
Generalizador Neural de Espaços de Aprendizagem em Sistemas Tutores Inteligentes

Francisco Ramos de Melo^{1,2,3}, Weber Martins^{1,4},

Lauro Eugênio Guimarães Nalini^{1,4}, Viviane Meireles^{1,2}

¹Grupo PIRENEUS

Escola de Engenharia Elétrica e Computação
Universidade Federal de Goiás – Goiânia – GO – Brazil

²Departamento de Ciência da Computação
Faculdade Latino Americana – Anápolis – GO – Brazil

³Departamento de Sistemas de Informação
Centro Universitário UniEvangélica – Anápolis – GO – Brazil

⁴Laboratório de Análise Experimental do Comportamento / Departamento de Psicologia
Universidade Católica de Goiás – Goiânia – GO – Brazil

chicorm@yahoo.com.br, weber@eee.ufg.br, legn@ucg.br, vmeireles@ueg.br

Abstract. *This paper presents an Intelligent Tutoring System based on MLP (Multilayer Perceptron) neural networks. It is adaptive and reactive and has the ability to offer customized and dynamic teaching. Features of apprentice's psychological profile are employed as basic elements of customization, and they are complemented by (human) expert rules. The proposed (hybrid) system is implemented on (internet) web environment to take advantages such as wide reach and portability. The investigation follows the development process of the intelligent tutor, including the software used for data collection, essential to the training of neural networks. Initially, theoretical bases are presented to characterize psychological profiles and the technology of connectionist systems. Three types of navigation (on course contents) are compared empirically: free (user has full control), random (user is controlled by chance) and intelligent (navigation is controlled by the proposed system: neural network combined with expert rules). Descriptive and inferential analysis of data indicate that the application of proposed techniques is adequate, based on (significant at 5%) results. The main aspects that have been studied are retention ("learning improvement") normalized gain, navigation total user time and number of steps (length of visited content).*

Resumo. *Este artigo apresenta um Sistema Tutor Inteligente baseado em redes neurais MLP (Perceptron Multi Camadas, do Inglês Multi Layer Perceptron), dotado de característica adaptativa e reativa, capaz de oferecer ensino personalizado e dinâmico. As características do perfil psicológico do aprendiz são utilizadas como elementos básicos da personalização, sendo complementadas por regras de especialistas, imprimindo o dinamismo necessário ao tutor. O sistema proposto (híbrido) foi desenvolvido para*

ambiente web no intuito de usufruir as vantagens que tal tecnologia oferece, tais como: alcance abrangente e portabilidade. A investigação acompanha o processo de desenvolvimento do tutor inteligente, inclusive do programa utilizado na coleta de dados, essencial no treinamento de redes neurais. O estudo expõe, inicialmente, as bases teóricas da caracterização de tipos psicológicos e a tecnologia de sistemas conexionistas. Três tipos de navegação (no conteúdo de um mesmo curso) são comparados empiricamente: livre (aprendiz controla totalmente sua navegação), aleatória (destinos são sorteados) e inteligente (destinos são determinados pelo sistema proposto: rede neural combinada com regras de especialistas). As análises (descritiva e inferencial) dos dados coletados indicam que a aplicação das técnicas propostas em sistemas tutores inteligentes é adequada, pois os resultados obtidos são significantes (ao nível de 5%) quanto a ganho normalizado de retenção (“melhoria de aprendizagem”), tempo total de navegação e número de visitas.

1. Espaços Psicológicos

Segundo Jung, tipologias psicológicas descrevem e explicam a personalidade humana. Jung observou que o comportamento humano não é algo aleatório, onde as ações são resultado do acaso. Ao invés disto, o comportamento segue **padrões** desenvolvidos a partir da estrutura da mente humana. Representante importante do mentalismo cartesiano e do inatismo kantiano, Jung observou que padrões comportamentais podem ser concebidos como correlatos à estrutura da mente humana, correlação esta presente desde o nascimento do indivíduo. Desta concepção geral, Jung desenvolveu sua teoria de tipos psicológicos baseada em quatro fatores (sentimento, raciocínio, intuição e sensibilidade) e em duas disposições (extroversão e introversão) [Jung 1921].

Os tipos psicológicos se revelam ou atuam à medida que diferentes demandas experienciais no ambiente fazem com que haja direcionamento diferencial das energias do indivíduo para cada um dos extremos dos pares de fatores: sensibilidade-intuição, raciocínio-sentimento e as disposições extroversão-introversão. Segundo a teoria, devido ao fato de um dos extremos dos pares prevalecer e atuar mais freqüentemente, a tipologia prediz que os padrões comportamentais correlatos se tornarão cada vez mais estabelecidos e predizíveis. Por sua vez, a ocorrência habitual dos padrões prevalentes conduz às diferenças individuais, diferenças estas definidas por padrões comportamentais de alta regularidade. Jung denominou esta teoria de “psicologia da consciência” por acreditar que seus elementos representavam e poderiam explicar as estruturas básicas da mente humana consciente. A partir desta teoria, estabelece-se uma forma de generalizar o comportamento do indivíduo ou, mais especificamente neste estudo, do aprendiz.

2. Redes Neurais Artificiais

O cérebro humano, uma rede neural, é composto de neurônios. Os neurônios biológicos são divididos em três seções inter-relacionadas: corpo da célula, dendritos e axônio. Os dendritos recebem os impulsos nervosos (informações) de outros neurônios, transmitindo-os até o corpo da célula. Em seguida, a informação é transformada em novo impulso, o qual é transmitido a outros neurônios através do axônio. 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 e funcionando como válvulas capazes de controlar a transmissão de impulsos (fluxo de informação) entre os neurônios na rede neural. O efeito da sinapse sobre o sinal que trafega através dela é ajustado conforme a experiência, implementando a capacidade de adaptação de toda rede neural.

As redes neurais artificiais (RNAs) [Sherry 1996] são estruturas de processamento computacionais que imitam a atividade de processamento do cérebro humano. 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 e um sinal de saída. As ligações sinápticas são representadas pelos pesos (valores que indicam o grau de importância que determinada entrada possui em relação ao respectivo neurônio). As entradas são multiplicadas pelos pesos e a soma desses resultados é o sinal de excitação do neurônio. O sinal de excitação produzirá uma saída conforme a função de ativação (transferência) interna do neurônio.

Os neurônios artificiais, analogamente ao que ocorre no cérebro, são interconectados, formando a rede neural artificial. 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 sinápticos, possibilitando a retenção das características de padrões conhecidos e, inclusive, o emprego da rede na generalização/classificação de novos padrões. Ao final desta fase, a rede estará “treinada” e capacitada a reconhecer os padrões que lhe forem apresentados, bem como capacitada a dar uma resposta coerente a padrões que não tenham feito parte do conjunto de treinamento, 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.

3. Sistemas Tutores

O conhecimento — sua aquisição e sua transmissão — tem sido instrumento utilizado para promover e garantir a sobrevivência humana, a evolução pessoal e social e a soberania das nações. Como decorrência, os processos de aquisição (aprendizagem) e de transmissão (ensino, instrução) do conhecimento têm sido alvo de muitos questionamentos e pesquisas, assim como têm induzido progressos tecnológicos ao longo da história evolutiva humana.

O modo de transmissão de conhecimentos (ou ensino) mais antigo e ainda vigente é o denominado “presencial”. Educadores e psicólogos desenvolveram, a partir de 1940, alternativas instrucionais baseadas na idéia de que parcela significativa do processo ensino-aprendizagem poderia dispensar a presença física do agente transmissor junto aos aprendizes. O conjunto de técnicas, instrumentos, procedimentos e programas que, gradativamente, surgiu deste empreendimento constituiu o campo de investigação e tecnologia educacional que veio a ser denominado “Ensino a Distância” (EAD).

Por volta dos anos 50, os cientistas passam a contar com a possibilidade de utilização dos computadores na Educação [Barlow 1961; Richmond 1975, Jonassen 1992 e Lee 2000], inicialmente, com a criação de sistemas tutores. Tais programas iniciais são considerados simples “viradores de páginas eletrônicos”. Tal tecnologia foi classificada como “Instrução Assistida por Computador” (IAC; do Inglês “Computer-Assisted Instruction” – CAI) [Eberpächer 1998].

Para contextualizar a proposta de tutores, utilizando sistemas inteligentes baseados em redes neurais artificiais, é importante observar a existência de diversas estruturas de tutoriais, variando do tutorial clássico a sofisticadas estruturas customizadas [Horton 2000]. 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.

Outra estrutura recente propõe sistemas tutores conexionistas [Alencar 2000]. O conteúdo é particionado 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 qualquer um dos outros níveis ou para o próximo contexto. Nesse modelo, após a formatação do conteúdo em contextos e níveis, aprendizes navegam livremente pelo tutorial. Tais navegações são registradas para que as melhores sejam selecionadas, baseado na melhoria de desempenho entre o teste inicial e o teste final. Uma rede neural artificial específica é treinada para cada nível de cada contexto, conforme Martins & Carvalho [Carvalho 2002]. Para uma sessão tutorial de 15 contextos, são necessárias 75 redes neurais diferentes.

4. Generalizador Neural

Conforme a proposta da “máquina de ensinar” [Skinner 1968], este trabalho fundamenta-se na capacidade da técnica de RNAs de extrair padrões capazes de serem utilizados no auxílio da navegação em um sistema tutor inteligente. O presente trabalho busca melhorar o aproveitamento da especificidade do estudante através da consideração de características psicológicas 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 do Sistema Tutor Conexionista. Por exemplo, um determinado padrão contém a quantidade de visitas dos níveis (facilitado, avançado, exemplos e FAQs) e do próximo contexto.

Esta pesquisa modifica o uso de redes neurais na estrutura conexionista apresentada em [Martins e Carvalho 2003], ampliando a caracterização do aprendiz pela adição de características psicológicas e habilidade tecnológica ao conjunto de testes (pré-teste). A rede neural é responsável pela definição do padrão global de navegação. Para tratar a situação local, foram introduzidas regras de especialistas. Desta forma, temos um sistema tutor inteligente híbrido com a capacidade de identificar e generalizar os espaços mentais do aprendiz para condução flexível do estudo através de um conteúdo. Na estrutura (apresentada na Figura 1) empregou-se uma única rede para todo o tutor, estabelecendo uma redução forte no uso deste recurso. A função dessa rede neural única é, sem dúvida, mais abrangente, genérica. A decisão do STI proposto é baseada no padrão

de navegação gerado pela RNA e no desempenho local do aprendiz (nível corrente e resultado da correção do teste) [Melo 2002; Meireles 2002].

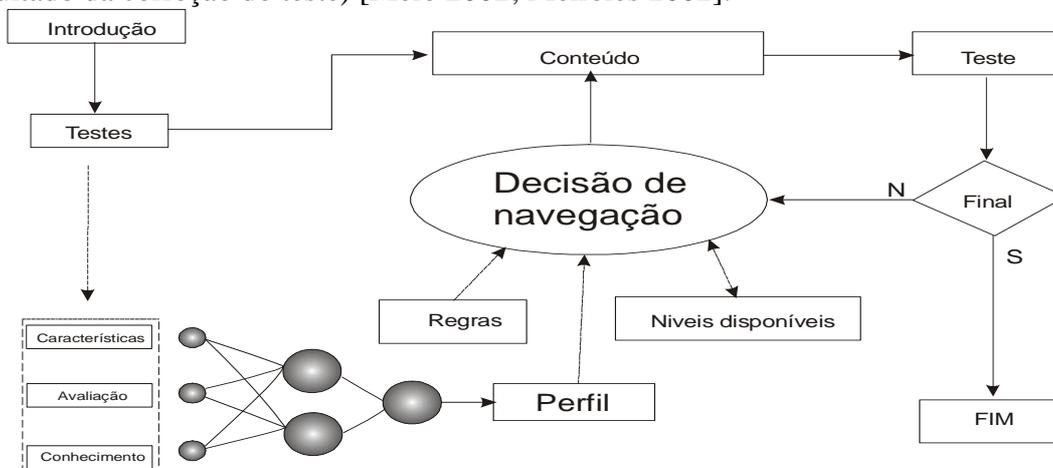


Figura 1: Estrutura proposta

O uso de características psicológicas na condução do tutor permite ao sistema decidir o que deve ser apresentado, sustentado nas preferências individuais do educando e objetivando o melhor desempenho possível. A maneira de cada estudante concentrar, processar e reter informação é considerada com intuito de realizar a personalização do processo de tutoria. As dimensões que caracterizam as características psicológicas são variáveis componentes na determinação dos padrões de navegação. Tais padrões podem ser extraídos pelas redes neurais a partir de preferências individuais (dimensões que caracterizam o tipo) dos melhores estudantes. As preferências do aprendiz são coletadas através de questionário de características psicológicas e as respostas são usadas como entradas da RNA no sentido de viabilizar a conexão entre características pessoais e uma adequada condução do processo de ensino-aprendizagem.

Neste trabalho, propomos utilizar uma rede neural que tenha à sua disposição as características psicológicas do indivíduo, a habilidade tecnológica e seu nível de conhecimento no conteúdo específico do tutorial, como é ilustrado na Figura 2. 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 possibilita a reutilização da estrutura em novos conteúdos.

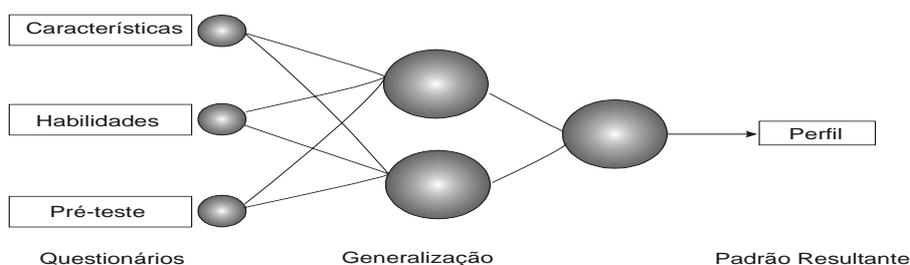


Figura 2. Formação do Perfil

Para compor a decisão da navegação inteligente, exercendo controle mais preciso e sensível ao desempenho local do aprendiz, um conjunto de regras simbólicas [Norvig 1997; Kaplan 1995] é adicionado ao sistema. A definição das regras simbólicas é feita por professores (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 3.

- | |
|---|
| <ol style="list-style-type: none">1. para cada nível visitado<ol style="list-style-type: none">1.1.obtenha resultado da correção do teste1.2.obtenha regra da situação local |
|---|

Figura 3. Utilização das regras simbólicas

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 conteúdo 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 multiplicada pela probabilidade correspondente do perfil do estudante, gerando uma distribuição de 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 distribuição probabilística resultante, o sistema utiliza uma “seleção genética” (onde os mais fortes têm maior probabilidade de serem escolhidos) [Goldberg 1989] para indicar o próximo nível a ser visitado ou a passagem para o próximo contexto.

Os dados selecionados a partir da coleta em navegação livre (na mesma estrutura sem RNA) foram utilizados para treinar a rede. Este trabalho é baseado nas redes neurais do tipo perceptrons de múltiplas camadas (MLP, Multilayer Perceptron). Trata-se do modelo mais utilizado (registrado) na literatura, merecendo precedência. Esse modelo de redes neural é indicado na implementação da estrutura devido à capacidade de tratar dados não linearmente separáveis e à habilidade de aprender pela experiência, por meio de treinamento supervisionado [Haykin 2000]. Após o treinamento, a rede MLP torna-se capaz de reconhecer, inclusive, padrões não 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.

5. Análise dos resultados

Para chegar aos resultados obtidos, desenvolveu-se um sistema tutor para a coleta de dados (Tutor Livre) e um tutor guiado sem inteligência (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. Para compor o conjunto de treinamento da rede neural, foram realizadas coletas com o Tutor Livre. Após o treinamento das redes neurais, foi efetuada nova coleta de dados com o Tutor Guiado e o Tutor Aleatório para proceder a um estudo comparativo do desempenho do sistema.

Realizamos as comparações entre as três amostras através da Estatística Descritiva, além de empregar técnicas de Estatística Inferencial para efetuar generalizações. A primeira nos apresenta os resultados imediatos, aplicados àquelas amostras especificamente. A segunda (inferencial) nos indica a significância das diferenças obtidas em termos populacionais.

Na Tabela 1, apresentamos a análise descritiva. Podemos observar pontos importantes que sugerem a maior estabilidade dos dados da navegação inteligente. 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, um fato interessante encontra-se na média da melhoria normalizada (em relação à máxima melhoria individual possível), onde a navegação inteligente (sistema proposto) alcançou a média 58,02% (a mais alta das três coletas).

Tabela 1 – Análise Descritiva dos Dados Coletados

Item	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

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). Podemos observar que a navegação inteligente apresenta, 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), mesmo comparado à situação de navegação livre (a cargo do próprio aluno).

Tabela 2 - Comparativo do desempenho médio das navegações

Navegação	Tempo (min)	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%

Na análise descritiva, podemos verificar algumas diferenças importantes entre os experimentos. Os valores apresentados apenas descrevem as amostras sem, contudo, indicar se as diferenças são realmente significativas em termos populacionais. Para apresentar a significância das diferenças apresentadas, devemos utilizar outra importante

área da estatística. A Estatística Inferencial apresenta um conjunto de técnicas que permite verificar a generalização e transferência das conclusões para toda a população. Com isto, poderemos afirmar com maior confiança e precisão se o sistema proposto deve ou não ser entendido como responsável pelas diferenças observadas.

Utilizamos o teste t-Student com nível de significância de 5%, tendo em vista que dispomos de médias. Inicialmente, analisaremos as notas iniciais, depois analisaremos as notas finais e os ganhos normalizados. O teste t-Student é realizado com a comparação de duas amostras distintas, independentes, não-pareadas. Através do teste t-Student, ao estabelecer o nível de significância, podemos verificar a probabilidade dos resultados serem semelhantes (diferenças devidas ao acaso, conforme hipótese nula), com isto é estabelecido o valor “t crítico”. O t crítico determina a zona onde a hipótese nula não deve ser rejeitada (zona não crítica) da área onde ela deve ser rejeitada e, conseqüentemente, fortalecida a hipótese alternativa do experimento (que supõe diferenças significativas). Desta forma, após a aplicação do teste t, pode-se decidir objetivamente se os dados foram raros o suficiente para assegurar objetivamente o fortalecimento de nossa hipótese.

Com a aplicação do teste t-Student, na comparação das notas iniciais, observamos que, em nenhum dos três casos, houve rejeição da hipótese nula, ou seja, todas as amostras devem ser consideradas oriundas da mesma população, ou seja, equivalentes. Com relação à comparação de notas finais, observamos diferenças significativas entre as navegações livre e aleatória e entre inteligente e aleatória. Não observamos diferenças significativas entre notas finais quanto às navegações inteligente e livre. Apesar da diferença não ser significativa, o sistema utilizou menos recursos (níveis visitados e tempo) do estudante. Finalmente, verificamos se a melhoria (ganho normalizado) observada no sistema proposto é realmente significativa (ver Tabela 3) A análise das diferenças da melhoria no aprendizado indica o sistema proposto como forte responsável pela melhoria na condução da tutoria.

Tabela 3 - Teste t sobre o ganho normalizado (“melhoria de aprendizagem”)

Navegação	Livre X Aleatória	Inteligente X Livre	Inteligente X Aleatória
<i>Médias (%)</i>	39,59 X 32,59	58,02 X 39,59	58,02 X 39,59
<i>Probabilidade (%)</i>	27	0,2	0,02
<i>t Crítico</i>	1,97	1,65	1,67
<i>t Observado</i>	1,11	2,94	3,76

Para investigar a influência da Rede Neural Artificial (RNA) no sistema proposto, 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 participante 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 sugeridos pela RNA e o efetivamente seguido. 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.

6. Conclusão

Desenvolvemos um Sistema Tutor Inteligente baseado em Redes Neurais Artificiais, realizando a personalização do aprendiz através de variáveis identificadoras do aprendiz em termos de características psicológicas. Além disto, promoveu-se um estudo mais detalhado da capacidade do tutor ensinar, comparando o desempenho entre o sistema proposto e tutores não dotados de inteligência (livre e guiado aleatoriamente).

A análise descritiva dos resultados 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. Na comparação das amostras, observamos que os melhores resultados do sistema proposto foram alcançados com média menor de níveis visitados e tempo reduzido para realização da tarefa.

A análise dos resultados com o t-Student sobre as notas finais indicou que a média maior do sistema proposto em relação ao livre não é significativa. Por outro lado, a comparação com a navegação aleatória indica (com significância efetiva de 0,7%) que o sistema proposto conduz a resultados realmente melhores. Com isto, podemos concluir que as decisões do sistema proposto são mais apropriadas que decisões casuais, resultando em médias finais no mínimo iguais ao sistema livre. A análise do ganho normalizado (“melhoria na aprendizagem”) com o t-Student mostrou que a diferença a favor do sistema proposto é significativa (efetivamente, 0,2% em relação à livre e 0,02% em relação à aleatória). Com isto, concluímos que o sistema proposto é responsável pelo aumento de retenção de conhecimentos.

Finalmente, os resultados obtidos através da correlação de Pearson entre os perfis indicado pela RNA e o efetivamente observado em cada participante da amostra indicam uma correlação linear positiva forte (0,875). Tal correlação sugere a indicação do perfil personalizado sintetizado pela RNA como fortemente atuante na definição do caminho a ser seguido no tutor em toda sua extensão. Eventuais diferenças entre os perfis justificam-se pelas correções apresentadas pela inserção das regras simbólicas que procuram corrigir situações locais não pedagógicas no processo de tutoria. Podemos, assim, observar a validade e a operatividade do sistema híbrido com a simplificação dos recursos computacionais inteligentes conexionistas no sistema, sem descaracterizar seu poder de atuação.

Apresentou-se, portanto, as bases para o desenvolvimento de sistemas tutores conexionistas no sentido de implementar o ensino através do uso de características psicológicas. A proposta apresentada expande a primeira modelagem conhecida [Carvalho 2002] no sentido de agregar o uso de características psicológicas e permitir o aproveitamento da estrutura do sistema tutorial para outros conteúdos sem necessidade de novos treinamentos, além de reduzir o número de redes neurais envolvidas para apenas uma única.

Referências

- Alencar, W. S. (2000) “Sistemas Tutores Inteligentes Baseados em Redes Neurais”. Goiânia. Dissertação (Mestrado em Engenharia Elétrica e de Computação) - UFG - Universidade Federal de Goiás, Brasil.

-
- Barlow, J. A. (1961) "The teaching and the teaching machine. Auto-instructional Devices", New York:Prentice-Hall, USA.
- Carvalho, S. D. (2002) "Mapas Auto-Organizáveis Aplicados a Sistemas Tutores Inteligentes", Goiânia,. Dissertação (Mestrado em Engenharia Elétrica e de Computação) - UFG - Universidade Federal de Goiás, Brasil.
- Eberspächer, Henri F e Kaestner, Celso A A. (1998) "A arquitetura de um sistema de autoria para construção de tutores inteligentes hipermídia e seu posicionamento na informática educativa". IV Congresso RIBIE, Brasília, Brasil.
- Goldberg, D. E. (1989) "Genetic Algorithms in Search, Optimization and Machine Learning" Addison Wesley, USA.
- Haykin, S. S. (2000) "Redes Neurais Artificiais - Princípio e Prática". 2ª Edição, Bookman, São Paulo, Brasil.
- Horton, W. K. (2000) "Designing Web-based Training", Wiley, New York, USA.
- Jung, C. G. (1921) "Psychological Types", trans. By H. G. Baynes, ver. By R.F.C. Hull. Princetoon, NJ: Princeton University Press, 1971 (originally published in 1921).
- Kaplan, R. & Rock, D. (1995) "New directions for intelligent tutoring systems". Artificial Intelligence Expert, February, USA.
- Lee, W. W. & Owens, D. L. (2000) "Multimedia-based instructional design: computer-based training, web-based training, and distance learning". Jossey-Bass/Pfeiffer, San Francisco : CA, USA.
- Martins, W. & Carvalho, S. D. (2003) "Mapas Auto-Organizáveis Aplicados a Sistemas Tutores Inteligentes". Anais do VI Congresso Brasileiro de Redes Neurais, pp. 361-366, São Paulo, Brasil.
- Melo, F.R. (2002) "Sistemas Tutores Inteligentes Híbridos Baseados em Características Psicológicas". Goiânia. Dissertação (Mestrado em Engenharia Elétrica e de Computação) - UFG - Universidade Federal de Goiás, Brasil.
- Meiros, V. (2002) "Sistemas Tutores Inteligentes Híbridos Baseados em Estilos de Aprendizagem". Goiânia. Dissertação (Mestrado em Engenharia Elétrica e de Computação) - UFG - Universidade Federal de Goiás, Brasil.
- Norvig, P. & Russel, S. (1997) "Artificial Intelligence: a modern approach". New Jersey, NJ: Prentice-Hall, USA.
- Pierce, W. D. & Epling, W. F. (1999) " Behavior analysis and learning". Prentice Hall, Upper Saddle River, New Jersey, USA.
- Richmond, W.K. (1975) "A Revolução no Ensino" tradução do original "The Teaching Revolution", Companhia Editora Nacional, Brasil.
- Sherry, L. (1996) "Issues in distance learning". International Journal of Educational Telecommunications", vol 1 (4), 337-365, USA.
- Skinner, B. F. (1968) "The technology of teaching.", New York: Appleton-Century-Crofts, USA.