indica a ele, à medida que caminha pelos quadros, a correção ou a incorreção das suas respostas (feedback) (Holland 1961).

No final dos anos 90, a internet abriu espaços na Educação, encurtando distâncias para cursos e programas em EAD. Tal facilidade veio como conseqüência da associação desta revolucionária tecnologia educacional à Informática e às telecomunicações, o que possibilitou agilidade e velocidade de comunicação interativa nunca antes alcançada pelo homem (HORTON 2000).

Como exposto anteriormente, o uso de computadores na Educação (RICHMOND 1975) permitiu a criação de sistemas tutores. Tais programas são considerados simples “viradores de páginas eletrônicos”. Para contextualizar a proposta de tutores, utilizando sistemas inteligentes baseados em redes neurais artificiais, é importante apresentar as principais estruturas (HORTON 2000) utilizadas. Normalmente, uma introdução marca o início da lição e, no final, um resumo é apresentado para revisão dos conceitos, seguido de teste ou outra atividade para medir o conhecimento adquirido.

No tutorial clássico (ver Figura 6), progressivamente, apresenta-se o conteúdo em níveis básico, intermediário e avançado.

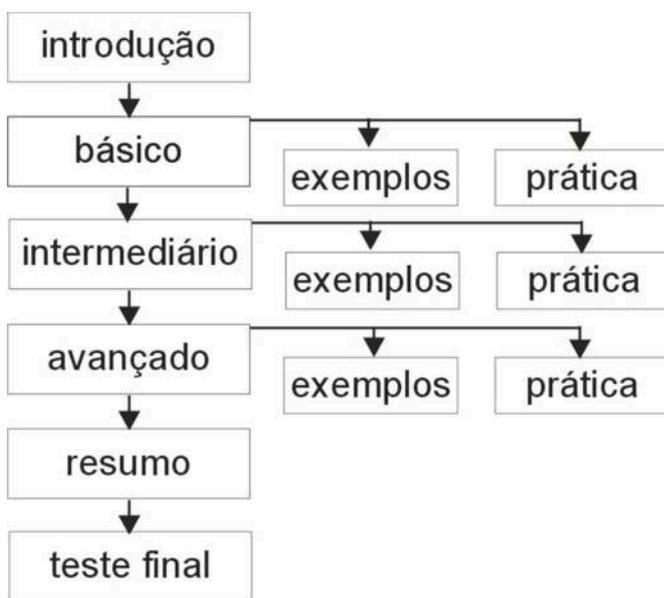


Figura 6 - Tutorial Clássico

No tutorial customizado pelo aprendiz (ver Figura 7), entre a introdução e o resumo, há ciclos de páginas de opções (navegação) e páginas de conteúdo. A página de opções apresenta uma lista de caminhos para escolha pelo aprendiz ou um teste no sentido de definir o próximo passo.

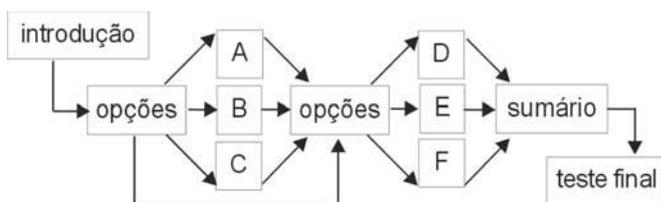


Figura 7 - Tutorial customizado

No tutorial de avanço por conhecimento, o aprendiz pode omitir conteúdos já dominados, sendo submetido a testes de dificuldade progressiva para

determinar o ponto de entrada na seqüência de conteúdos. No tutorial exploratório, existe a página inicial de exploração com links de acesso a documentos, bancos de dados ou outras fontes de informação. No tutorial gerador de lições (ver Figura 8), o resultado do teste define a seqüência personalizada de tópicos a ser exposta ao aprendiz.

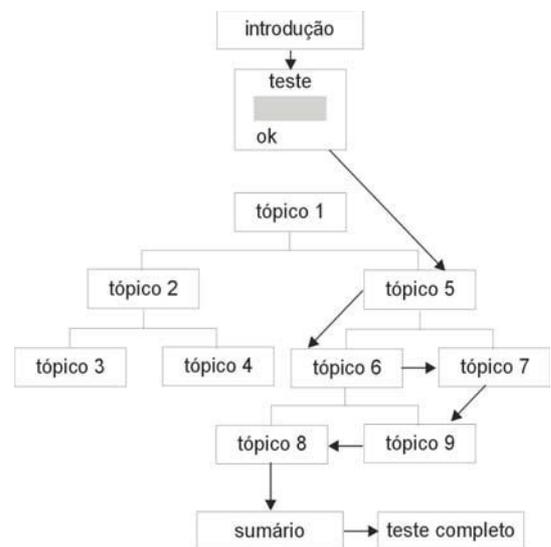


Figura 8 - Tutorial gerador de lições

Outra estrutura recente propõe sistemas tutores conexionistas. O conteúdo é dividido em vários tópicos (contextos). Cada contexto é subdividido em cinco níveis: facilitado, médio, avançado, perguntas/respostas e exemplos. A entrada em cada contexto é realizada através do nível médio. Após cada nível, realiza-se um teste. Após esse teste, o aprendiz pode escolher (navegação livre) ou ser conduzido (navegação guiada) para quaisquer um dos outros níveis ou para o próximo contexto (CARVALHO 2002 e ALENCAR 2000). A estrutura está representada na Figura 9

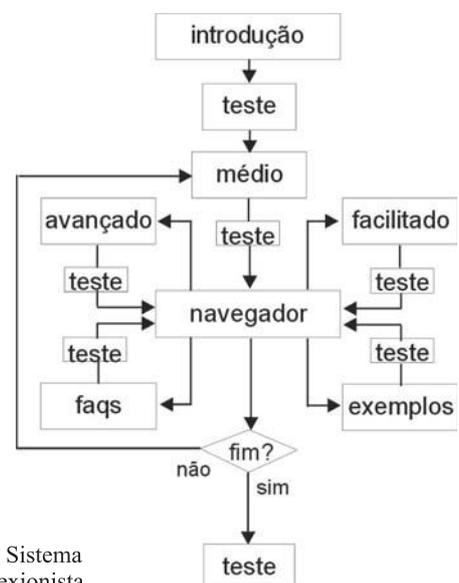


Figura 9 - Sistema Tutor Conexionista

Nesse modelo, uma rede neural artificial específica é treinada (HAYKIN, 2000 e TAFNER, 1995) para cada nível de cada contexto. Para uma sessão tutorial de 15 contextos, são necessárias 75 redes neurais diferentes. Os resultados foram promissores, mas a dependência da formatação do conteúdo impede o rápido desenvolvimento de novos tutoriais. Em outras palavras, qualquer alteração nessa formatação implica na necessidade de novas navegações livres e treinamento de todas as redes neurais envolvidas (além de possível inclusão de outras) (MELO, 2003 e MEIRELES, 2003).

Desenvolvimento do Sistema

Este trabalho fundamenta-se na capacidade da técnica das Redes Neurais Artificiais para extrair padrões capazes de serem utilizados no auxílio da navegação em um sistema tutor inteligente. A presente proposta busca melhorar o aproveitamento do estudante através da consideração do perfil do aprendiz (MELO, 2003 e MEIRELES, 2003) na geração dos padrões de navegação. Um padrão de navegação estabelece as distribuições de probabilidades de visitas dos cinco níveis em cada contexto na estrutura mostrada em Sistemas Tutores. Por exemplo, um determinado padrão contém a quantidade de visitas dos níveis (facilitado, avançado, exemplos e FAQs) e do próximo contexto.

A preparação do sistema é baseada na observação da navegação livre, onde foi utilizada uma estrutura semelhante ao sistema inteligente em desenvolvimento, apresentada na Figura 10. Nesta estrutura, cada passo no sistema é decidido pelo próprio estudante. A partir desta observação foram selecionados os parâmetros e os conjuntos (treinamento e teste) para preparação e configuração da rede neural do sistema tutor inteligente.



Figura 10 - Estrutura do Sistema Tutor Livre

O conjunto de dados, que formará o conjunto de treinamento da rede neural para determinar o estilo de navegação do aprendiz, é selecionado a partir da observação dos melhores casos obtidos na navegação

livre. Como melhores casos, espera-se no mínimo nota final igual ou superior a 5,0 (cinco) e a ocorrência de alguma melhoria. Para esta melhoria, foi estipulado um ganho normalizado, onde se leva em consideração o percentual possível de evolução de nota, tendo por base a nota inicial. Os resultados observados na navegação livre são representados no gráfico da Figura 11. Pela análise das curvas de cada nota, pode-se observar a indicação de que a quantidade de elementos da amostra reduz à medida que a exigência do ganho normalizado aumenta.

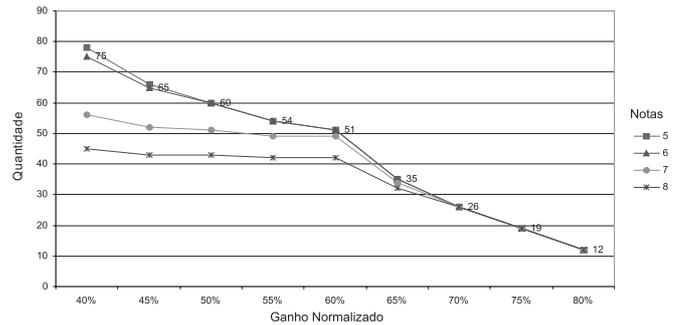


Figura 11 - Navegação livre - (Tamanho da amostra) x (notas finais) x (ganho normalizado)

Foram avaliados diferentes desempenhos de navegação e selecionados, como bons exemplos, os alunos que atingiram no mínimo nota 6,0 (seis) com melhoria igual ou superior a 50%. Da análise dos dados pode-se observar que o ponto escolhido tem boa representatividade conduzindo a uma amostra de tamanho razoável, com 60 elementos. Esta escolha foi feita, supondo que a aplicação da generalização dos padrões a outros alunos, pela RNA, pode sugerir um padrão de navegação para atingir resultados satisfatórios.

Para a identificação do perfil do aprendiz, são utilizados características, extraídas a partir de um questionário de preferências, tendo por base um teste válido na psicologia. Além de considerar preferências e conhecimento do aprendiz, o sistema considera seu nível de habilidade tecnológica (para lidar com a tecnologia onde o sistema implementa sua interface com o usuário). No caso inicial, foi utilizado o computador como interface. Assim, essa habilidade muitas vezes é conseguida de uma maneira informal, no trabalho ou no lazer. Estes dados formam o conjunto de entradas da rede neural (ver Figura 12). Com as entradas, a rede apresentará um padrão probabilístico de navegação. As características psicológicas e as habilidades tecnológicas são coletadas a partir da aplicação de questionários específicos, em ambiente web. Além do desempenho no teste inicial, as respostas do aprendiz aos questionários são entradas da rede neural, comprometida a fornecer o

padrão de navegação guiada. Desta forma, a rede neural tem à sua disposição as características psicológicas do aprendiz, a habilidade tecnológica e seu nível de conhecimento no conteúdo específico do tutorial. Tal rede neural independe da formatação do conteúdo desde que seja mantida a estrutura (número de níveis em cada contexto). O acréscimo de novos contextos ou alteração do conteúdo, por exemplo, não implica em mudanças no sistema tutorial. Tal fato permite a reutilização da estrutura em novos conteúdos.

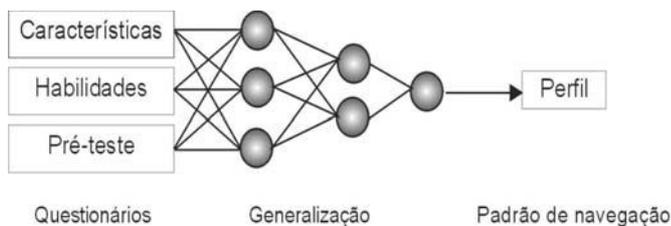


Figura 12 - Formação do Perfil

Para complementar a decisão genérica da navegação inteligente e exercer controle mais preciso e sensível ao desempenho local do aprendiz, um conjunto de regras simbólicas (NORVIG, 1997 e KAPLAN, 1995) é adicionado ao sistema. A definição das regras simbólicas foi feita por especialistas em docência. As regras tratam situações existentes de acordo com a estrutura do tutor (composta de níveis de contexto e testes), orientando as chances de escolha de níveis (ou próximo contexto) diante do desempenho do nível já executado, como é ilustrado na Figura 13.

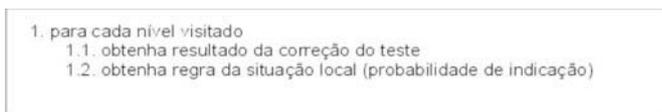


Figura 13 - Utilização das regras probabilísticas

Para definir o próximo passo no tutor, o sistema inteligente dispõe do perfil do estudante, das regras simbólicas, do nível visitado e da resposta do exercício após a visitação do nível. De acordo com o nível e a resposta do exercício, o sistema resgata, do conjunto de regras simbólicas, a regra de indicações probabilísticas para a situação local específica. Cada probabilidade da regra é combinada com probabilidade correspondente do perfil do estudante, gerando uma probabilidade resultante. Com aplicação das regras simbólicas, a probabilidade resultante fica isenta de incoerências, as indicações para cada ponto são reforçadas ou atenuadas. De posse da probabilidade resultante, o sistema utiliza uma seleção genética (onde os mais fortes têm maior probabilidade de serem escolhidos, sem que os mais fracos deixem de ter chances) (GOLDBERG, 1989) para indicar o próximo nível a ser visitado ou a passagem

para o próximo contexto. A Figura 14 mostra como acontece o processo de decisão da navegação inteligente.

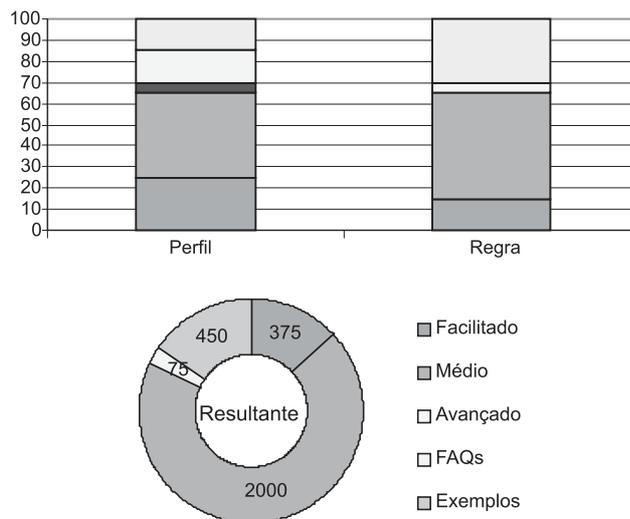


Figura 14 - Processo da navegação guiada

A organização do conteúdo, conforme a estrutura proposta por Alencar (ALE, 2000), é uma parte crítica do sistema e demanda grande esforço da equipe. A assertividade na estruturação dos níveis (diferenciação entre eles) em cada contexto contribui para o processo ensino-aprendizagem (MELO, 2003).

A seleção do assunto “Introdução ao Processamento de Dados” (IPD) para o conteúdo do tutor foi decorrente de vários fatores. Um deles é o domínio do tema por parte da equipe envolvida no projeto. Por outro lado, devem ser ressaltadas as características de atualidade do tema. Ele desperta interesse em uma população extensa, facilitando a participação de vários segmentos sociais.

Após a seleção do tema, implementou-se o tutor conforme a estrutura proposta. O conteúdo foi dividido em 15 subconteúdos (contextos), organizados em seqüência lógica adequada (no caso, outras poderiam ser escolhidas...). O conteúdo de cada contexto foi elaborado em termos de informação geral, visando atender às necessidades específicas de cada nível (avançado, médio, facilitado, exemplos e perguntas-respostas).

Após elaborado o texto, o sistema tutor foi implementado na linguagem ASP para o ambiente WEB. O sistema tutor foi desenvolvido de forma a permitir, com algumas modificações na estrutura da navegação, sua utilização em todas etapas de coletas (livre ou guiadas). A Figura 15 apresenta um esquema completo do sistema tutor inteligente desenvolvido (MELO, 2003 e MEIRELES, 2003).

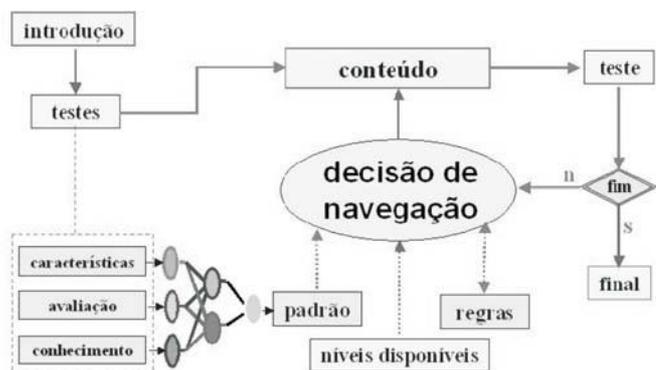


Figura 15 - Estrutura do Sistema Tutor Inteligente

Para implementar a parte inteligente do sistema, foi utilizada uma rede neural do tipo perceptron de múltiplas camadas (MLP, Multilayer Perceptron). Trata-se do modelo mais utilizado (registrado) na literatura, merecendo precedência. Esse modelo de rede neural é indicado na implementação da estrutura devido ao seu poder computacional derivado da capacidade de tratar dados não linearmente separáveis e da habilidade de aprender pela experiência, por meio de treinamento supervisionado (HAYKIN, 2000). Após o treinamento, a rede MLP tem a capacidade de apresentar padrões intermediários aos padrões utilizados no treinamento. Esta característica de generalização, permite ampliar o espaço de personalização do perfil de navegação para novas combinações de entradas, diferentes das utilizadas no treinamento.

O treinamento da rede neural foi a etapa mais crítica e decisiva do projeto. Começou com a avaliação dos dados obtidos na coleta livre e culminou com o desenvolvimento da ferramenta responsável pela condução inteligente do tutor, objeto principal do trabalho.

Para a fase de treinamento da RNA, a amostra foi dividida em 2 conjuntos. O primeiro conjunto, composto de 40 elementos da amostra, foi destinado ao treinamento e o segundo, composto de 20 elementos da amostra, foi destinado à validação. A partir deste ponto, o trabalho era definir a estrutura da rede a ser utilizada no experimento.

A camada de entrada compreende 17 neurônios: 8 entradas para o resultado do questionário das características psicológicas, 7 entradas para o resultado do teste de habilidades e 2 entradas para a nota inicial, obtida no pré teste.

A camada de saída é composta de cinco neurônios. Cada neurônio de saída é responsável pela indicação da probabilidade de visitação de cada um dos níveis do tutor.

Para concluir a estrutura, resta definir a quantidade

de neurônios da camada oculta. A seleção desta camada aconteceu a partir da análise de 400 treinamentos realizados com diferentes estruturas nesta camada. O ponto de definição dos valores empregados foi definido pelo erro mínimo global apresentado pelo conjunto de validação, conforme se pode observar na curva apresentada na Figura 16. Os parâmetros deste ponto foi escolhido para implementação da rede do sistema responsável pela navegação guiada inteligente.

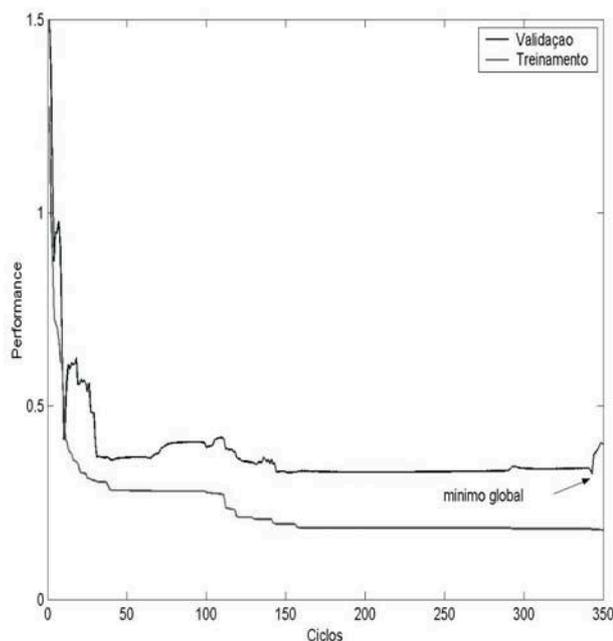


Figura 16 - Visão localizada das curvas de treinamento da rede neural

Resultados do Sistema

Para chegar aos resultados obtidos, desenvolveu-se um sistema tutor para a coleta de dados, denominado Tutor Livre, e um tutor guiado (sem inteligência) denominado Tutor Aleatório para avaliação das decisões de navegação do tutor inteligente. O Tutor Livre e o Aleatório possuem a mesma estrutura do Tutor Inteligente proposto neste trabalho, porém não são dotados de inteligência. As coletas dos dados utilizados nos experimentos foram realizadas com alunos dos cursos de Administração e Cursos Superiores Sequenciais. Após o treinamento das redes neurais, foi efetuada uma nova coleta de dados, com o Tutor Guiado e o Tutor Aleatório para proceder um estudo comparativo do desempenho do sistema.

Foram realizadas comparações entre as três amostras através da Estatística Descritiva, além de empregar técnicas de Estatística Inferencial para efetuar generalizações. A primeira (descritiva) descreve os resultados imediatos, aplicados àquelas amostras especificamente. A segunda (inferencial) indica o quão

significantes foram as diferenças obtidas em termos populacionais.

Na Tabela 1 são apresentados os dados da análise descritiva. Pode ser observado pontos importantes que apontam a maior estabilidade dos dados da navegação inteligente utilizada no sistema proposto.

Tabela 1 - Análise Descritiva dos Dados Coletados

Ítem	Nota inicial			Nota final			Ganho normalizado		
	livre	aleatória	inteligente	livre	aleatória	inteligente	livre	aleatória	inteligente
<i>Nº de casos</i>	148	31	31	148	31	31	148	31	31
<i>Média</i>	4,56	3,99	3,92	6,87	5,93	7,21	39,59	32,60	58,02
<i>erro padrão</i>	0,15	0,39	0,40	0,14	0,39	0,33	2,70	4,93	4,63
<i>Mediana</i>	4,40	3,47	4,00	6,80	5,73	6,93	42,08	32,31	56,82
<i>Moda</i>	3,60	5,60	4,00	8,80	5,73	6,27	0,00	0,00	100,00
<i>desvio padrão</i>	1,78	2,17	2,21	1,66	2,16	1,83	32,87	27,42	25,79
<i>Assimetria</i>	0,18	0,06	0,00	-0,34	-0,23	-0,66	-0,62	0,09	0,09
<i>amplitude total</i>	8,13	7,47	7,73	8,53	7,47	7,20	169,57	89,17	83,33
<i>Mínimo</i>	0,67	0,13	0,00	1,47	1,87	2,80	-69,57	-10,91	16,67
<i>Máximo</i>	8,80	7,60	7,73	10,00	9,33	10,00	100,00	78,26	100,00

Nas três situações, as notas iniciais médias estão próximas, ficando em torno de 4,16 - um indicativo dos participantes amostrais possuírem conhecimento regular sobre o assunto abordado, inferior à média tradicional de aprovação (5,0). A média das notas finais ficou em torno de 6,6 entre as coletas, indicando ter ocorrido melhoria. Neste caso, a maior média foi alcançada pela navegação inteligente (7,21), seguida pela livre (6,87) e, por último, a navegação aleatória (5,93).

Na observação das médias, o fato mais interessante está na média da melhoria normalizada, onde a navegação inteligente (sistema proposto) alcançou a média 58,02% de melhoria (a mais alta das três coletas).

A Tabela 2 resume a descrição da média dos resultados obtidos na análise comparativa dos dados da navegação livre, da navegação aleatória e da navegação com o sistema proposto (inteligente). Pode ser observado o fato da navegação inteligente apresentar, sem incoerências, maiores valores na média da nota final e do ganho normalizado com menor tempo de execução (curso) e menor quantidade de visitas. Assim, verifica-se que as médias do sistema proposto são melhores e com a utilização de menos recursos (níveis visitados e tempo).

Tabela 2 - Comparativo do desempenho médio das navegações

Navegação	Tempo em minutos	Níveis visitados	Incoerências	Nota final	Ganho
<i>Livre</i>	37,88	35,34	0,63	6,87	39,59
<i>Aleatória</i>	35,97	45	1,06	5,93	32,60
<i>Inteligente</i>	26,80	26,71	0	7,21	58,02

Neste ponto pode ser observada a eficiência do sistema proposto como um todo. Porém, é importante verificar a validade de cada uma das técnicas no resultado

final. Mais especificamente, procura-se investigar a influência da Rede Neural Artificial (RNA) no sistema proposto. Tal investigação é justificada pelo fato das regras simbólicas dos especialistas serem consideradas, intuitivamente, como altamente responsáveis pelo destino da navegação como um todo.

Para esta investigação, estudamos o perfil global de navegação indicado pela rede para cada nível e o perfil individualizado efetivamente observado na navegação realizada no sistema proposto. Após o levantamento dos perfis globais (indicado e observado) de cada elemento da amostra, foi realizado o estudo estatístico através da correlação de Pearson entre os perfis da amostra para averiguar a validade da RNA no sistema. O valor da correlação geral observada foi de 0.875, indicando uma forte correlação positiva entre os perfis. Este nível de correlação é um forte indício de que a atuação da RNA no sistema é fortemente responsável pela definição do caminho a ser percorrido pelo estudante no tutor. Na Tabela 3 é apresentado o estudo completo dos cálculos da correlação global e da correlação de cada nível.

Tabela 3 - Correlação de Pearson RNA X Observado

Teste do Nível	Correlação Rxy
Todos	0,875
Fácil	0,952
Próximo/Médio	0,694
Avançado	1
FAQs	1
Exemplos	0,529

Pela observação dos gráficos comparativos das navegações apresentada na Figura 17, pode-se constatar a grande semelhança apresentada nos perfis de navegação propostos pela rede e observado na utilização real do sistema. A correlação de 0,952 observada no Nível Fácil sugere o fato das indicações da rede neste nível estarem fortemente correlacionadas com o perfil efetivamente observado nas navegações realizadas. As diferenças de percentual de visita podem ser explicadas pelas correções impostas pelas regras simbólicas e, também, pela característica do sistema probabilístico.

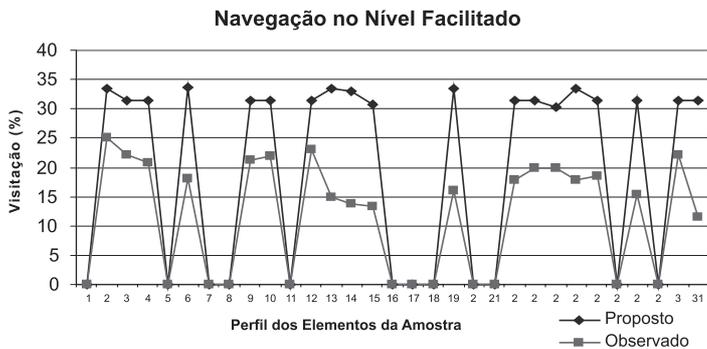


Figura 17: Comparativo do perfil proposto pela rede com o observado no nível Facilitado

As navegações no nível Médio e Exemplos, representadas na Figura 18, apresentaram as correlações de menor valor no sistema, mesmo assim, as mesmas são positivas e com valores longe do valor nulo, indicativo de haver correlação.

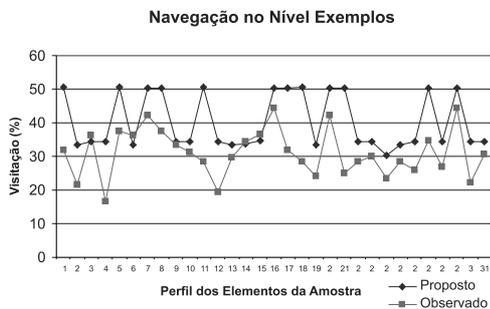
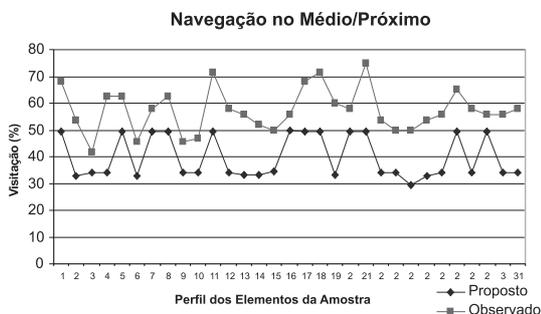


Figura 18: Comparativo do perfil proposto pela rede com o observado no nível Médio e Exemplos

A maior proximidade entre as curvas de navegação pode ser observada nos perfis de navegação “Avançado” e “FAQs”, representados na Figura 19. Nestes perfis a correlação de Pearson atinge o valor máximo de 1. Convém salientar o fato da RNA não ter indicado o nível “Avançado” para nenhum dos elementos da amostra e foi constatada a não existência de navegações no nível. O nível FAQs a RNA indicou apenas um dos elementos amostrais para navegação no nível e foi constatado que apenas o elemento indicado foi conduzido neste nível.

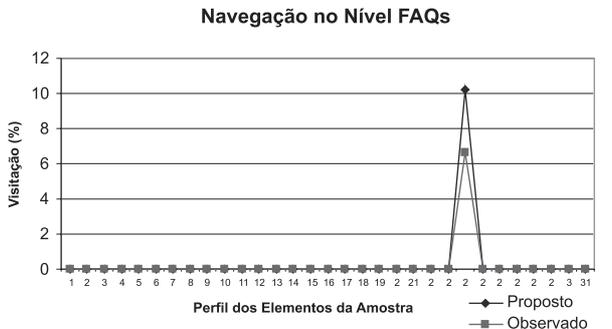


Figura 19: Comparativo do perfil proposto pela rede com o observado nos níveis Avançado e FAQs

Conclusão

Neste trabalho, foi apresentada a análise de um Sistema Tutor Inteligente baseado em Redes Neurais Artificiais, caracterizando a personalização do aprendiz, através da generalização das variáveis identificadoras do aprendiz. Além disto, promoveu-se um estudo mais detalhado do potencial do tutor como ferramenta para organizar diferentes níveis didáticos mais apropriados ao aprendiz apresentado ao sistema. Para tal, foi comparado o desempenho entre o sistema proposto e tutores não dotados de inteligência (livre e guiado aleatoriamente).

A análise dos resultados, sob a ótica da Estatística Descritiva, apontou vantagens para o sistema proposto. A média de suas notas finais situou-se acima das outras navegações, apesar de ser pequena a diferença. Quanto à média do ganho normalizado, o sistema proposto ficou claramente acima da média dos outros tutores.

A análise comparativa do desempenho das notas finais mostrou a força do sistema proposto em todas os três aspectos analisados (notas 5, 6 e 8). Elas indicam uma frequência percentual maior no sistema proposto tanto na nota como no ganho (melhoria de aprendizagem).

Na comparação das amostras, observou-se que os melhores resultados do sistema proposto foram alcançados com média menor de níveis visitados e tempo para realização da tarefa reduzido.

Referências Bibliográficas

- ALENCAR, W. S., Sistemas Tutores Inteligentes Baseados em Redes Neurais, Goiânia, 2000. Dissertação (Mestrado em Engenharia Elétrica e de Computação) - UFG - Universidade Federal de Goiás.
- CARVALHO, S. D., Mapas Auto-Organizáveis Aplicados a Sistemas Tutores Inteligentes, Goiânia, 2002. Dissertação (Mestrado em Engenharia Elétrica e de Computação) - UFG - Universidade Federal de Goiás.
- FAUSETT, L. V. Fundamentals of neural networks. Prentice Hall, 1994.
- FU, L. M. Neural networks in computer intelligence. McGraw-Hill, 1994.
- GOLDBERG, D. E. Genetic Algorithms in Search, Optimization and Machine Learning, Addison Wesley, 1989.
- HAYKIN, S. S.; Redes Neurais Artificiais - Princípio e Prática. 2ª Edição, Bookman, São Paulo, 2000.
- HOLLAND, J. G. & Skinner, B. F. The analysis of behavior: a program for self-instruction. McGraw-Hill Book Company, Inc., New York, USA, 1961.
- HORTON, William K. Designing Web-based Training. 2000.
- JONASSEN, D. H. Applications and limitations of hypertext technology for distance learning. Trabalho apresentado no Distance Learning Workshop, Armstrong Laboratory, San Antonio, USA, 1992.
- KAPLAN, R. & ROCK, D. New directions for intelligent tutoring systems. Artificial Intelligence Expert, February, 1995.
- MCCULLOCH, W. S.; PITTS, W. A logical calculus of ideas imminent in nervous activity. Bull. Math. Biophysics, 1943.
- MEIRELES, V. Sistemas Tutores Inteligentes Híbridos Baseados em Estilos de Aprendizagem. Dissertação de Mestrado. Universidade Federal de Goiás. Goiânia, Brasil, 2003.
- MELO, F.R. Sistemas Tutores Inteligentes Híbridos Baseados em Características Psicológicas. Dissertação de Mestrado. Universidade Federal de Goiás. Goiânia, Brasil, 2003.
- NORVIG, P. and RUSSEL, S. Artificial Intelligence: a modern approach, Prentice-Hall, New Jersey, USA, 1997.
- PARK, O., PEREZ, R.S. and SEIDEL, F.J., "Intelligent CAI: Old Wine in New Bottles or a New Vintage ?", em KEARSLEY, G., "Artificial Intelligence and Instruction - Applications and Methods", 1987.
- PERRATON, H. A theory for distance education. Em D. Sewart, D. Keegan, & B. Holmberg (Ed.), Distance education: international perspectives. New York: Routledge, 1988.
- RICHMOND, W.K., "A Revolução no Ensino" tradução do original "The Teaching Revolution", Companhia Editora Nacional, 1975.
- ROSENBLATT, F. The perceptron: a probabilistic model for information storage and organization in the brain. Psychological Review, 1958.
- RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning internal representation by error propagation. Em Parallel distributed processing: explorations in the microstructures of cognition. MIT Press, 1986.
- SHERRY, L. Issues in distance learning. International Journal of Educational Telecommunications, 1996.
- TAFNER, M. A. et all. Redes neurais artificiais: introdução e princípios de neurocomputação. EKO: Ed. da FURB, Blumenau, SC, 1995.

Recebido em 14 de julho de 2007 e aprovado em 29 de agosto de 2007.