

Mapas Auto-Organizáveis Aplicados a Sistemas Tutores Inteligentes

Weber Martins¹, Sirlon Diniz de Carvalho^{1,2}

¹Universidade Federal de Goiás
Escola de Engenharia Elétrica e de Computação
Grupo de Pesquisa Pireneus

²Faculdades Alves Faria

E-mails: weber@eee.ufg.br, sirlon@pireneus.eee.ufg.br

Abstract

This work presents an Intelligent Tutorial System based on SOM (Self-Organizing Maps) neural networks, able to adapt and react in order to offer customized and dynamic tuition. The proposed system is implemented in web environment (and technology) to take advantages like: wide covering, portability, among others. The content, source of knowledge to be learned, has been modeled in an original way and is adequate to neural control. Two user groups have been analyzed. The first one moves freely in the content, while the other group is guided by the decision of neural networks previously trained from the most successful free interactions. Statistical techniques were employed to analyze the significance of sample differences to compare the two groups. Results related to the interaction time have shown significant differences in favor of the guided tutor. With relation to the acquisition of new knowledge, all users guided by the intelligent control have performed as well as the best ones which had freedom to navigate through the content.

1. Introdução

Desde a década de cinquenta, o computador tem sido empregado na Educação como ferramenta auxiliar na tarefa de ensino-aprendizagem [1]. Os primeiros sistemas computacionais aplicados na Educação são classificados como Instrução Assistida por Computador ou Sistemas CAI (CAI, do Inglês Computer-Assisted Instruction). Tais sistemas não incluem técnicas inteligentes em sua concepção. Com o avanço das técnicas inteligentes (Inteligência Artificial Simbólica), nasceu neste meio um novo paradigma de sistemas educacionais, denominados ICAI (do Inglês, Intelligent Computer-Assisted Instruction) ou Sistemas Tutores Inteligentes (STI). Nessa nova geração, os sistemas passaram a ter a capacidade de representar determinados domínios e de se adaptar às características dos alunos [2].

Apesar da evolução alcançada nos sistemas ICAI, nesses modelos os métodos tutores são, basicamente, determinados pelo conhecimento conceitual do especialista e pelo comportamento de aprendizagem dos estudantes durante a execução da tutoria. Além disso, o

desenvolvimento de tais sistemas encontra-se limitado à área simbólica da Inteligência Artificial (IA).

Diante do contexto atual dos projetos de Informática voltados para a Educação, resolveu-se explorar uma nova linha de pesquisa através da aplicação de redes neurais artificiais (IA conexionista) em sistemas tutores inteligentes. Neste trabalho, o sistema é treinado com dados extraídos dos próprios estudantes para permitir a tomada de decisões baseadas na forma humana de agir.

Até hoje somente algumas investigações foram elaborados no sentido de aplicar redes neurais em sistemas tutores inteligentes. Alencar [3] demonstrou a capacidade de uma rede neural Perceptron multicamadas extrair padrões que poderiam ser utilizados para auxiliar na navegação de um sistema tutor inteligente.

A principal diferença entre esta proposta e os sistemas ICAI tradicionais é que, nestes últimos, o conhecimento do especialista é fundamental para a modelagem do sistema; enquanto, em nosso projeto, os comportamentos dos próprios alunos indicam as ações do tutor.

Utilizam-se, neste trabalho, as redes neurais denominadas Mapas Auto-Organizáveis ou Self Organizing Maps (SOM) devido à sua capacidade de manter uma ordenação topológica dos padrões treinados. Para atuarem como classificadores, projetou-se um esquema específico de rotulação. Acredita-se que as pessoas quando submetidas a determinadas tarefas tendem a manter padrões, apesar de suas diferenças individuais. Assim, as redes neurais SOM tornam o sistema adaptativo, capaz de permitir um ensino individualizado e personalizado.

2. Mapas Auto-Organizáveis

Desenvolvida por Teuvo Kohonen na década de oitenta [4], a rede neural Self Organising Map (SOM) é biologicamente sustentada por mapas topológicos presentes no córtex cerebral. Esse modelo possui a capacidade de se auto-organizar, preservando topologicamente a estrutura dos padrões apresentados.

Na rede SOM, neurônios próximos (na disposição do mapa), devem responder por funções similares (específicas), tal como no cérebro de animais mais evoluídos. Em tais cérebros, determinadas áreas

respondem por estímulos de mesma natureza: fala, audição, visão, etc.

Os Mapas Auto-Organizáveis são constituídos basicamente por uma camada (além da camada de entrada, onde cada sinal do mundo externo é percebido por um neurônio sensorial determinado), como pode ser visto na Figura 1. Seu treinamento é baseado no algoritmo de aprendizagem por competição. Os neurônios da camada de saída competem entre si para definir o mais semelhante ao padrão apresentado, entretanto não existem conexões físicas entre eles. Os neurônios são localmente interconectados por uma relação de vizinhança, determinando a topologia do mapa (linear em anel, hexagonal e retangular).

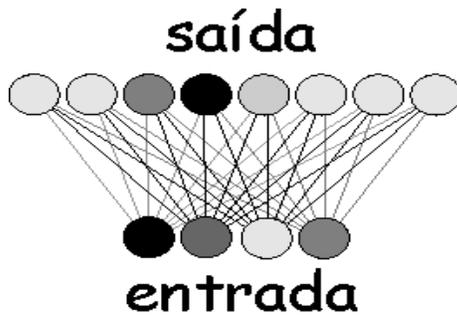


Figura 1: Mapa de Kohonen/Rede SOM

A determinação do neurônio vencedor em uma rede SOM pode ser feita utilizando diversas métricas. O procedimento mais comum é verificar qual neurônio possui a menor distância euclidiana em relação ao padrão apresentado [5]. Essa distância pode ser calculada da seguinte forma:

$$Distância = \sum_{i=1}^n \| x_i - w_{ji} \|$$

Onde:

x_i : é a i -ésima entrada do padrão apresentado à rede;
 w_{ji} : peso do neurônio (referente à entrada).

Cada neurônio tem pesos sinápticos correspondentes a cada uma das entradas. Se forem consideradas três entradas de cores R, G e B (red, green e blue), por exemplo, haverá um vetor de pesos com três componentes, como pode ser visto na Figura 2.

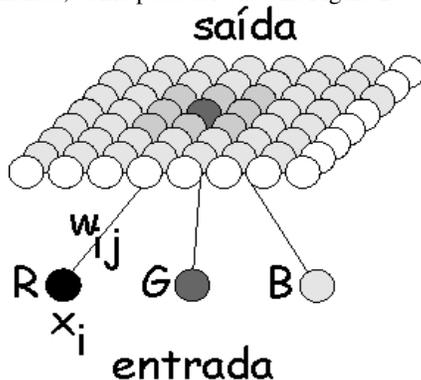


Figura 2: Pesos associados em uma rede SOM

A inicialização dos pesos em uma rede SOM é feita, habitualmente, utilizando-se valores aleatórios. Todavia, nem sempre tal procedimento produz o melhor resultado, tendo em vista que alguns vetores de pesos podem assumir valores muito diferentes dos padrões de treinamento. Desta forma, alguns nodos da rede tornam-se inutilizáveis, pois poderão nunca representar um padrão do conjunto de exemplos. Uma alternativa é usar amostras extraídas aleatoriamente do conjunto de exemplos como atribuição inicial aos pesos.

O treinamento de uma rede SOM é feito em duas fases: ordenação global, que deve ocorrer geralmente durante os primeiros mil passos, e ajuste fino (convergência) que dura entre cem e mil ciclos a mais do que a primeira fase.

3. Sistema Proposto

O sistema proposto é baseado em redes neurais artificiais onde, especificamente, utilizam-se os mapas de Kohonen (Self Organizing Maps ou Mapas Auto-Organizáveis). O modelo de rede neural escolhido pode ser encontrado nas mais diversas aplicações, devido à sua capacidade de ordenação topológica [6].

A idéia de criar um sistema tutor inteligente baseado em redes neurais artificiais veio do interesse de desenvolver um sistema que pudesse tomar decisões, independentemente da interferência de um especialista. Na maioria dos sistemas tutores inteligentes encontrados, o trabalho de um especialista é exigido para criar a *base de domínio* [7], responsável pelas tomadas de decisões.

No sistema proposto, as redes neurais artificiais são usadas para tomar as decisões. O treinamento das redes é definido a partir de um conjunto de exemplos extraído de coleta de dados. Tal coleta foi realizada através da utilização de um software tutor, denominado Tutor Livre.

O sistema Tutor Guiado (inteligente) é baseado nas características das pessoas que se submeteram à coleta de dados, de onde foram gerados os padrões para o treinamento das redes neurais. A conseqüente adaptação do tutor é, também, baseada na forma que as pessoas realmente estudam, dando características de maior proximidade da forma humana de agir. Deste modo, a “base de domínio” deixa de existir, dando lugar às redes neurais artificiais, que passam a ser as responsáveis pelas tomadas de decisões.

3.1. Tutor Livre

A primeira etapa do projeto foi coletar dados utilizando o Tutor Livre, cujas características são similares às do Tutor Guiado, porém não dotado de inteligência. Sua estrutura básica pode ser vista na Figura 3.

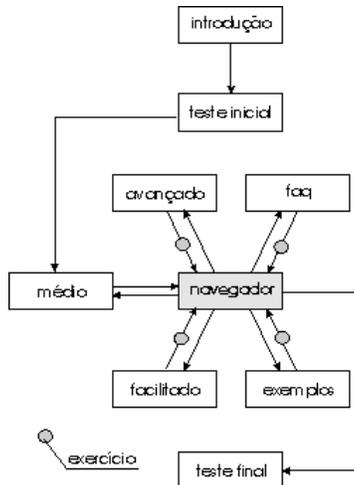


Figura 3: Estrutura do Tutor Livre

O Tutor Livre é um software composto de onze contextos sobre conceitos básicos de redes de computadores. Os assuntos são constituídos por uma seqüência de textos, dispostos em cinco níveis distintos, além dos testes inicial e final. Destes cinco níveis, três podem ser considerados como principais (facilitado, médio e avançado) e os outros dois como níveis auxiliares (FAQs e exemplos).

Cada um dos níveis (facilitado, médio, avançado, FAQs e exemplos) é seguido de uma questão relacionada ao conteúdo daquele contexto e nível. Depois de executado o teste inicial, o usuário é remetido ao nível médio. Depois de estudado este nível (médio) e respondido o exercício correspondente, o usuário é exposto a uma página de navegação que lhe permite consultar outros níveis ou prosseguir para o próximo contexto, de acordo com a sua necessidade e interesse. Se desejar prosseguir, mesmo depois de visitados outros níveis, o tutor sempre o conduzirá ao nível médio do próximo contexto, ou ao o teste final, quando concluído o tutor.

A denominação “Tutor Livre” é justificada pelo fato de que o usuário pode visitar quaisquer dos níveis na ordem que desejar. A única imposição do tutor se relaciona ao nível médio e aos testes inicial e final, que devem ser visitados obrigatoriamente.

3.2. Tutor Guiado

O Tutor Guiado segue praticamente a mesma estrutura de distribuição de contextos abordada pelo Tutor Livre, ou seja, testes inicial e final, níveis facilitado, médio, avançado, FAQs e exemplos. A grande diferença entre um modelo e outro é com relação à forma de navegação. No **Tutor Guiado**, o “navegador”, existente no modelo livre, é **substituído pelas redes neurais artificiais**. Cabe então às redes neurais tomar a decisão de qual o próximo passo que o aluno deve seguir. A Figura 4 ilustra a estrutura do Tutor Guiado.

Na mesma linha de raciocínio abordada pelo Tutor Livre, no Tutor Guiado o usuário é submetido às avaliações inicial e final, bem como ao nível médio de todos os contextos. Contudo, neste último modelo o usuário não tem a liberdade de escolher qual nível visitar e em qual ordem fazê-lo. A **rede neural** é quem **decide** e submete o educando ao **nível** mais adequado ao seu perfil, inclusive um novo contexto, quando for o caso.

No Tutor Guiado, uma rede neural está associada a cada conjunto texto/exercício de cada nível. Ao término da leitura do conteúdo e resposta do respectivo exercício, os dados captados naquele instante são submetidos à rede neural pertencente àquele nível, para a tomada de decisão.

As características dos textos e exercícios seguem inalteradas nos tutores Livre e Guiado, porque os dados coletados durante a navegação livre, destinados ao treinamento das redes neurais, devem ser coerentes com os dados coletados no Tutor Guiado. Desta forma, em ambos os tutores, mantém-se a mesma escolha de layouts, cores, textos, etc.

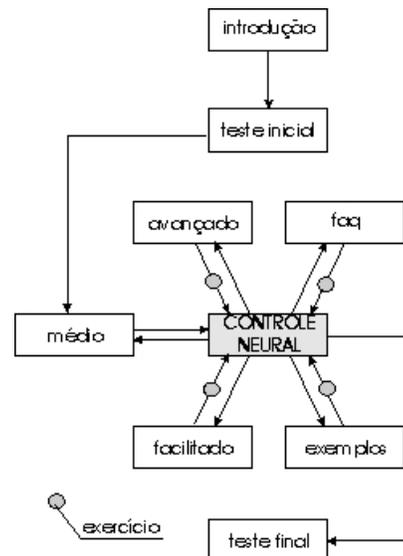


Figura 4: Estrutura do Tutor Guiado

No Tutor Guiado, assim como no Tutor Livre, cada passo do usuário é registrado em um banco de dados. Os registros resultantes são usados para submissão à rede neural, para decisão do próximo passo, bem como para comparação de resultados entre os dois tutores.

O **Tutor Guiado** oferece a vantagem de ser **facilmente adaptado a qualquer curso** (conteúdo), desde que possa ser oferecido com a mesma estrutura. Para tanto, torna-se necessário **apenas a inclusão** do novo curso no tutor, uma vez que o software já está preparado para isso. Naturalmente, far-se-á necessária a devida **coleta** e conseqüente **treinamento das redes neurais** associadas.

4. Análise dos Resultados

4.1. Coleta de Dados

No intuito de obter maior uniformidade nos dados, tanto componentes do conjunto de treinamento quanto do Tutor Guiado, a coleta foi limitada a uma população específica. Foram escolhidos alunos dos primeiros anos dos cursos de Engenharia da Computação e de Sistemas da Informação.

Antes de os alunos serem submetidos aos tutores, foi distribuído material explicativo sobre o sistema. As principais características do tutor foram expostas, de modo a minimizar problemas inerentes à navegação. Foram transmitidas várias informações sobre o software, tais como estrutura, ambiente de desenvolvimento e tempo médio para conclusão do curso proposto.

As coletas para os tutores Livre e Guiado envolveram dois grupos diferentes, sendo um para cada tutor. Tal procedimento permite a comparação de grupos com características comuns, mas submetidos a situações distintas.

4.2. Conjunto de Treinamento

Vinte e dois alunos foram submetidos à coleta de dados no Tutor Livre, sendo que vinte e um destes tiveram os dados selecionados e utilizados no conjunto de treinamento. A citada seleção refere-se à utilização apenas dos registros dos alunos que obtiveram algum aprendizado durante a execução do tutor, isto é, somente os alunos que atingiram nota maior no teste final, relativo ao teste inicial, tiveram seus dados computados e incluídos no conjunto de treinamento.

Os testes inicial e final são compostos de 11 (onze) questões cada, de onde foram gerados 462 (quatrocentos e sessenta e dois) registros. Em cada registro foram coletadas informações como nível de acerto, latência (em milissegundos) e grau de satisfação.

O tutor possui 11 (onze) contextos, divididos em 05 (cinco) níveis cada (facilitado, médio, avançado, FAQs e exemplos), sendo que cada um destes possui um exercício associado. As visitas a estes contextos e seus respectivos exercícios produziram um total de 1.418 (mil quatrocentos e dezoito) registros

4.3. Redes Neurais

Para este trabalho, optou-se por usar redes SOM unidimensionais, com vizinhança em formato de anel. Cada rede neural possui um total de 10 (dez) neurônios, cujos pesos iniciais foram escolhidos aleatoriamente com valores próximos de zero.

Mantiveram-se os mesmos padrões de treinamentos para todas as redes. Cada uma delas foram treinadas com 540 ciclos por neurônio, totalizando 5.400 ciclos. A vizinhança inicial adotada foi igual à metade do raio da rede. A redução de vizinhança seguiu aos padrões indicados pelo modelo SOM [8], fase de ordenação topológica e período de estabilização (ajuste fino).

A cada conjunto de “texto e exercício” (que define um par contexto-nível) associou-se uma rede neural

SOM com as características acima descritas, resultando em um total de 55 redes neurais. Tais redes permitem ao tutor, após a leitura de cada texto e resposta do respectivo exercício, tomar a decisão de qual próximo tópico que o aluno deverá estudar.

Depois de treinadas, as redes neurais apresentaram boa ordenação topológica e precisão de resposta. Assim, o **sistema independe de regras** específicas relativas à estratégia de ensino e, conseqüentemente, do especialista humano nesta área. A **decisão** sobre os destinos apropriados durante a navegação guiada é **tomada pela rede neural**, treinada a partir dos melhores exemplos.

4.4. Rotulação dos Neurônios

A rede neural SOM tem apenas uma camada e, na sua forma mais simples, ela é utilizada apenas para informar qual é o neurônio vencedor ou o que mais se adaptou (ajustou suas sinapses convenientemente) a um determinado padrão. No caso deste trabalho, cada neurônio deve ser capaz de decidir entre cinco níveis distintos de orientação (cinco classes pré-definidas). Assim, a rede neural, além de determinar o neurônio vencedor, deve habilitar a este indicar qual dos próximos possíveis níveis o aluno deverá visitar. A partir do nível médio de um determinado contexto, o aluno pode visitar o nível facilitado, médio do próximo contexto, avançado, FAQs ou exemplos.

Para permitir aos neurônios tomarem decisões variadas, foi criado um processo de rotulação que consiste em associar cada neurônio ao nível que ele deve sugerir. A rotulação ocorre apenas depois do treinamento das redes neurais, quando cada exemplo treinado é mapeado na rede, reforçando qual o próximo passo que o neurônio deverá indicar. Isto é feito com base no passo seguinte executado pelo aluno (bem sucedido) que gerou o padrão.

4.5. Análise do Tempo de Execução

Quando se fala em ensinar, mais especificamente em ensino a distância, um fator da maior relevância é o tempo gasto no curso. Nesta linha de raciocínio, faz-se adiante uma comparação entre o tempo médio gasto para conclusão de estudos nos tutores Livre e Guiado. Nesta análise, não estão inseridas as latências dos testes inicial e final, tendo em vista que o interesse é focalizar o tempo gasto em estudo propriamente dito. Isto inclui as latências de contextos e de seus respectivos exercícios. O gráfico da Figura 5 mostra o tempo médio gasto na execução de cada um dos tutores.

De acordo com o gráfico da Figura 5, fica evidente que no Tutor Guiado o tempo de curso foi reduzido significativamente. De qualquer forma, realizou-se análise estatística para verificar se a diferença entre as médias é realmente significativa.

Aplicou-se o teste “*t*” de Student, assumindo como hipótese nula (H_0) que a diferença entre as médias se deveu ao acaso, e como hipótese alternativa (H_a) que a característica do Tutor Guiado influenciou na diminuição do tempo de estudo.

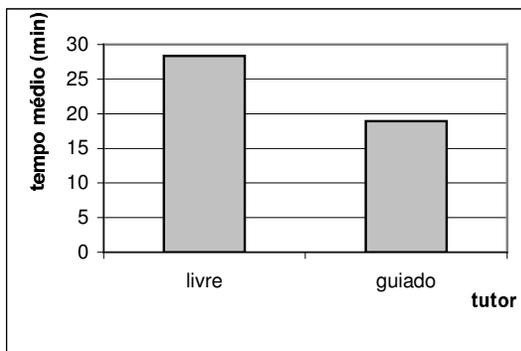


Figura 5: Gráfico do tempo de execução dos tutores.

O teste “*t*” aplicado aos dados resultou no valor de 2,65 para “*t* observado”. Considerando ainda a tábua de valores críticos da distribuição *t*, para um nível de significância (α) de 5% e grau de liberdade (gl) 39, tem-se um “*t* crítico” de 1,68. Com “*t* observado” maior do que “*t* crítico”, pode-se rejeitar a hipótese nula, em favor da hipótese alternativa. Portanto, conclui-se estatisticamente, com nível de significância de 5%, que o Tutor Guiado contribuiu para a redução do tempo de estudo.

4.6. Análise dos Testes Finais

Inicialmente, verificou-se em quais dos tutores os alunos conseguiram maior resultado. Isto foi feito através da comparação das médias de questões respondidas corretamente nos testes finais de ambos os tutores, considerando no Tutor Livre apenas os dados componentes do conjunto de treinamento. O interesse é constatar se as características dos tutores puderam influenciar nos resultados dos testes finais dos alunos, que, neste trabalho, refere-se como aprendizado.

O gráfico da Figura 6 apresenta o número médio de questões respondidas corretamente nos testes inicial e final dos tutores (conjunto de treinamentos e Tutor Guiado). Como pode ser visto no gráfico, a navegação livre ofereceu uma pequena vantagem de aprendizado em relação à navegação guiada, apesar de os dois tutores terem apresentado taxas de acertos muito próximas.

Os resultados obtidos, nos testes finais dos tutores Livre e Guiado, remete à indicação de realizar uma análise estatística para verificar se a diferença entre as médias é realmente significativa ou casual. Para fazer tal análise, aplicou-se o teste “*t*” de Student, onde a hipótese nula (H_0) supõe que a diferença entre as médias deve-se ao acaso. Para contrapor à H_0 , supõe-se H_a onde o desempenho do Tutor Livre foi significativamente maior.

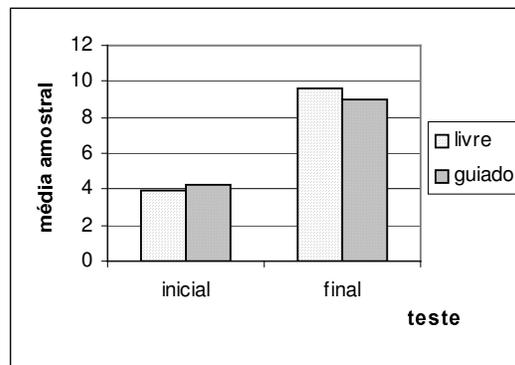


Figura 6: Comparação entre testes e tutores.

Com a aplicação do teste “*t*” obteve-se o valor de 1,55 para “*t* observado”. Consultando a tabela de valores críticos da distribuição *t* de Student, para um nível de significância (α) de 5% e grau de liberdade (gl) 39, verifica-se um “*t* crítico” de 1,68. Portanto, o valor obtido na análise está fora da área crítica. Com tal resultado, pode-se considerar com nível de significância de 5% que, estatisticamente, ambos os tutores obtiveram o mesmo desempenho na tarefa de ensinar.

5. Conclusão

Este trabalho formalizou a proposta de um Sistema Tutor Inteligente baseado em Mapas Auto-Organizáveis ou redes SOM (mapas de Kohonen).

Neste estudo, além de ter desenvolvido um Sistema Tutor Inteligente baseado em redes neurais, promoveu-se ainda um estudo mais detalhado da sua capacidade de ensinar, quando comparado a um tutor não dotado de inteligência.

Para chegar aos resultados obtidos, desenvolveu-se no decorrer do estudo um sistema tutor para a coleta de dados, denominado Tutor Livre. O Tutor Livre tem a mesma estrutura do Tutor Guiado proposto neste trabalho, porém não é dotado de inteligência. A coleta dos dados utilizados no treinamento das redes neurais foi realizada com alunos dos primeiros anos dos cursos de Engenharia da Computação e de Sistemas da Informação. Após o treinamento das redes neurais e conseqüente adaptação ao tutor inteligente, foi efetuada uma nova coleta de dados, com o Tutor Guiado, para proceder um estudo do desempenho do sistema.

Na comparação entre o Tutor Livre e o Tutor Guiado, foi comprovado estatisticamente que os alunos apresentaram semelhantes desempenhos de aprendizado. Em contrapartida, no sistema proposto observou-se uma significativa diminuição no tempo de tutoria. Isto implica oferecer treinamentos dinâmicos e personalizados, com menor tempo de estudo.

Este trabalho contribui no sentido de apresentar uma nova proposta para a criação de Sistemas Tutores Inteligentes. Isto não significa que as redes neurais

artificiais devam substituir quaisquer outras abordagens utilizadas na criação de STIs, mas, sim, que elas podem ser aplicadas como método alternativo e, até mesmo, em conjunto com outras tecnologias.

A estrutura desenvolvida oferece ainda a vantagem de ser facilmente utilizada por tutores (conteúdos) diversos.

Referências

- [1] CHAIBEN, H. Um Ambiente Computacional de Aprendizagem Baseado em Redes Semânticas. Curitiba, 1996. Dissertação (Mestrado em Ciências) - CEFET-PR - Centro Federal de Educação Tecnológica do Paraná.
- [2] GIRAFFA, L.M.M & VICCARI, R.M. The Use of Agents Techniques on Intelligent Tutoring Systems. Instituto de Informática-PUC/RS. Porto Alegre, 1997.
- [3] ALENCAR, W.S. Sistemas Tutores Inteligentes Baseados em Redes Neurais. Escola de Engenharia Elétrica e de Computação. Goiânia. Janeiro, 2000.
- [4] KOHONEN T. (1982). Analysis of a Simple Self-Organizing Process. Biological Cybernetics 44:135-140. Springer.
- [5] SILVA, J.C.M. "Ranking" de Dados Multidimensionais Usando Mapas Auto-Organizáveis e Algoritmos Genéticos. Goiânia, 2000. Dissertação (Mestrado em Engenharia da Computação), UFG-GO, Escola de Engenharia Elétrica e de Computação.
- [6] HAYKIN, S. S.; Redes Neurais Artificiais - Princípio e Prática. 2ª Edição, Bookman, São Paulo, 2000.
- [7] VICCARI, R.M. & GIRAFFA, L.M.M, Sistemas Tutores Inteligentes: Abordagem Tradicional vrs. Abordagem de Agentes. XII Simpósio Brasileiro de Inteligência Artificial. Curitiba. Outubro, 1996.
- [8] KOHONEN, T. Self-Organizing Maps. Berlin: Springer, 2001.