
Classificação de Aprendizes através de Mapas Auto-Organizáveis.

Robinson Vida Noronha^{1,3}, Nizam Omar^{1,2},
Rafael Duarte Coelho dos Santos⁴, Clovis Torres Fernandes¹

¹Instituto Tecnológico de Aeronáutica
Praça Marechal Eduardo Gomes, 50 – Vila das Acácias – CEP 12228-900- São
José dos Campos – SP – Brasil.

²Universidade Presbiteriana Mackenzie
Rua da Consolação, 930 – CEP 01302-970 – São Paulo – SP – Brasil

³Centro Federal de Educação Tecnológica do Paraná
Av. Sete de Setembro, 3165 – CEP 80230-010 – Curitiba Pr – Brasil.

⁴Instituto Brasileiro de Tecnologia Avançada
Rua Laurent Martins, 329 – CEP 12242-431 – São José dos Campos SP –
Brasil

rvida@cefetpr.br, omar@mackenzie.com.br, rafael@geoambiente.com.br,
clovis@comp.ita.br

Abstract. *The ability to formulate apprentice's models is a critical component in the Intelligent Tutor System. One of the great difficulties found in the construction of systems that it adapt to the apprentice's characteristics is to determine the knowledge and the apprentice's believes before, during and at the end of the training sessions. Several technologies can be used for the making of student models, Artificial Neural Nets (ANN) it is the subject of this work. The algorithm of Kohonen has been obtaining success as classifier of objects with attributes and values in common. In this experiment, a questionnaire of initial diagnosis was applied 88 new computer science students. The obtained data were interpreted through the self-organizing maps (Kohonen) and confronted with the teacher's opinion after a month of class.*

Resumo. *A habilidade de elaborar modelos de aprendiz é um componente crítico nos sistemas tutores inteligentes. Uma das grandes dificuldades encontradas na construção de sistemas que se adaptem às caractrísticas do aprendiz é determinar os conhecimentos e crenças do aluno antes, durante e ao término das sessões de treinamento. Neste experimento, um questionário de diagnóstico inicial foi aplicado a 88 estudantes que iniciaram o curso de tecnologia em informática. Os dados obtidos foram interpretados através de Redes Neurais Artificiais empregando o algoritmo de Kohonen e confrontados com a opinião do professor da disciplina após um mês de aula.*

1. Introdução

A democratização de acesso a conteúdos coloca em um mesmo ambiente educacional, seja este uma sala de aula ou um ambiente computacional de ensino, aprendizes com conhecimentos e habilidades diferenciadas formando grupos heterogêneos. Dar atendimento personalizado ao aluno é uma utopia buscada pelos Sistemas Tutores Inteligentes.

A habilidade de definir modelos ou estereótipos de aprendiz é um componente crítico em sistemas tutores inteligentes. Uma das grandes dificuldades encontradas na construção de sistemas que se adaptem ao aluno é determinar os conhecimentos e crenças do estudante antes, durante e ao término das sessões de treinamento.

O estudante pode cometer erros ao ser questionado sobre um certo domínio. O erro cometido pelo aprendiz pode ser causado por diversos fatores tais como: i) conhecimento inconsistente, ii) conhecimento faltante, iii) fadiga, iv) distração, v) depressão entre outros. Estes erros, ou lacunas de aprendizagem, têm sido um grande desafio aos pesquisadores em modelagem de estudante.

Uma técnica empregada na obtenção de informações a respeito das crenças e conhecimentos de um aprendiz é capturar informações das interações aprendiz-ambiente. Estas informações permitem a modificação do ambiente para personalizar o aprendizado. A adaptação do ambiente permite que o sistema de tutoria acerte as lacunas de aprendizagem.

As alterações no ambiente podem variar desde a confecção e apresentação de diálogos por parte do tutor, definição do próximo tópico a ser apresentado ao aprendiz, limitar a continuidade do treinamento ou mesmo encaminhá-lo a assuntos já apresentados.

O ser humano possui habilidades limitadas no reconhecimento de padrões com grande volume de informações e parâmetros. Neste aspecto, as Redes Neurais Artificiais têm sido empregada em atividades de classificação, reconhecimento e obtenção de padrões. Dos algoritmos disponíveis para o emprego em uma rede neural, o self organization map ou algoritmo de Kohonen [Kohonen 1997] tem sido utilizado com sucesso e bom desempenho em sistemas de mineração de dados. A principal característica deste algoritmo é a capacidade de identificar classes ou grupos com características semelhantes.

O algoritmo de Kohonen é empregado com sucesso em simulação, classificação ou previsão de resultados em diversos domínios, entre estes, podemos destacar: previsão de reações químicas [Petit et al 2002] ou consumo de energia elétrica [Lendasse et al 2000], reconhecimento de imagens, ou em tarefas de mineração de dados de um modo geral.

Este trabalho apresenta os resultados do emprego do algoritmo de Kohonen para classificar estudantes em níveis de conhecimento. Esta classificação tem a função de obter macro-informações a respeito do conhecimento do aprendiz no início de um programa de estudos. Estas informações podem nortear a profundidade em que os assuntos serão trabalhados durante o processo ensino-aprendizagem. Estas informações compõem um modelo de aprendiz.

O levantamento de informações do aprendiz realizado neste trabalho procurou reduzir a sobrecarga cognitiva e tensão emocional encontradas em uma avaliação formal. Os conhecimentos e crenças do aprendiz são agora determinados de maneira a delimitar o conteúdo programático a ser trabalhado em um programa de tutoria. Oitenta e oito estudantes foram selecionados do primeiro ano do curso de tecnologia em informática para participar do experimento.

2. Trabalhos Correlatos

[Holt et al 1991] apresenta algumas barreiras na modelagem do conhecimento do aprendiz, podendo ser destacada: i) a grande quantidade de incertezas e ruídos, ii) o processo de inferência é incompleto e pode ser baseado em conhecimentos inconsistente, iii) a dificuldade de construção de explicações do comportamento do aprendiz e iv) estudantes são criativos e constantemente inventam formas não previstas na solução de questões.

As barreiras descritas por [Holt et al 1991] tem fornecido um bom desafio aos autores de sistemas de modelagem de aprendiz. Um dos possíveis caminhos a serem explorados é o da classificação de estudantes de acordo com as lacunas de aprendizagem apresentadas. Nesta seção são apresentados alguns trabalhos referentes a métodos que podem e foram empregados na classificação de aprendizes.

[Bussmann 1991] trabalha com o conceito de similaridade para a classificação de objetos. Semelhança familiar, termo empregado por Bussmann, é empregada para classificar objetos com atributos diferentes. Esta classificação considera os atributos comuns e exclusivos dos objetos.

[Direne & Scott 2001] apresentam um experimento que levantou 15 capacidades do perito em relação aos novatos. O experimento foi realizado com um domínio de alta complexidade, o diagnóstico de imagens médicas. O ambiente computacional onde o experimento foi realizado, denominado de RUI [Direne 1997], é um sistema de autoria com modelo independente de domínio para desenvolvimento de ITS (Sistema Tutor Inteligente). Através de técnica de descoberta guiada, o ambiente explora a representação de conceitos visuais. Os aprendizes desenvolvem as capacidades da perícia de um radiologista através de diálogos com o ambiente tutor. As informações do conhecimento do estudante são obtidas através da discriminação entre as soluções apresentadas pelo aprendiz e o especialista em um determinado cenário.

Quinlan [Quinlan 1983] relata experimentos de retirada de informações de grandes massas de dados através de processos de inferência indutiva. O algoritmo utilizado trabalha com objetos de classes conhecidas em termos de coleções fixas de propriedades ou atributos. Através de um mecanismo de “Inductive Inference Machinery” desenvolvido especialmente para o sistema, obtém-se regras de classificação para uma coleção de objetos pertencentes a classes. Cada objeto necessita ser descrito em termos de um conjunto fixo de atributos.

[Baffes & Mooney 1996] apresenta técnicas de Machine Learning para obtenção de bibliotecas de erros do conhecimento do aprendiz. Um modelo de aprendizagem, definido pelo tutor humano é utilizado como referência para a modelagem. O estudante ao iniciar o seu treinamento, recebe uma cópia deste modelo. A interação do aprendiz com os desafios apresentados pelo ambiente determinam alterações em seu modelo. Estas alterações são realizadas de tal forma a reduzir o impacto na base de

conhecimento e não gerar inconsistências. Bibliotecas de erros é uma boa solução na modelagem de aprendiz do tipo “Overlay Student Model” [Holt et all 1991].

[Chen & Norcio 1995] apresentam uma forma de empregar de Redes Neurais Artificiais para a modelagem do aprendiz. Utilizando estereótipos, procura implementar mecanismos de reconhecimento de padrões. Os conhecimentos ou afirmações são representadas pelas unidades da Rede. As afirmações levam em consideração a sua relevância em relação a outras em um conjunto que é valorado como negativo ou positivo. Utilizando “Bidirection Linear Associator” e “BackPropagation Network”, obteve-se bons resultados na classificação dos conhecimentos do aprendiz. O modelo proposto por Chen e Norcio (1995), apresenta as seguintes limitações:

- Existe inconsistência entre as informações armazenadas e as novas,
- O modelo utiliza uma hierarquia de generalização pré-definida. Esta estrutura limita o sistema ao estereótipo que apenas herda informações de estereótipos descendentes.
- É um sistema baseado em regras. As regras torna a sua manutenção ineficiente e sujeita a erros.

[Vendlinski & Stevens 2000] utilizou o algoritmo de Kohonen para classificar os passos utilizados pelos aprendizes na solução de problemas. Com esta classificação, o tutor humano pode acompanhar os passos do aprendiz na solução de problemas.

Uma característica comum entre os trabalhos apresentados é a comparação entre o conhecimento do aprendiz e o conhecimento previamente definido pelo tutor.

Não há evidência de comparação entre o conhecimento do aprendiz e o grupo que participa da instrução. Esta comparação, realizada de forma empírica pelo tutor humano em salas de aula, serve como referência para o preparo das atividades de ensino e na formação de equipes de trabalho.

Pesquisadores têm procurado por métodos de agrupamento de tal forma a obter equipes produtivas ou produzir instruções personalizadas às classes de aprendizes. Estes grupos são, em outras palavras, modelos de aprendizes ou modelos de usuários. Dos vários métodos de agrupamento (aleatório, homogêneos ou heterogêneos), optamos pelo agrupamento de indivíduos que possuem características comuns.

O algoritmo de Kohonen tem obtido sucesso como classificador de objetos com atributos e valores em comum. Esta técnica não necessita da definição prévia de um estereótipo para a comparação. Os dados fornecidos pelo algoritmo em questão representam estereótipos que podem compor um modelo de aprendiz ou definir equipes de trabalho.

Não há registro do emprego deste algoritmo para a confecção de modelos de aprendiz ou para classificação de aprendizes. A próxima seção apresenta um experimento que emprega este algoritmo em classes de estudantes.

3. Metodologia

Para obtenção dos dados a serem utilizados na rede neural, foi elaborado um questionário conforme parcialmente ilustrado na Figura 1. Este questionário é composto por 57 questões do tipo sim ou não.

Procedimento.

Marque com um "X" nas colunas **Sim** ou **Não** de acordo com os conceitos e perícias que você conhece ou já sabe executar no ambiente Windows e em seus respectivos aplicativos Microsoft Word e Excel.

Conceito e perícia	Sim	Não
1. Configuração do ambiente (área de trabalho do ambiente Windows).		
a. Alterar Data e hora,		
b. Alterar plano de fundo da tela,		
c. Mudar proteção de tela,		
d. Alterar as propriedades de vídeo,		
e. Alterar as propriedades de teclado,		
f. Alterar as propriedades de mouse,		
g. Alterar as propriedades da barra de ferramentas,		
h. Alterar as propriedades		
2. Escrever, salvar e ler a partir do processador de texto Microsoft Wordpad,		
3. Editar, salvar e ler a partir do editor de imagens Microsoft Paint,		

Figura 1 – Questionário respondido pelos alunos na primeira semana de aula.

O conteúdo do questionário envolveu assuntos e perícias a serem trabalhadas pelo aprendiz durante o primeiro semestre do curso de tecnologia em informática na disciplina de fundamentos de software. O aluno deveria responder se conhecia ou não o tópico da questão. As questões foram cuidadosamente elaboradas de tal forma que houvessem uma independência entre as mesmas e envolvessem apenas a memória de longo prazo.

A condução deste experimento foi feita em duas fases. A primeira fase englobou apenas os dados fornecidos pelos alunos em seu questionário. Na segunda fase, inseriu-se 5 alunos hipotéticos. A função destes alunos-hipotéticos é permitir a localização de níveis de conhecimento na representação gráfica do resultado da execução do algoritmo de Kohonen.

As questões fornecidas pelos alunos foram tabeladas em forma binária, 1 ou 0 de acordo com a coluna Sim ou Não respectivamente preenchida. Os dados fornecidos pelos aprendizes foram utilizados para treinamento e execução da Rede Neural Artificial.

Os cinco "alunos-hipotéticos" inseridos nas amostras foram: 1) um aluno-especialista onde as suas repostas são sempre 1 (um); 2) um aluno novato com as repostas uniformes e igual a 0 (zero); 3) um aluno denominado de "meio" com os primeiros 50% das resposta 1 e o restante 0; 4) um aluno denominado de "meio2" com 50% das repostas alternando entre 0 e 1; 5) um aluno denominado "meio3" com as repostas variando entre duas seqüências de 1 e duas seqüências de 0. A inserção destes aprendizes hipotéticos indicou áreas na representação gráfica de acordo com o nível de especialização dos alunos.

4. Resultados Obtidos

O aplicativo classificou os aprendizes em 3 grupos tanto na primeira parte da experiência quanto na segunda parte.

O resultado da simulação ajudou a identificar a posição dos aprendizes no mapa de Kohonen, conforme ilustra a figura 2.

O número de matrícula é apresentado como marcador no gráfico da figura 2. O rótulo de um ponto no gráfico, por exemplo “2.19.014.103”, corresponde ao número de matrícula.

Para confirmar a hipótese de que a rede agrupou os alunos de acordo com seu grau de conhecimento, questionou-se o professor da disciplina a respeito dos alunos que formavam os grupos apresentados pelo algoritmo de Kohonen. A confirmação foi positiva por parte do tutor humano quanto ao desempenho de cada grupo de alunos e pela composição dos grupos. Após a confirmação por parte do tutor humano, o gráfico representativo dos grupos de aprendizes ilustrado na Figura 2 é interpretado e apresentado na Figura 3.

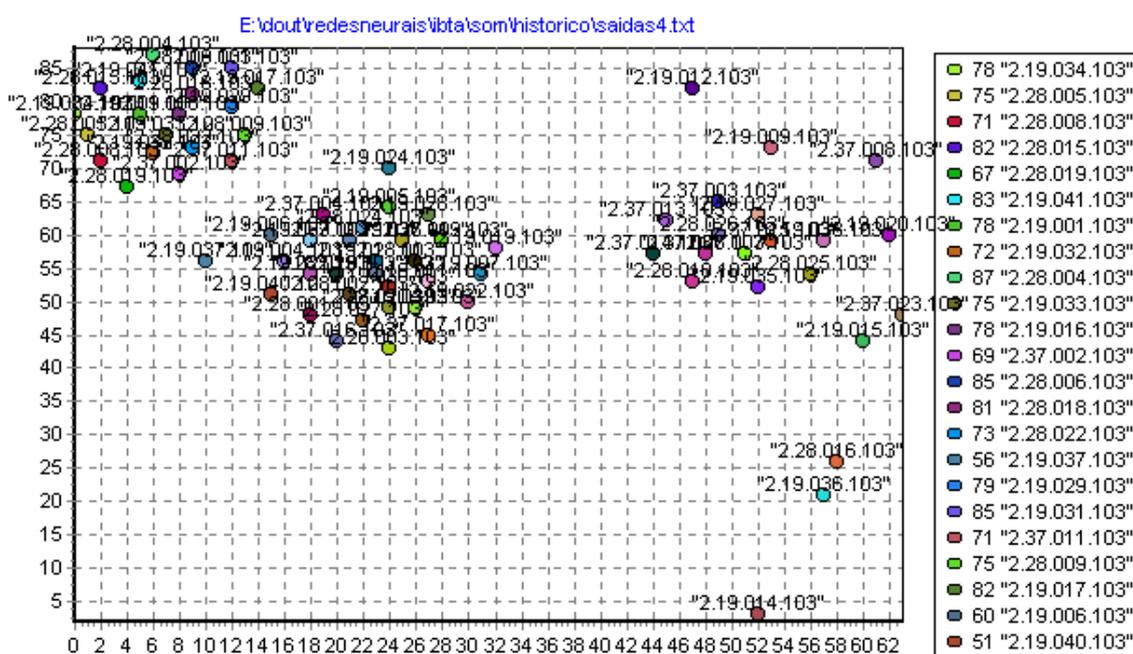


Figura 2 – Classificação dos alunos fornecida pelo algoritmo de Kohonen.

A técnica apresentou quatro áreas distintas conforme ilustra a figura 3. Estas regiões são: a) especialista, b) novato, c) estudante com conhecimento médio não similar e d) estudantes com conhecimento médio similar.

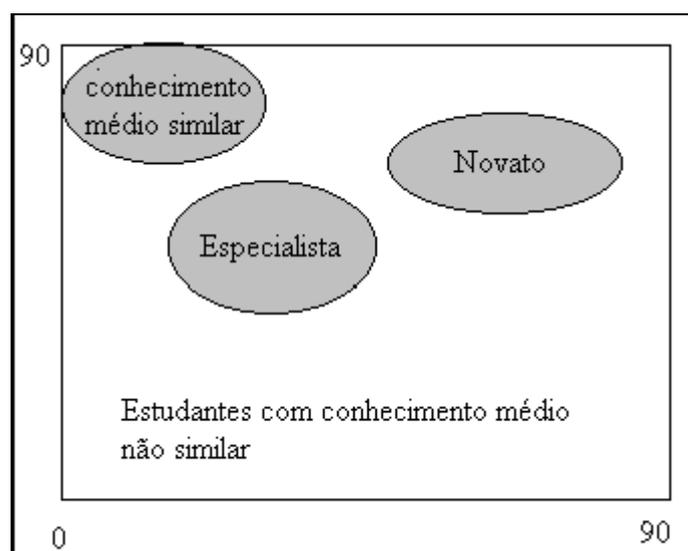


Figura 3 – Identificação das áreas de conhecimento.

Os estudantes pertencentes à região denominada Especialista são aqueles que preencheram as questões, em sua maioria, com o valor 1. Os estudantes pertencentes à região denominada Novato preencheram a maioria das questões com valor 0. Os estudantes com conhecimento médio similar apresentaram respostas similares (um ou zero) entre as questões, ou seja, características comuns entre as questões preenchidas como conhecidas e aquelas que foram preenchidas como desconhecidas. Os estudantes com conhecimento médio não similar não apresentaram similaridade alguma ou bem pouca entre as questões preenchidas.

Os grupos formados determinam modelos que podem servir de norteadores para elaboração de atividades de ensino, definição de grau de dificuldade a ser empregado na instrução ou na definição de elementos participantes em equipes de trabalho.

5. Conclusão

O resultado positivo da experiência, reforça a hipótese de que o algoritmo de Kohonen possa ser utilizado como classificador de aprendizes de acordo com conhecimentos e perícias comuns. Salienta-se ainda, a independência de domínio desta técnica. As questões elaboradas no questionário definem o domínio e seu detalhamento e não o algoritmo.

Como trabalho futuro a esta experiência apresenta-se a execução de novos ensaios. O ambiente será alimentado com as avaliações ou provas realizadas pelos aprendizes e o algoritmo classificador será empregado. Espera-se com este novo experimento, a identificação de lacunas no aprendizado e a comparação dos dados obtidos no início e no término do treinamento. Estas lacunas, quando agrupadas e identificadas após cada sessão de treinamento, possibilitará ao tutor humano a adoção de medidas corretivas individuais ou em grupos.

Apresenta-se ainda como trabalho futuro, a condução de experiências que verifiquem que os tópicos a serem apresentados em uma instrução podem ser adaptados em função dos grupos formados pelo algoritmo de Kohonen.

6. Referências

- Baffes, P. & Mooney R. (1986) “Refinement-Based Student Modeling and Automated Bug Library Construction”, *Journal of Artificial Intelligence in Education*, 7,1 (1996) pp. 75-116.
- Bussmann, S. (1991) “Prototypical Concept Formation – An alternative Approach to knowledge Representation”, Technical memo TM-91-15.
- Chen, Q. & Norcio A.F. (1995) “Pattern Recognition of User’s Domain Knowledge”, 1995 IEEE, International Conference on Systems, Man and Cybernetics, volume 2, Vancouver British Columbia, Canada.
- Direne, A. (1997) “Authoring intelligent system for teaching visual concepts”, *International Journal of Artificial Intelligence in Education*, 8, 1, pp 71-78, 1997.
- Direne, A. & Scott D. (2001) “From Novice to Expert Learner Models: Authoring adaptive user-interface behaviour to convey training needs”, *International Workshop on Information Presentation and Natural Multimodal Dialogue Verona, Italy 14-15 December 2001* .
- Holt P., Dubs, S., Jones, M. and Greer, J. (1991) “The State of Student Modelling, In: Student Modelling: The Key to Individualized Knowledge-Based Instruction”, Edited by Jimm E. Greer and Gordon I. McCalla, Springer-Verlag , pp 3 – 35.
- Kohonen, T. (1997). *Self-Organization Maps*, second edition, Spriger series in information science.
- Lendasse, A. , Lee, J. , Wertz, V. and Verleysen, M. (2000) “Time Series Forecasting using CCA and Kohonen Maps - Application to Electricity Consumption”. *ESANN'2000 proceedings - European Symposium on Artificial Neural Networks Bruges (Belgium), 26-28 April 2000, D-Facto public., ISBN 2-930307-00-5, pp. 329-334.*
- Petit, J., Zupan, J., Leherte, L. and Vercauteren, D. (2002) “Application of a Kohonen Neural Network to the Analysis of Data Regarding the Alkylolation of Toluene with Methanol Catalyzed by ZSM-5 Type Zeolites”. (2002), *Computers and Chemistry*, 6, 26, pp 557-572.
- Quinlan, J.R. (1983) “Learning Efficient Classification Procedures and Their Application to Chess Games”. In: *Machine Learning An Artificial Intelligence Approach* (R.S. Michalski, T.M. Mitchell & J. Carbonell, eds.) , pp. 463-482. Palo Alto CA: Tioga Press 1983.
- Vendlinski, T., Stevens R. (2000) “The Use of Artificial Neural Nets (ANN) to Help Evaluate Student Problem Solving Strategies”. In B. Fishman & O’Connor-Divelbiss (Eds.), *Fourth International Conference of Learning Sciences* (pp. 108-114). Mahwah, NJ: Erlbaum.