



Anais do XXXIV COBENGE. Passo Fundo: Ed. Universidade de Passo Fundo, Setembro de 2006.
ISBN 85-7515-371-4

PROTÓTIPO DE SOFTWARE PARA APRENDIZAGEM DE REDES NEURAS ARTIFICIAIS

Rejane de Barros Araújo – rdebarros_2000@yahoo.com.br

Patrícia L. S. V. Melo – patricialsvm@yahoo.com.br

Centro Universitário do Pará
Av. Governador José Malcher 1963
66060-230 – Belém - Pará
Universidade Federal do Pará
Rua Augusto Corrêa 01
66075-110 – Belém - Pará

Resumo: *Partindo do pressuposto de que o aprendizado dos conceitos referentes às Redes Neurais Artificiais não é trivial, o trabalho propõe um protótipo de software para o auxílio no processo de aprendizagem destas redes de maneira gráfica, interativa e intuitiva. O objetivo, no entanto, não é explorar de maneira exaustiva todo o embasamento teórico respectivo ao assunto, mas servir de ferramenta adicional neste processo.*

Palavras-chave: *Redes Neurais Artificiais, Modelo Backpropagation, Modelo Levenberg-Marquardt, Modelo Kohonen, Ensino de Engenharia, Interface Gráfica.*

1. INTRODUÇÃO

O presente trabalho tem o propósito de descrever o protótipo de software para ensino de Redes Neurais Artificiais. O software foi desenvolvido com o intuito de dar apoio àqueles que por ventura se interessem pelo assunto.

A proposta do desenvolvimento de um software desta natureza partiu da observação de que, a princípio, os conceitos que cercam as Redes Neurais Artificiais parecem bastante abstratos, o que dificulta o seu entendimento por parte do aluno.

Desta forma, pensou-se em construir uma ferramenta que pudesse auxiliar no processo inicial de aprendizagem das Redes Neurais, de forma que o aluno pudesse visualizar com melhor eficiência os parâmetros que tivessem influência no comportamento de uma Rede Neural. Para tanto foram utilizados os principais modelos de Redes Neurais – Backpropagation, Levenberg-Makart e Kohonen.

2. REDES NEURAIS ARTIFICIAIS

2.1 Abordagem introdutória

A Inteligência Artificial é um ramo da Engenharia e/ou Informática que consiste em um conjunto de técnicas de programação destinadas à resolução de determinados tipos de problemas, normalmente muito complexos, a partir da percepção da maneira como o homem, ou a natureza em si, o faria, partindo-se da premissa de que tudo na natureza é funcional e equilibrado [1].

Sendo assim, os programas seriam construídos de maneira a simular o comportamento humano (ou da natureza) diante de uma determinada situação.

Dentre as técnicas de Inteligência Artificial, uma das mais promissoras, uma vez que tem sido bastante divulgada e, portanto utilizada, é a Rede Neural Artificial (RNA), ou simplesmente Rede Neural.

O funcionamento das RNAs se baseia na observação do comportamento do cérebro humano ao processar informações. Segundo [2], “O cérebro é um computador (sistema de processamento de informações) altamente complexo, não-linear e paralelo. Ele tem a capacidade de organizar seus constituintes estruturais, conhecidos por neurônios, de forma a realizar certos processamentos muito mais rapidamente que o mais rápido computador digital hoje existente.”

Conseqüentemente, a estrutura de uma Rede Neural assume a forma de um processador muito semelhante àquela em que o cérebro humano encontra-se organizado, ou seja, maciçamente e paralelamente distribuído, com unidades de processamento simples, também chamadas neurônios, cuja finalidade é armazenar e produzir conhecimento, tornando-o disponível quando necessário.

O conhecimento é, então, adquirido a partir de um processo de aprendizagem (algoritmo de aprendizagem), que extrai do ambiente, no qual a Rede neural encontra-se implementada, informações suficientes que a fazem aprender.

Este conhecimento é armazenado na rede em forma de pesos sinápticos, que são as forças de conexão entre os neurônios. Na realidade, o processo de aprendizagem consiste no ajuste dos pesos sinápticos durante o aprendizado da rede, até que uma meta previamente definida seja alcançada.

2.2 Arquiteturas de Redes Neurais

Independente do problema que se quer tratar, uma Rede Neural possui, em todas as circunstâncias, uma camada de entrada e uma camada de saída [3].

Entre a camada de entrada e a de saída, existe um número variável de camadas intermediárias, chamadas camadas escondidas ou ocultas. A arquitetura de uma Rede Neural define o número e a disposição das camadas e número de neurônios por camada.

Portanto, de acordo com os parâmetros estabelecidos a arquitetura determina também quais problemas a rede é capaz de tratar. Por conseguinte, a escolha da arquitetura da rede depende fortemente da aplicação que se quer implementar.

Os parâmetros utilizados na definição da arquitetura, podem ser utilizados igualmente para a classificação da rede segundo diferentes aspectos.

Quanto ao número de camadas, uma Rede Neural pode ser classificada como Rede de Camada Única ou Rede de Múltiplas Camadas. Em uma rede de camada única, como o próprio nome sugere, existe somente uma camada capaz de executar algum processamento, esta camada é a camada de saída, pois a camada de entrada não executa qualquer computação (Figura 1). Contrariamente, em uma rede de múltiplas camadas, podem existir uma ou mais

camadas escondidas, com capacidade de processamento, entre a camada de entrada e a de saída (Figura 2).

Quanto á topologia da rede, ou seja, o tipo de conexão existente entre os neurônios, a rede pode ser dita Acíclica (Direta) ou Cíclica (Recorrente). Uma rede é Acíclica quando a camada de entrada se projeta sobre a camada de saída, mas não vice-versa (Figura 1 e Figura 2).

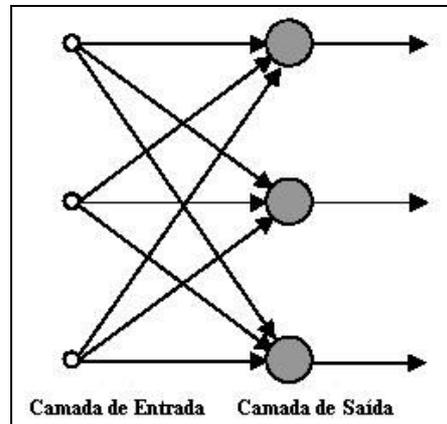


Figura 1: Rede Acíclica com uma Única Camada

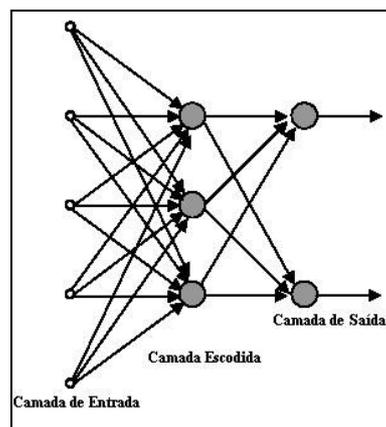


Figura 2: Rede Acíclica com Múltiplas Camadas.

Em uma rede cíclica existe pelo menos um laço de realimentação, isto é, a saída de uma camada pode tornar-se a entrada de outra (Figura 3).

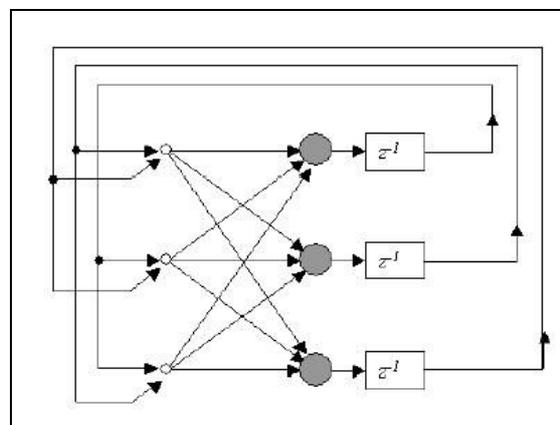


Figura 3: Rede Cíclica

Quanto à forma de aprendizado (treinamento), ou seja, a maneira através da qual ocorrerá a modificação dos pesos sinápticos, uma Rede Neural pode assumir o Aprendizado Supervisionado (Associativo), Não-Supervisionado (Auto-Organização) ou Híbrido.

No Aprendizado Supervisionado a rede aprende de acordo com um conjunto de treinamento composto de um padrão de entrada e um respectivo padrão de saída desejado. Sendo assim, faz-se necessária a presença de um instrutor, a fim de indicar explicitamente se o comportamento da rede é aceitável ou não.

Diferentemente, no Aprendizado Não-Supervisionado é inexistente a presença de qualquer instrutor e de padrões de saída, uma vez que a rede é treinada para identificar padrões relativos à entrada. O Aprendizado Híbrido combina os dois tipos de aprendizado anteriores.

2.3 Modelos de Redes Neurais Artificiais

Desde que as Redes Neurais Artificiais foram propostas, muitos modelos foram sugeridos para a implementação deste tipo de rede. Cada modelo estabelece sua própria arquitetura, atingindo problemas/aplicações específicas.

Dentre estes vários modelos até então propostos, o trabalho abordará o Modelo Backpropagation, Kohonen e Levenberg-Marquardt.

Modelo Backpropagation

Este modelo é utilizado, principalmente, para classificação de padrões, tais como em aplicações de reconhecimento de caracteres, reconhecimento de sinais em geral, treinamento de robôs e composição musical.

Também chamado de retropropagação, pois consiste em um modelo de aprendizado supervisionado de múltiplas camadas, cujo erro obtido na saída é transferido às camadas escondidas, caracterizando-se como uma rede Acíclica.

A vantagem do Modelo Backpropagation é a sua capacidade de abranger as mais variadas classificações de padrões, podendo ser utilizado em uma variedade de aplicações. No entanto, em geral o tempo de treinamento da rede é bastante extenso e alguns tipos de padrões, principalmente aqueles cuja análise e classificação dos padrões é complexa, necessitam de grande pré-processamento [4].

Modelo Levenberg-Marquardt

Este modelo caracteriza-se como um dos métodos mais rápidos para o treinamento de Redes Neurais Acíclicas de tamanho moderado, além disso é eficaz na minimização de funções com um pequeno número de parâmetros. Todavia, aumentando-se o número de parâmetros, aumenta-se também a complexidade computacional do modelo, tornando-o inviável para a maioria das aplicações.

Uma característica importante no Modelo de Levenberg-Marquardt é que o tempo de convergência da rede tende a ser menor quando comparado aos outros modelos.

Modelo Kohonen

O Modelo Kohonen é aplicado quando se deseja identificar padrões que tenham alguma semelhança entre si, como reconhecimento de voz.

Este modelo caracteriza-se como uma rede de aprendizado não-supervisionado, onde não há o reconhecimento de padrão, mas a classificação de um padrão juntamente com outros que têm características similares, formando, desta forma, classes. As classes obtidas são organizadas em uma espécie de mapa, que permite a visualização dos padrões.

Por conseguinte, a Rede Kohonen pode ser aplicada a todos os problemas onde comumente se utilizam os outros modelos de Redes Neurais, tornando-se mais eficiente naquelas aplicações em que os padrões possuem alguma relação entre si.

3. O PROTÓTIPO

O protótipo apresentado neste trabalho foi desenvolvido no MATLAB, versão 6.1, pois este programa, além de oferecer um ambiente completamente amigável, admite a utilização de ferramentas úteis ao desenvolvimento intuitivo de Redes Neurais. A Interface Gráfica do Usuário (GUI – *Graphical User Interface*) foi criada a partir da ferramenta GUIDE.

Como o intuito do protótipo é servir de instrumento de auxílio ao aprendizado das Redes Neurais, todas as interfaces do programa são bastante simples e intuitivas.

O trabalho concentrou-se somente na simulação dos três modelos de Redes Neurais descritos anteriormente: Backpropagation, Levenberg-Marquardt e Kohonen, o que permite a divisão do programa em três módulos diferentes, cada um representando um modelo, como pode ser observado na Figura 4, que mostra a tela inicial do protótipo.



Figura 4: Tela Inicial do Protótipo

O objetivo é fazer com que o aluno visualize o comportamento da rede na presença de diferentes modelos e aplicações. Desta forma, o programa oferece a possibilidade dos parâmetros da rede serem modificados aleatoriamente, permitindo o acompanhamento do desempenho da rede.

O problema da classificação da Base de Dados Íris foi utilizado para simulação nos três módulos. Para os módulos Backpropagation e Levenberg-Marquardt foi escolhida uma segunda aplicação baseada na Função Seno.

Para todos os módulos, o protótipo admite a inicialização e o treinamento da rede, no entanto, somente nos módulos referentes aos modelos Backpropagation e Levenberg-Marquardt é que o protótipo permite a validação da rede, uma vez que o modelo Kohonen não necessita de validação.

O protótipo admite o carregamento e a normalização dos dados de entrada, assim como a atribuição de valores aos parâmetros que a rede, obedecendo ao módulo empregado, trabalha.

Vale ressaltar que a taxa de aprendizagem, o erro médio quadrático e a taxa de amostragem, em cada módulo, encontram-se expressos em porcentagem. Assim, por exemplo, uma taxa de aprendizagem de 0,1 deve ser expressa com valor igual a 10.

2.5 Módulo Backpropagation

O módulo Backpropagation é iniciado a partir da tela exibida na Figura 5. Neste módulo, o aluno deve decidir por uma das duas aplicações indicadas (Base de Dados Íris ou Função Seno).



Figura 5: Tela Inicial do Módulo Backpropagation

Tendo sido escolhida a aplicação que trata a classificação da Base de Dados Íris, a tela exibida será semelhante a tela mostrada na Figura 6.

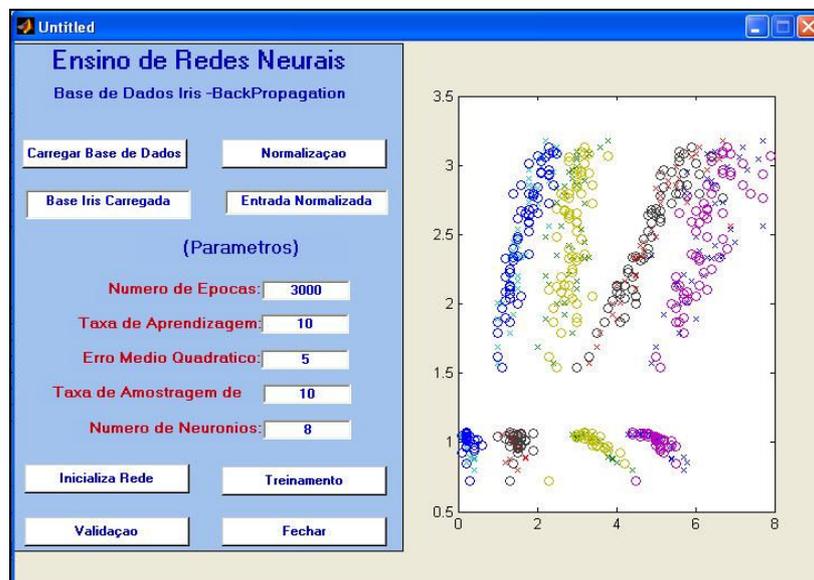


Figura 6: Classificação Íris com Modelo Backpropagation

A partir desta tela o aluno poderá atribuir aleatoriamente, ou não, os valores referentes aos parâmetros concernentes ao modelo. Da mesma forma ocorrerá se a aplicação escolhida tiver sido a Função Seno, conforme Figura 7.

Nas figuras 6 e 7 os gráficos se referem à rede já tendo sido validada e, portanto, devidamente treinada.

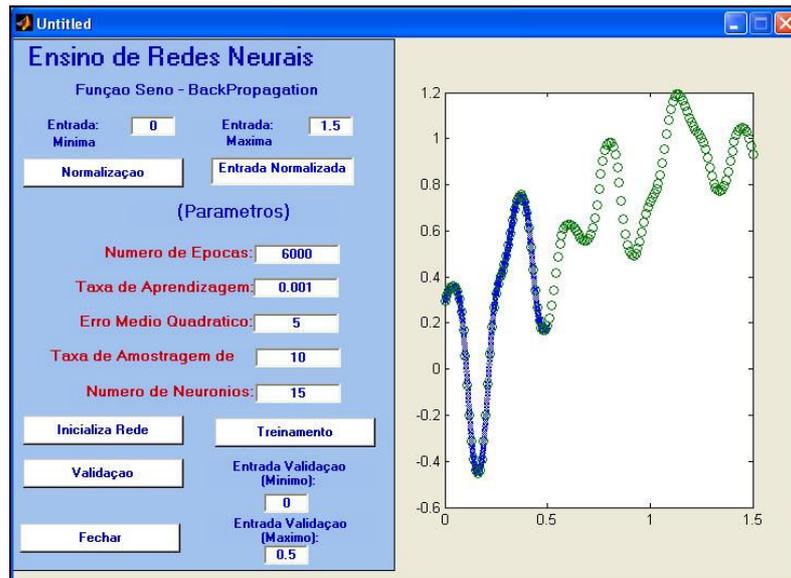


Figura 7: Representação da Função Seno com Modelo Backpropagation

3.2. Módulo Levenberg-Marquardt

A tela de início do módulo Levenberg-Marquardt encontra-se ilustrada na Figura 8. Esta tela dá acesso às mesmas aplicações do módulo Backpropagation, conseqüentemente, classificação da Base de Dados Íris e Função Seno.



Figura 8: Tela Inicial do Módulo Levenberg-Marquardt

Tendo o aluno optado pela primeira aplicação (Base de Dados Íris), a tela de atribuição dos valores dos parâmetros é igual a do Backpropagation, uma vez que as características destes dois modelos são bastante semelhantes. A Figura 9 ilustra a rede após o processo de validação de acordo com os parâmetros estabelecidos.

Da mesma forma, ocorre para o problema da Função Seno. A Figura 10 mostra o comportamento da rede após a sua inicialização.

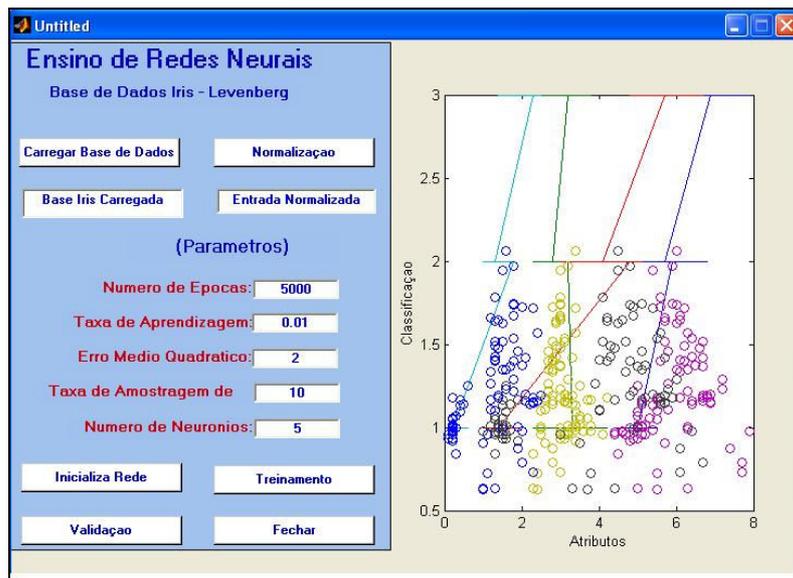


Figura 9: Classificação Iris com Modelo de Levenberg-Marquardt

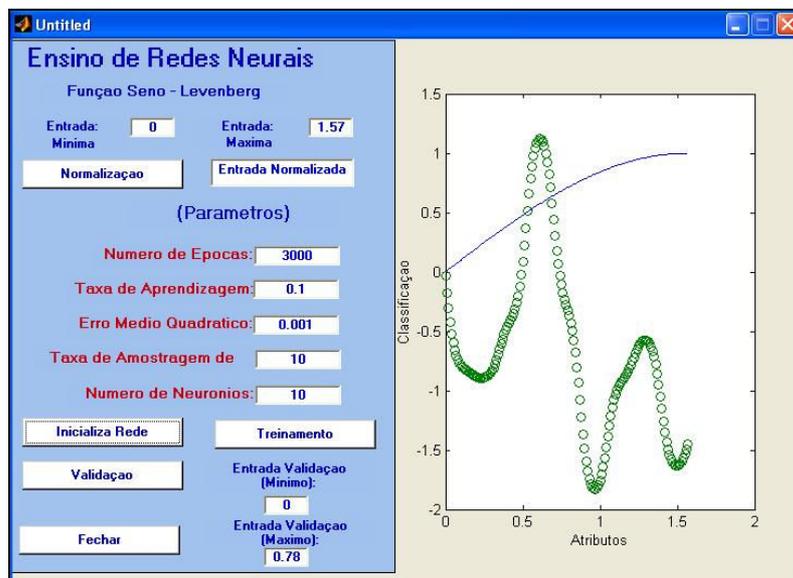


Figura 10: Função Seno com Modelo de Levenberg-Marquardt

3.3. Módulo Kohonen

No módulo Kohonen o aluno tem acesso às aplicações a partir da tela mostrada na Figura 11. O software possibilita ainda ao aluno escolher trabalhar em uma abordagem unidimensional e bidimensional, então o próximo passo que o aluno deve escolher na tela da Figura 12 é entre essas duas abordagens.



Figura 11: Tela Inicial do Módulo Kohonen

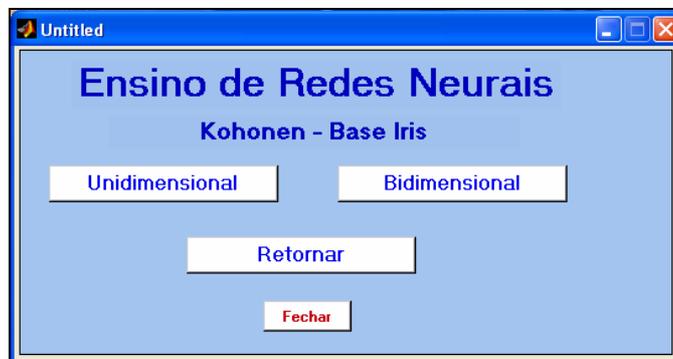
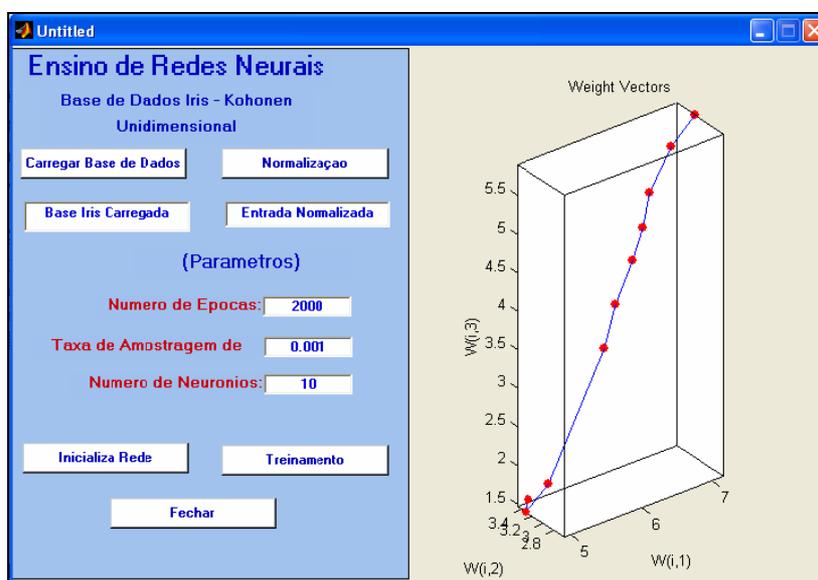


Figura 12: Tela de Escolha da Abordagem para o Módulo Kohonen

Tendo escolhida a abordagem, o aluno poderá, finalmente, atribuir valores aos parâmetros respectivos ao modelo Kohonen. Neste instante, o aluno poderá observar que o número de parâmetros necessários à construção de uma Rede Kohonen é menor do que aquele necessário ao desenvolvimento de Redes Backpropagation e Levenberg-Marquardt. A Figura 13 mostra o problema da Classificação Íris sendo tratado através de uma abordagem Kohonen unidimensional.



A Figura 13: Classificação Íris com Modelo Kohonen Unidimensional

Figura 14 ilustra a utilização de uma Rede Kohonen para o problema da Classificação Íris, no entanto, a partir de uma abordagem bidimensional.

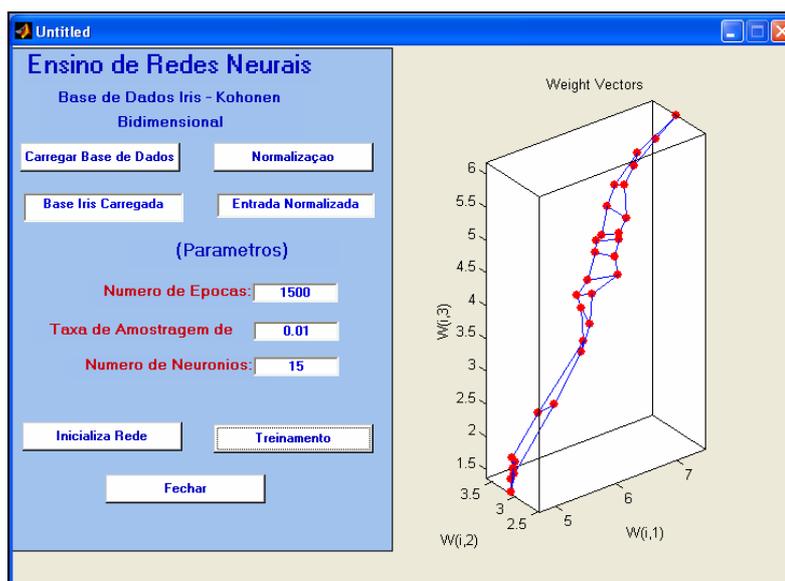


Figura 14: Classificação Íris com Modelo Kohonen Bidimensional

3. CONSIDERAÇÕES FINAIS

Uma Rede Neural Artificial é um paradigma de processamento de informações que se baseia na maneira como o sistema nervoso biológico trata as informações. Neste sentido, ao longo dos anos tem-se estudado as Redes Neurais na solução mais eficiente e eficaz de uma série de problemas difíceis, uma vez que estas redes possuem habilidade para extrair significado de dados complexos e imprecisos, por exemplo, definindo padrões e detectando tendências que seriam muito complexas de serem notadas tanto pelos seres humanos quanto através de outras técnicas de computação.

Apesar da sua importância atual no contexto da engenharia, o ensino das Redes Neurais não é trivial, pois inicialmente seus conceitos têm caráter bastante abstrato, tornando-se de difícil entendimento. Esta afirmação partiu da observação do comportamento dos alunos em sala de aula.

Desta forma, o trabalho apresentou, a primeira versão, de um protótipo de software para auxílio daqueles que almejam explorar as Redes Neurais Artificiais. Neste sentido, o software se tornaria uma ferramenta adicional, onde o aluno pudesse visualizar graficamente os conceitos teóricos previamente estudados.

Por conseguinte, o aluno poderá interagir com a rede escolhida, modificando aleatoriamente os parâmetros referentes a cada modelo estudado, observando o comportamento, e conseqüentemente, o desempenho da rede ao longo destas modificações.

Para tanto, o software foi elaborado de maneira a ilustrar aplicações diferentes implementadas sob modelos de Redes Neurais importantes, como Backpropagation, Levenberg-Marquardt e Kohonen.

REFERÊNCIAS BIBLIOGRÁFICAS

- [1] RODRIGUES FILHO, Ilson W.; TAFNER, Malcon A.; XEREZ, Marcos. **Redes neurais artificiais : introdução e princípios de neurocomputação**. Eko, 1995.
- [2] [HAYKIN, SIMON S.](#) **Redes Neurais: princípios e prática**. 2.ed. *BOOKMAN COMPANHIA*, 2000.
- [3] Cerqueira, Eduardo O. de, et. Al. **Redes Neurais e suas Aplicações em Calibração Multivariada**. Disponível em: <<http://www.s bq.org.br/publicacoes/quimicanova/qno1/2001/vol24n6/24.pdf>>. Acesso em: 27 jun. 2005.
- [4] CARDON, André; Muller, Daniel Nehme. **Introdução às Redes Neurais Artificiais**. Disponível em: <<http://www.ulbra.tche.br/~danielnm/ia/rna/rna.html>> Acesso em: 28 jun 2005.

PROTOTYPE OF SOFTWARE FOR LEARNING OF ARTIFICIAL NEURAL NETWORKS

Abstract: *Leaving of the presupposition that the learning of the referring concepts to the Artificial Neural Networks is not trivial, the work proposes a prototype of software for the aid in the process of learning of these network of graphic form, interactive and intuitive. The objective, however, it is not to explore in an exhausting form the whole respective theoretical content to the subject, but to serve as additional tool in this process.*

Key-words: *Artificial Neural Networks, Model Backpropagation, Model Levenberg-Marquardt, Model Kohonen, Engineering Teaching, Graphic Interface.*