

REDES NEURAIIS ARTIFICIAIS NA CLASSIFICAÇÃO DE PADRÕES PROXIMAIS DE APRENDIZAGEM

Francisco Ramos de Melo^{1,2}, Edna Lucia Flores¹, Sirlon Diniz de Carvalho^{1,3}, Milena Bueno Pereira Carneiro¹, Luis Fernando Batista Loja^{1,3} e Antônio Claudio Paschoarelli Veiga¹

¹ Universidade Federal de Uberlândia - Faculdade de Engenharia Elétrica - Uberlândia- MG – Brasil

² Universidade Estadual de Goiás - Unidade Universitária de Educação a Distância -Anápolis- GO – Brasil

³ Instituto Federal de Luziânia - Luziânia – GO – Brasil

chicorm@yahoo.com.br, edna@ufu.br, sirlondiniz@gmail.com, milenabueno@yahoo.com, luizloja@gmail.com, acpveiga@ufu.br

Resumo – Este trabalho apresenta uma abordagem empregando redes neurais artificiais na personalização automatizada de conteúdos em sistemas tutores inteligentes (STI). A metodologia consiste em selecionar um grupo de características de organização de conteúdo, realizada por um grupo de estudantes, para uma rede neural artificial. A rede neural treinada possibilita classificar outros estudantes e associar um padrão proximal de aprendizagem. Este padrão possibilita o sistema tutor inteligente estabelecer uma apresentação personalizada de conteúdos didáticos. Os testes de correlação indicaram a rede neural com forte influência na definição das ações do sistema.

Palavras-Chave – Padrões proximais de aprendizagem, redes neurais artificiais, personalização de conteúdos, sistemas tutores inteligentes, inteligência artificial.

NEURAL NETWORKS IN THE CLASSIFICATION OF PROXIMAL LEARNING PATTERNS

Abstract - This paper presents an approach using artificial neural networks to automated customization of content in intelligent tutoring systems (ITS). The methodology consists of selecting a group of features content organization, held by a group of students to an artificial neural network. The trained neural network allows to classify other students and to associate a proximal pattern of learning. This standard enables the intelligent tutoring system to establish a customized presentation of educational content. The correlation tests showed the neural network with strong influence in shaping the actions of the system.

Keywords – Learning proximity patterns, artificial neural networks, customized contents, intelligent tutor systems, artificial intelligence.

I. INTRODUÇÃO

A organização tradicional de um modelo de construção de conhecimentos em sala de aula pode considerar três

elementos básicos e suas relações multilaterais: o educador como o agente mediador do conhecimento, o educando como o agente interessado pelo conhecimento e o conteúdo que contém o assunto a ser aprendido.

O educando é o agente para quem todo o processo educacional deve ser direcionado. É para ele que deve ser organizado o processo de aquisição de conhecimento. Assim é importante estabelecer alguns pontos como elemento de identificação do educando, tais como: sua forma de aprender, suas reações ao que está sendo discutido, etc.

O conteúdo é o elemento que contém o conhecimento a ser apresentado, discutido e apreendido. Esse conteúdo pode conter um ou mais conceitos relacionados ao conhecimento. Para a sua apresentação, é importante estabelecer elementos que favoreçam a interação de aproximação com o educando.

O educador é o elemento que estabelece o diálogo entre o conhecimento construído historicamente e o educando. Para isto, organiza os conceitos, sua forma de apresentação e estabelece a interação com os educandos, em uma relação dialógica. Esta interação suscita o enriquecimento da formação do conteúdo proposto, em um processo de construção individual e coletiva.

A educação à distância é uma modalidade de ensino, cujos conhecimentos são apresentados em grande parte de forma assíncrona quanto à presença do professor e do estudante no local em que ocorre o processo de ensino-aprendizagem. Nesse sentido, o professor e o estudante não precisam ocupar simultaneamente o mesmo espaço e tempo. Esta situação transfere ao estudante grande parte da responsabilidade pela condução do próprio aprendizado. Assim, espera-se um estudante com perfil disciplinado e autônomo, capaz de gerenciar a aprendizagem. O auxílio na aprendizagem pode estar no esforço do professor em organizar conteúdos que procuram minimizar dificuldades. Entretanto, essa organização pode não ser a mais adequada quanto à aceitação por outros estudantes. Sistemas computacionais incorporando alguma espécie de inteligência foram desenvolvidos para auxiliar os aprendizes no processo de assimilação de conhecimentos.

No modelo de ensino não presencial, o estudante passou a ter a possibilidade de acessar o conhecimento e controlar a sua disponibilidade e ritmo. Esse modelo tem sido alvo de muitas pesquisas e estudos. Um grande problema desse modelo consiste em administrar individualidades [1]. Um livro, por exemplo, é uma forma de ensino não presencial.

Independente do leitor, o formato do livro é o mesmo com a mesma sequência de páginas e capítulos. É tarefa do leitor seguir a sequência original do livro ou, então, construir uma que julgue mais adequada, alterando a forma de folheá-lo.

Várias tecnologias são desenvolvidas na busca de soluções para prover o ensino adaptativo, contextualizado, direcionado e flexível em ambientes virtuais de aprendizagem (AVA). O sistema tutor inteligente (STI) é uma das mais proeminentes tecnologias computacionais para a adaptabilidade da transmissão de conhecimentos em ambientes de Ensino a Distância (EAD). O desenvolvimento de STIs normalmente emprega técnicas de inteligência artificial clássica, na qual o conhecimento para a estruturação do sistema é estabelecido conforme o entendimento do especialista.

A utilização de uma abordagem fundamentada em redes neurais com a perspectiva de poder contribuir técnica e cientificamente para a construção de sistemas tutores inteligentes motivou o desenvolvimento deste trabalho.

II. SISTEMAS TUTORES INTELIGENTES

Os STIs objetivam implementar estratégias para personalizar o processo de transmissão de conhecimento. Adicionalmente, o STI pode apresentar técnicas que proporcionem ação à reatividade do estudante. De alguma maneira, as técnicas dos STIs procuram desenvolver mecanismos computacionais que reproduzam alguma tecnologia educacional consolidada no ensino presencial.

Um sistema tutor para ser considerado inteligente deve ser flexível. Isto significa que ele deve ter a capacidade para aprender com o meio de inserção e atualizar o seu conhecimento [2]. Nesse tipo de software o estudante aprende fazendo e, igualmente, o sistema se adapta ao desenvolvimento do estudante. Desta forma, os Sistemas Tutores Inteligentes (STIs) deveriam assumir um papel próximo ao do “professor humano”. Mas devido às inúmeras limitações, tanto em nível de software quanto de hardware, isto está longe de acontecer. As arquiteturas de sistemas tutores inteligentes variam de uma implementação para outra. Em geral, os STIs tradicionais possuem uma organização básica, como pode ser visualizado na Figura 1.

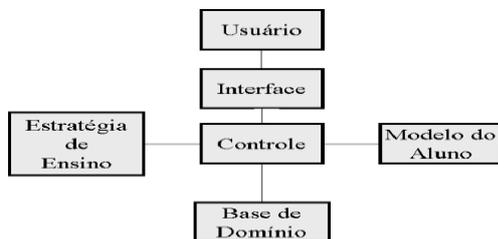


Fig. 1: Arquitetura tradicional de um STI

A base de domínio é o componente que age como o especialista e desempenha a função de fonte de conhecimento a ser apresentada. Ela é considerada como um padrão para as avaliações de desempenho do estudante. A base de domínio é constituída pelo material instrucional, por um sistema de geração de exemplos, por processos de simulação e pela possibilidade de formulação de diagnósticos. Em essência, esse modelo incorpora a maior parte da “inteligência” do sistema na forma do conhecimento

necessário para solucionar os problemas do domínio. O grande desafio é fornecer uma rica representação desse domínio, de forma que possibilite flexibilidade no ensino.

O modelo do estudante representa o conhecimento e as habilidades cognitivas do usuário em um determinado momento. A característica principal desse modelo é a de tentar contemplar todos os aspectos do conhecimento e do comportamento do estudante, que tragam consequências para o seu desempenho e aprendizagem.

As estratégias de ensino constituem o modelo pedagógico em si e podem ser vistas como planos de apresentação do material instrucional. Esse modelo deve conter o conhecimento necessário para a tomada de decisões sobre quais táticas de ensino empregar. A construção de tais estratégias é bastante complexa e exige muita versatilidade, pois as decisões devem ser tomadas dinamicamente, tendo como base as atitudes e as necessidades do estudante.

De modo geral, é possível afirmar que o usuário tem a concepção de que a interface é o próprio sistema. Logo, fica evidente que uma atenção especial deve ser dispensada nesse sentido. A interface será a responsável pela apresentação do material instrucional e pela manipulação do progresso do estudante, por meio da recepção de sua resposta.

O módulo de controle é o responsável pela coordenação geral do tutor. Geralmente são as funções programadas para trocas de informações, apresentação de interfaces, etc. Esse módulo consiste de funções tais como acesso a banco de dados, manutenção do histórico da sessão do usuário e comunicação com outros programas utilitários que façam parte do STI.

Nas diferentes técnicas empregadas, observa-se um esforço no sentido de desenvolver disponibilidades de estratégias diferenciadas e um mecanismo que possibilite a adaptação necessária ao estudante. Um grande esforço no desenvolvimento de um STI é a busca de um mecanismo que possa compensar a falta do professor na condução didática do conteúdo apresentado.

O desenvolvimento de STIs, normalmente emprega técnicas de IA simbólica [3]. Nestas técnicas os processos de conhecimento são abstraídos e organizados em regras ou estruturas equivalentes que possibilitam a manipulação automatizada por um sistema [4].

Uma alternativa de desenvolvimento de trabalhos com STIs buscou simplificar a representação do conhecimento com técnicas de IA conexionista [5][6][7]. No conexionismo o conhecimento é abstraído, organizado e manipulado na forma de padrões.

III. REDES NEURAIS ARTIFICIAIS

As redes neurais artificiais (RNA) são estruturas de processamento que imitam a atividade de processamento do cérebro humano. A principal característica de uma RNA é a capacidade de estabelecer uma relação dos dados apresentados em suas entradas e efetuar a classificação em padrões na sua saída [8][9].

O cérebro humano é composto de neurônios interligados, formando uma rede neural. Os neurônios biológicos são células nervosas que podem ser funcionalmente divididas em três seções inter-relacionadas: o corpo da célula, os dendritos e o axônio. Os estímulos são recebidos pelos dendritos e são

processados pelo corpo da célula que emite uma saída pelo axônio. A saída de um neurônio é repassada para outro neurônio por meio de uma ligação denominada sinapse. As sinapses funcionam como válvulas, sendo capazes de controlar a transmissão de impulsos entre os neurônios na rede neural. O efeito das sinapses é variável e esta variação implementa a capacidade de adaptação ao neurônio. Para implementação das RNAs foi proposto um modelo de neurônio artificial (nodo) similar, em estrutura e funcionamento, ao neurônio biológico. O nodo possui um ou mais sinais de entrada associada a um peso, um sinal de saída e o corpo do neurônio representado por duas funções (soma e ativação). O peso é um valor que indica o grau de importância da entrada na formação do sinal de saída do neurônio. A entrada de dados ocorre com a apresentação das características consideradas na classificação em cada uma das entradas. Cada entrada é ponderada pelo respectivo peso antes de ser inserido na unidade de processamento. Para realizar o processamento o neurônio efetua uma soma de todas as entradas ponderadas pelos respectivos pesos e submete esta soma a uma função pré-definida, denominada função de ativação. Conforme o tipo da função de ativação, é produzido um sinal na saída que é a classificação do padrão apresentado. Para efetuar a classificação, a rede deve passar por um treinamento.

A rede neural perceptron multi-camadas (MLP, do inglês Multi Layer Perceptron) é um modelo que possibilita a identificação e classificação de padrões. A classificação de padrões pela RNA do tipo MLP é possível após o treinamento supervisionado. Neste paradigma é utilizado um conjunto de exemplos dos padrões a serem classificados. Cada elemento do conjunto é composto de um grupo de características (utilizadas como entradas) e o padrão correspondente, que representa a saída esperada. Após a apresentação das características na entrada da RNA, a saída calculada pela rede é comparada com a saída esperada. Caso haja diferença, será realizado um reajuste nos valores dos pesos das conexões. O reajuste dos pesos é realizado iterativamente até que a rede seja considerada treinada. O algoritmo backpropagation é o mais difundido para o treinamento de redes tipo MLP, apresentado na Figura 2. Nesse modelo os neurônios são organizados em camadas de entrada, intermediária e saída.

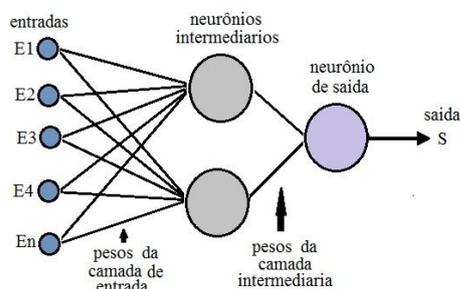


Fig. 2: Rede Neural Artificial MLP

O poder computacional de uma RNA do tipo MLP está na capacidade de classificar dados não linearmente separáveis e aprender por treinamento supervisionado. Após o treinamento, a RNA tem a capacidade de identificar novos

padrões, diferentes dos padrões utilizados no treinamento, estabelecendo uma nova classificação intermediária entre os padrões aprendidos durante o treinamento. Desta forma, o modelo é especialmente útil em situações em que outros métodos para classificação de padrões são ineficientes, seja pela complexidade do problema, seja pela dificuldade de estabelecer a relação entre os parâmetros considerados na classificação do padrão.

IV. CONTEÚDO DIDÁTICO

Um conteúdo C convencional qualquer pode ser definido matematicamente pelo conjunto composto de uma sequência de vários conceitos. Os conceitos são organizados em uma sequência lógica para conduzir ao conhecimento. A organização dessa sequência pode ser realizada de diferentes modos, desde a organização clássica até organizações customizadas [10].

O objetivo da personalização é proporcionar ao estudante o melhor aproveitamento do assunto apresentado. Após a definição do conteúdo multinível, para prosseguir no processo de personalização, é necessário definir como identificar o perfil do estudante e como organizar o conteúdo de forma mais adequada para esse perfil.

Um conteúdo personalizado pode ser considerado uma sequência diferenciada de conceitos. Esta diferença está no fato da sequência ser organizada de tal forma que se ajuste o mais próximo possível ao perfil do estudante. A personalização do conteúdo pode oferecer entre outras coisas o melhor aproveitamento do assunto apresentado.

Como a concepção do conteúdo convencional é direcionada a um determinado perfil de estudante, normalmente ele é apresentado da mesma forma para qualquer estudante, sem considerar eventuais diferenças. Desta forma, a possibilidade de ajuste do conteúdo para outros perfis de estudantes é quase nula. Assim, é necessário criar uma maneira que possibilite tratar o mesmo conteúdo de formas diferentes.

A sequência do conteúdo didático convencional é inadequada para o processo de personalização. Entretanto, se cada conceito for reescrito com diferentes níveis de apresentação é possível compor o mesmo conteúdo utilizando diferentes combinações desses níveis.

A reestruturação do conceito em diferentes formas de apresentação é denominada de conceito multinível. A estrutura desse conceito é semelhante à mediação docente. Após a apresentação do conceito, o professor procura uma maneira de estabelecer a condução do conhecimento conforme a reação do estudante.

As diferentes combinações dos níveis de conceitos do conteúdo multinível possibilita a apresentação personalizada do conteúdo para cada perfil de estudante. Além disto, possibilita criar mecanismos para intervenções mediativas nos diferentes momentos da aprendizagem. Desta forma, é possível que no mesmo conteúdo, cada conceito multinível seja apresentado de forma distinta.

Neste trabalho é utilizado um conteúdo multinível em 5 níveis que são: médio, facilitado, avançado, exemplo e Frequently Asked Questions (FAQs).

V. PADRÃO PROXIMAL DE APRENDIZAGEM

Na análise dos perfis de estudantes pode-se constatar que não existe um modelo único de perfil. Na verdade existe uma grande diversidade de perfis de personalidades com variados padrões de comportamento. Trabalhos na área da Psicologia desenvolveram ferramentas para classificar padrões da mente humana. Os trabalhos estabelecem a relação de padrões de comportamento com as características obtidas empregando testes psicológicos [11].

Para a identificação das características do estudante (perfil) foram utilizados três tipos de instrumentos: um questionário de características psicológicas (perfil pessoal), um questionário de habilidades tecnológicas e um questionário de conhecimentos do assunto a ser apresentado (pré-teste). A Figura 3 apresenta a estruturação do perfil do estudante.

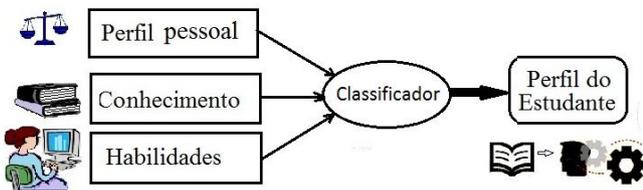


Fig. 3. Estrutura do Sistema Tutor

Para obter melhor aproveitamento do conteúdo didático, a apresentação desse conteúdo deve estar mais próxima do perfil pessoal do estudante. A personalização de conteúdos é a forma de estabelecer essa aproximação visando o melhor aproveitamento do assunto apresentado. No conteúdo multinível um caminho para a personalização é a definição do padrão de aprendizagem: quanto o estudante prefere cada um dos níveis desse conteúdo. Para cada um desses níveis, a preferência pelo nível é uma função densidade de probabilidade [12].

Com o perfil do estudante e o padrão de aprendizagem definidos é necessário estabelecer uma associação entre eles. Neste trabalho, a proposta de organização personalizada do conteúdo didático consiste em classificar o perfil do estudante e associá-lo, por aproximação, com o padrão de aprendizagem. O resultado é o padrão proximal de aprendizagem. Neste trabalho é utilizada uma rede neural Multi Layer Perceptron (MLP) para definir o perfil do estudante e estimar o padrão proximal de aprendizagem, como ilustrado na Fig. 4. Esta rede é treinada com dados observados de estudantes com capacidade de organizar o estudo individual. Ao final do treinamento, a RNA estará capacitada a exercer a função de classificar o perfil do estudante e indicar o padrão proximal de aprendizagem.

Conforme pode ser observado na Figura 4, foram estabelecidas 17 entradas, subdivididas em três grupos, para obter as características dos padrões que compõem o perfil do estudante. Para definir a saída, a alternativa, não testada no trabalho, é empregar uma rede para cada nível. Porém, um dos objetivos do trabalho é um sistema com o mínimo possível de RNAs, para possibilitar a implementação do sistema em ambientes de rede Internet.

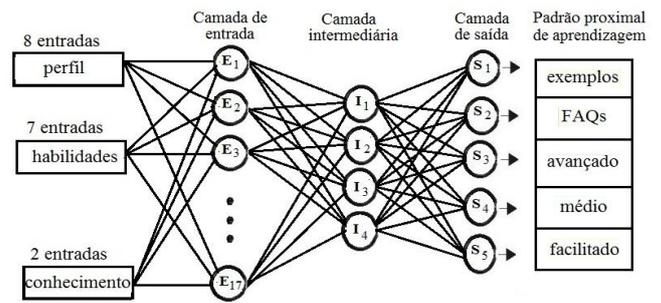


Fig. 4. Estrutura da RNA

Desta forma, foi definida uma RNA com cinco saídas, cujo valor é a probabilidade de cada nível considerada no sistema. Após a definição das entradas da rede, a seleção da estrutura das camadas intermediárias foi realizada a partir da análise do comportamento de diversas estruturas de organização da rede. Em cada estrutura foi variada a combinação de camadas e a quantidade de neurônios. A estrutura de rede selecionada apresentou o menor erro quadrático possível (curvas de generalização/especialização da rede) após o treinamento. Desta forma, a estrutura escolhida tem 17 neurônios para a camada de entrada, uma camada intermediária com 4 neurônios e uma camada de saída com 5 neurônios.

VI. ORGANIZAÇÃO DO SISTEMA

Para personalizar conteúdos didáticos é possível estruturar um sistema considerando o conteúdo multinível, a personalização do conteúdo multinível, o perfil do estudante e o padrão proximal de aprendizagem. A Figura 5 apresenta a estrutura do sistema proposto.

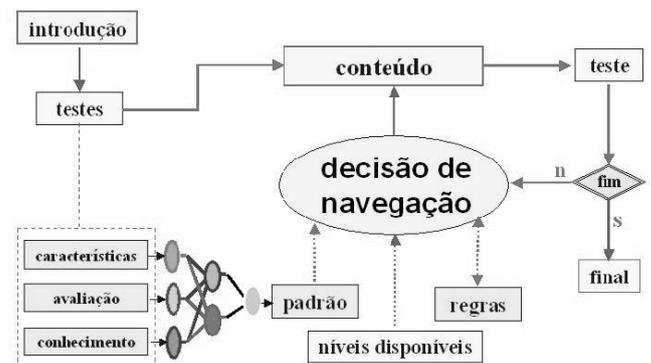


Fig. 5: Estrutura do Sistema Tutor

O sistema tutor é composto de introdução, testes iniciais, sequência de apresentação do assunto e teste final. Na introdução são apresentadas informações gerais sobre o sistema e o assunto a ser apresentado. Após a introdução são realizados os testes de características, habilidades e pré conhecimento. Os resultados dos testes são inseridos na entrada da RNA que classifica o perfil do estudante e apresenta na saída o padrão proximal de aprendizagem. Este

padrão fica armazenado na memória do sistema como padrão de referência global para apresentação do conteúdo.

O sistema inicia a sequência de apresentação do conteúdo a partir do primeiro conceito até o último conceito, conforme a definição do conteúdo pelo professor. A apresentação de cada conceito sempre inicia no nível médio. Após a apresentação de todo o conteúdo é realizado um teste final. Este teste efetua a medida de retenção do conteúdo apresentado.

A apresentação do conteúdo é organizada em uma combinação de duas sequências: geral e localizada.

A sequência geral é organizada pelo professor que define a ordem de apresentação dos conceitos. Essa sequência apresenta os conceitos em uma ordem lógica, estruturando o conteúdo desde o primeiro ao último conceito.

A sequência localizada é organizada pelo sistema proposto que define quais os níveis serão apresentados e a ordem de apresentação deles de acordo com a sequência geral. Após a apresentação do conceito em um nível qualquer, o estudante pode reagir de diferentes maneiras. Dependendo da reação(?), é selecionado um nível para ser apresentado. A sequência localizada corresponde às ações didáticas do professor diante da reatividade do estudante.

No sistema proposto, a organização da sequência localizada inicia sempre no nível médio. Ao final da apresentação de cada nível do conceito, o estudante é submetido a um teste de retenção desse nível. Após avaliar a resposta do estudante, o sistema seleciona a regra local adequada para a situação. Combinando a regra local e o padrão global (padrão proximal de aprendizagem), o sistema define o próximo passo na apresentação do conteúdo efetuando um sorteio probabilístico. Este sorteio utiliza a técnica de Monte Carlo [3]. O processo de definição do próximo passo é repetido até a conclusão do conteúdo. Desta maneira, o sistema organiza um conteúdo personalizado e reativo ao estudante.

VII. EXPERIMENTO E RESULTADOS

Para investigar a validade e a aplicabilidade das técnicas propostas neste trabalho foi desenvolvido um experimento. O objetivo deste experimento é a aquisição de dados para a análise e a fundamentação de conclusões sobre o modelo proposto.

A estrutura de suporte para o experimento consiste de formatação do conteúdo, da definição da rede neural, da definição das regras de especialistas e do desenvolvimento de sistemas para coleta de dados.

A coleta de dados consiste de três etapas. Na etapa inicial os dados são coletados com o objetivo de serem selecionados para o treinamento da RNA e, também, eles serem utilizados na análise e na comparação com as outras etapas. Nestas outras etapas os dados são coletados para a análise e a comparação com as outras coletas.

A análise dos dados ocorre em dois momentos. Em um primeiro momento os dados são analisados para a definição das características e do conjunto de treinamento da rede neural. Ao final das coletas, a análise tem como objetivo o estudo comparativo das coletas para fundamentar as conclusões do trabalho. A Figura 6 sintetiza a organização da metodologia do experimento realizado neste trabalho.

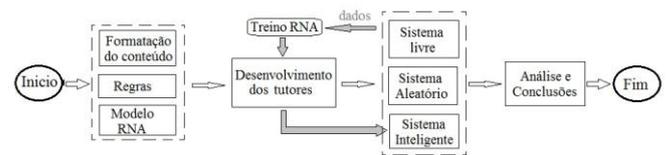


Fig. 6. Organização do Experimento

Para a realização do experimento, foram desenvolvidos três sistemas com interfaces de software semelhantes: sistema de navegação livre, sistema de navegação aleatória e sistema de navegação inteligente. A diferença entre esses sistemas é o mecanismo de decisão para a escolha do nível a ser apresentado na organização do conteúdo. Na navegação livre, é o estudante que decide o próximo nível na sequência de apresentação do conteúdo. No sistema de navegação aleatória, a decisão do próximo nível do conceito a ser apresentado é realizada por uma função de sorteio randômico do software. O sistema de navegação inteligente emprega as técnicas de modelagem propostas neste trabalho.

O tema do conteúdo apresentado foi Introdução à Informática. No conteúdo foram desenvolvidos 15 conceitos. Desta forma, o conteúdo multinível total foi composto de 75 textos (15 conceitos distribuídos em 5 níveis).

O conjunto de dados que estabelece as ações de reatividade ao estudante (regras) foi obtido com um formulário de consulta aos professores que são os especialistas em ensino. Nessa consulta foi solicitado ao professor que fizesse a indicação da ação a ser seguida para cada uma das situações possíveis no conteúdo multinível do tutor.

Durante a primeira etapa do experimento foi realizado um total de 228 navegações. Deste total, 148 foram consideradas navegações válidas para a análise dos dados. A desconsideração de 80 navegações no sistema de navegação livre ocorreu por vários problemas como reajustes no processo, estudantes que não completaram a navegação, falhas no sistema, etc.

Para a continuidade do experimento, além da coleta livre, foram realizadas 62 coletas com sistemas guiados. Dessas coletas, 31 foram realizadas com um sistema empregando as técnicas propostas neste trabalho (navegação inteligente) e 31 com um sistema de decisão aleatório. Ao final das coletas, foi realizada a análise dos dados e a avaliação comparativa entre as navegações.

A Tabela I apresenta os valores médios observados nos experimentos. É possível verificar que a navegação inteligente apresentou melhores resultados na média da nota final com menor tempo de execução do curso e menor quantidade de níveis de conceito apresentados.

TABELA I
Análise comparativa dos dados

Navegação	Tempo de apresentação (minutos)	Níveis apresentados	Média das notas	
			inicial	final
<i>Livre</i>	37,88	35,34	4,56	6,87
<i>Aleatória</i>	35,97	45	3,99	5,93
<i>Inteligente</i>	26,80	26,71	3,92	7,21

Neste ponto pode ser observada a eficiência do sistema proposto neste trabalho. Porém, é importante verificar a validade da rede neural no resultado final. Para a investigação foi empregado o teste de correlação de Pearson. O coeficiente de correlação de Pearson, mede o grau e a direção (positiva ou negativa) da correlação entre duas variáveis de escala métrica [12].

Para execução do teste de correlação, foram analisados os dados da navegação inteligente. O perfil global indicado pela RNA (padrão proximal de aprendizagem) para cada um dos 31 componentes foi comparado com o perfil individualizado efetivamente observado na navegação (conteúdo organizado pelo sistema). Após o levantamento dos perfis globais (indicado e observado) de cada elemento da amostra, foi realizado o estudo estatístico por meio da correlação de Pearson entre os perfis da amostra para verificar 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 II é apresentado o estudo completo dos cálculos das correlações globais e de cada nível.

TABELA II
Correlação de Pearson RNA x Observado

Nível	Geral	Fácil	Médio	Avançado	FAQs	Exemplos
Correlação	0,875	0,952	0,694	1	1	0,529

Os resultados obtidos utilizando a correlação de Pearson entre os perfis indicado pela RNA e o efetivamente observado em cada componente da amostra, indicam uma correlação linear positiva forte. A correlação observada sugere a indicação do padrão proximal de aprendizagem $L\Omega$ apresentado pela RNA como fortemente atuante na organização do conteúdo a ser apresentado ao estudante.

VIII. CONCLUSÕES

Ao decorrer do trabalho foram apresentadas as bases formais para definição de um sistema com a possibilidade de seleção e apresentação personalizada de conteúdos didáticos.

As definições das variáveis envolvidas se mostraram relevantes para as técnicas empregadas na solução dos problemas apresentados.

Para possibilitar a personalização do conteúdo, foi verificada a necessidade de estabelecer uma estrutura multinível. Diferentes versões do conceito possibilitam diferentes opções de apresentar o mesmo conteúdo.

O problema de definir o padrão do estudante e seu respectivo padrão proximal, pela complexidade e multidimensionalidade foi implementado com o auxílio de uma RNA com atuação generalizada. Para complementar o sistema foram inseridas regras simbólicas possibilitando reatividade às ações por meio das correções locais.

Os dados observados mostram a eficiência das técnicas empregadas, proporcionando personalização do conteúdo apresentado, sendo que foi alcançado um melhor

aproveitamento com menor quantidade de texto e, também, menos tempo de exposição.

O teste de correlação indicou a capacidade e a importância da RNA no sistema para classificar e associar o perfil do estudante a um padrão proximal de aprendizagem. Esta ação da RNA possibilita estabelecer os parâmetros para a personalização do sistema tutor inteligente.

Diante do exposto, verifica-se que o sistema apresentado tem um bom potencial como ferramenta auxiliar na tarefa de organizar a apresentação de conteúdos didáticos, de forma personalizada e reativa, em ambientes virtuais de aprendizagem.

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] W. K. Horton, Designing Web-based Training. 2000.
- [2] Vicari, R. Agentes Inteligentes en Educación Virtual. Proceedings of Seminario Internacional. Inteligencia Artificial y Seguridad. Pereira, Colombia, 2005.
- [3] Russel, S. & Norvig, P. Inteligencia Artificial: tradução da segunda edição. Rio de Janeiro, Elsevier, 2004
- [4] Fontenla, J.; Caeiro, M. e Llamas, M. A SOA Architecture to improve the tailorability and extensibility of e-learning Systems. IEEE Latin-America Transactions, Vol. 8, nº 2, 2010.
- [5] S. D. Carvalho, Mapas Auto-Organizáveis Aplicados a Sistemas Tutores Inteligentes, Goiânia, 2002. Dissertação (Mestrado em Engenharia Elétrica e de Computação) - UFG - Universidade Federal de Goiás.
- [6] Melo, F.R. Martins, W. Nalini, L. E. G. Meireles, V. Generalizador Neural de Espaços de Aprendizagem em Sistemas Tutores Inteligentes, XVII Simpósio Brasileiro de Informática na Educação - SBIE. Brasília, 2006.
- [7] Quindere, P. S. G. Adaptabilidade Temática em Sistemas Tutores Inteligentes Híbridos Dissertação de Mestrado. Universidade Federal de Goiás. Goiânia, Brasil, 2008.
- [8] Haykin, S. S. Redes neurais artificiais: princípio e prática. São Paulo, SP : Bookman, 2000.
- [9] Braga, A. P.; Carvalho, A. P. L. e Ludermir, T. B. Redes Neurais Artificiais – Teorias e Aplicações. 2ª Ed. Rio de Janeiro, LTC, 2007.
- [10] MELO, F. R. ; FLÓRES, E. L. ; CARVALHO, S. D.. Multilevel content's structure for personalization in connexionist intelligent tutor systems. In: 8th International Conference on Information Systems and Technology Management, 2011, São Paulo. Abstract and Proceedings of 8th CONTECSI. São Paulo : TECSI EAC FEA USP, 2011.
- [11] Schultz, D. P. e Schultz, S. E. Teorias da Personalidade, São Paulo, Cengage-Learning, 2008.
- [12] AGRESTI, A., FRANKLIN, C. Statistics Art and Science of Learning from data. 2ª Edition, Pearson. 2009.