

Redes Neurais Artificiais para a Classificação de Dados

Artificial Neural Networks for the Data Classification

RESUMO

Theodor Wulff Poloni
theodorwpoloni@hotmail.com
Universidade Tecnológica Federal
do Paraná, Ponta Grossa, Paraná,
Brasil

Hugo Valadares Siqueira
hugovaladares@gmail.com
Universidade Tecnológica Federal
do Paraná, Ponta Grossa, Paraná,
Brasil

Este trabalho teve como objetivo estudar e implementar uma Rede Neural Artificial (RNA) do tipo Perceptron de Múltiplas Camadas (MLP, do inglês *Multilayer Perceptron*) utilizando duas camadas ocultas, com o propósito de realizar classificação de dados. Foram utilizados dois bancos de dados e foi possível constatar que a RNA conseguiu obter bons resultados, ou seja, a saída da rede sendo igual ao resultado real, com uma taxa de acertos acima de 90%. Também foi possível analisar qual foi o melhor conjunto de dados e quantos neurônios cada camada oculta precisou ter no mínimo, para que a rede apresentasse este desempenho elevado.

PALAVRAS-CHAVE: Redes Neurais. MLP. Reconhecimento de Padrão. Grupos.

Recebido: 19 ago. 2019.

Aprovado: 01 out. 2019.

Direito autoral: Este trabalho está licenciado sob os termos da Licença Creative Commons-Atribuição 4.0 Internacional.



ABSTRACT

This work had the objective of studying and implementing an Artificial Neural Network (ANN) of the Multilayer Perceptron (MLP) type, utilizing two hidden layers, with the purpose of classify the databases. Two databases were used, and it was possible to determine that the ANN presented good classification results, that being the network output matching the real result, with a success rate above 90%. It was also possible to analyse which database was the best and how many neurons each layer needed to have at minimum, so that the network could show this high performance.

KEYWORDS: Neural Networks. MLP. Patterns. Groups.

INTRODUÇÃO

Com a ascensão cada vez maior da influência tecnológica sobre a vida dos seres humanos, tem feito parte do nosso dia-a-dia como estudantes e pesquisadores encontrar formas mais eficientes de executar tarefas de diferentes tipos. Este trabalho contém a descrição e detalhamento da construção de uma Rede Neural Artificial (RNA), cuja função é classificar conjuntos de dados em grupos bem definidos.

As Redes Neurais Artificiais são modelos computacionais cujo funcionamento é idealizado com base no sistema nervoso dos organismos superiores (Haykin, 1999). Este recebe sinais sinápticos de entrada no formato de dados, processa-os e então oferece uma resposta de saída vinculada a esta etapa (Haykin, 1999. Da Silva et al., 2010. Nieminen, 2010).


É com base neste conceito que foi elaborada a seguinte proposta de trabalho: a elaboração e aplicação de RNAs no reconhecimento de padrões de dois bancos de dados e, então, utilizar tais padrões para classificação de grupos específicos. O objetivo é que as RNAs possam auxiliar na identificação e organização rápida e precisa de dados, com um baixo custo computacional (Minsky et al., 1969. Siqueira et al., 2014).

PERCEPTRON DE MÚLTIPLAS CAMADAS

As redes *Perceptron* de Múltiplas Camadas são construídas por conjuntos de neurônios artificiais cuja arquitetura os distribui por várias camadas intermediárias ou ocultas. Nesta estrutura, os sinais que a rede recebe através da camada de entrada são propagados através das camadas ocultas, e os resultados processados são entregues para a camada de saída e apenas nessa direção (Nieminen, 2010). Esta forma de fluxo de dados, sem retroalimentação de informação, se chama *feedforward*.

As MLPs operam utilizando conexões entre as camadas de entrada, ocultas e saída que são feitas através de pesos inicialmente aleatórios. Estes pesos ponderam os dados e seu ajuste está diretamente relacionado com a eficiência ou precisão da MLP. É importante ressaltar que, embora eles façam conexões entre camadas, não há conexão entre os neurônios pertencentes a uma mesma camada, como mostra a Figura 1 abaixo.

Figura 1 – Arquitetura de uma MLP

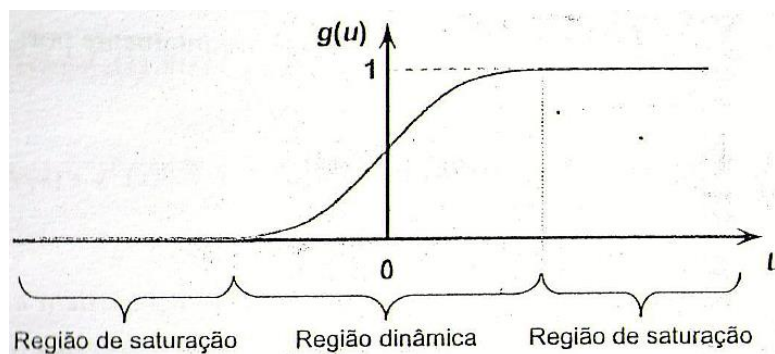


Fonte: Da Silva et al., 2010.

As MLPs possuem como formas de uso comum aproximações universais de funções, reconhecimento de padrões, identificação e controle de processos, previsão de séries temporais e otimização de sistemas (Da Silva et al., 2010. Nieminen, 2010). Foram selecionadas duas camadas ocultas para esta rede, visto que que isso faz com que ela possa aproximar funções de quaisquer tipos ou formas (Da Silva et al., 2010). Os dados em três conjuntos para uso em diferentes partes da rede: treinamento, validação cruzada e teste (Haykin, 1999). O treinamento usa a maioria dos dados, aproximadamente 70% deles (Da Silva et al., 2010).

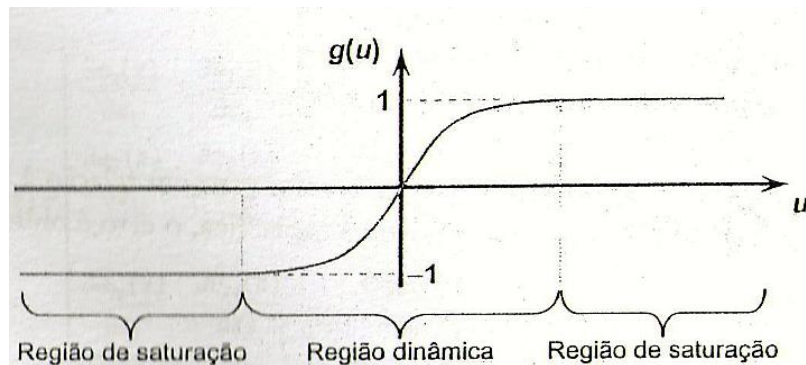
A rede é iniciada com pesos aleatórios e uma função de ativação, sendo as mais comuns sendo a Logística (Figura 2) e Tangente Hiperbólica (Figura 3).

Figura 2 – Função Logística



Fonte: Da Silva et al., 2010.

Figura 3 – Função Tangente Hiperbólica



Fonte: Da Silva et al., 2010.

É importante dizer que estas funções devem ser diferenciáveis para implementar a otimização dos pesos utilizando o erro quadrático médio (EQM) entre a saída esperada e o valor real. O algoritmo mais utilizado é o do gradiente ótimo, com a derivada da função custo sendo calculada pelo método da propagação reversa (*backpropagation*) (Da Silva et al., 2010). O treinamento é feito até que a rede ultrapasse um número definido de interações ou tenha um EQM baixo o suficiente.

Na validação cruzada, com aproximadamente 15% dos dados, impede-se que a rede treine demais e acabe muito ajustada as entradas de treinamento. No teste, os 15% finais dos dados são passados pela rede com os pesos tidos como ótimos e obtém-se a taxa de acertos.

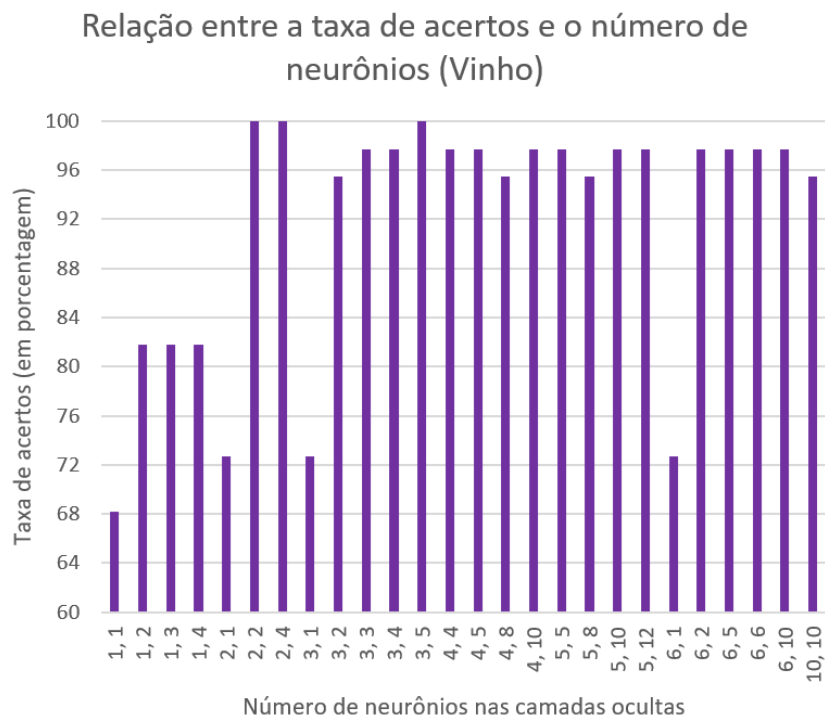
RESULTADOS E DISCUSSÕES

A MLP teve seu código desenvolvido em MATLAB usando cálculo matricial. Foram utilizadas duas bases de dados na MLP: a primeira das flores da classe *Iris* (Fisher, 1936), em que os dados são compostos por largura e comprimento das sépalas, e largura e comprimento das pétalas, e informam qual a classe da flor. A segunda base é sobre análises químicas de vinhos em três cultivos (Forina), como quantidade alcoólica, magnésio, flavonoides, intensidade de cor, etc, além de dizer a qual cultivo o vinho pertence.

Do banco de dados *Iris*, foram selecionadas aproximadamente 70% das 150 amostras para treinar a rede, e as outras 30% foram destinadas às outras partes de operação. Para o banco de dados de vinhos, de 178 amostras, foram separadas aproximadamente 75% para a parte de treinamento, destinando as outras 25% para validação e teste.

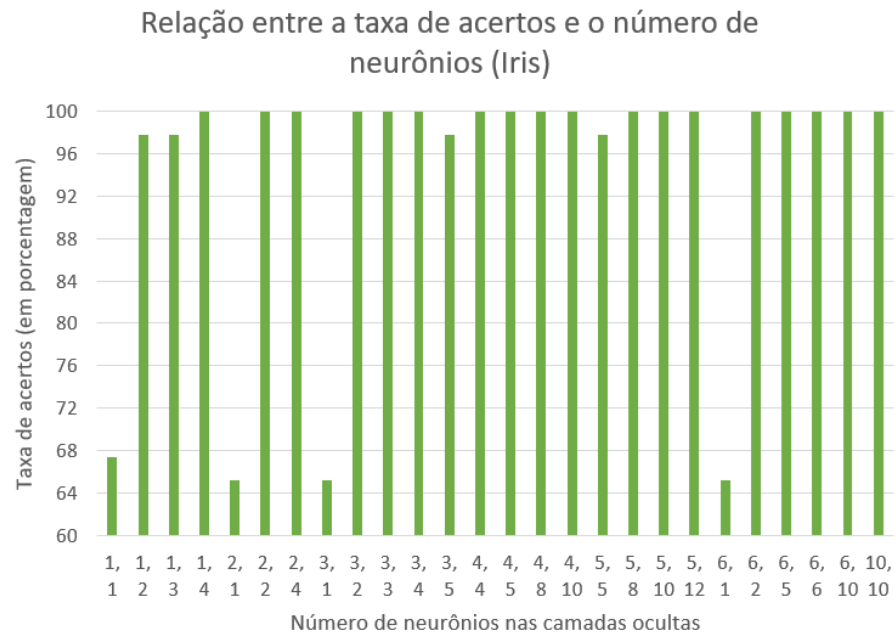
Para cada número de neurônios nas camadas ocultas, a rede foi executada 30 vezes e a taxa de acertos mais frequentes em cada operação de teste foi salva como dado para criar um gráfico. As Figuras 4 e 5 mostram os resultados obtidos, relacionando a taxa de acertos com o número de neurônios nas camadas ocultas da rede, para cada banco de dados.

Figura 4 – Desempenho da rede com o banco de dados dos vinhos



Fonte: Autoria própria utilizando o software Microsoft Excel

Figura 5 – Desempenho da rede com o banco de dados dos vinhos



Fonte: Autoria própria utilizando o software Microsoft Excel

É possível observar que a MLP está operando bem e conseguindo ter bons desempenhos de classificação para ambos os bancos de dados. Também se nota que por melhores que sejam as construções dos bancos, um neurônio em qualquer uma das camadas é insuficiente para que a rede consiga operar com boa precisão. Basta, no entanto, que haja mais de um neurônio nas camadas para o desempenho aumentar.

Por fim, pode-se ver que um número elevado de neurônios não implica necessariamente em um aumento de acertos, afinal, existiram casos em que houve 100% de acertos com baixo número de neurônios e casos onde os acertos foram menores, mesmo com um maior número de neurônios.

CONCLUSÃO

O objetivo deste trabalho foi aplicar uma Rede Neural Artificial (RNA) do tipo *Perceptron* de Múltiplas Camadas (MLP) desenvolvida em laboratório para a identificação de padrões, com o objetivo de realizar classificação de dados em categorias diferentes e definidas.

Para demonstração da precisão da rede foram utilizados dois bancos de dados diferentes, obtidos via internet graças a um depósito aberto de dados para fins de *machine learning*. Os resultados da rede mostram que ela é capaz de executar sua

tarefa e atingir bons índices de acerto, o que significa que a classificação de padrões está sendo feita com boa qualidade.

Para o futuro, planeja-se aprimorar esta rede e aplicar à ela diferentes e mais complexos conjuntos de dados, além de aprofundar o aprendizado com o desenvolvimento e utilização de outros tipos de RNAs.

AGRADECIMENTOS

Agradecemos ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pelo suporte financeiro, processo número 405580/2018-5.

REFERÊNCIAS

BRAGA, A. P.; CARVALHO, A. C. P. L. F.; LUDEMIR, T. B. Redes neurais artificiais: teoria e aplicações. Rio de Janeiro: LTC, 2000. Acesso em: 05 jul. 2019.

DA SILVA, I.N., SPATTI D., E FLAUZINO, R. (2010). Redes neurais artificiais para engenharia e ciências aplicadas: curso prático, Artliber Editora Ltda, São Paulo, SP, Brasil. Acesso em: 05 jul. 2019.

FISHER, R.A. (1936). *The use of multiple measurements in taxonomic problems*, Annual Eugenics, Part II, 179-188. Obtido em: *Iris Data Set*, UCI Machine Learning Repository [<http://archive.ics.uci.edu/ml>]. Acesso em: 05 jul. 2019.

FORINA, M. *An Extendible Package for Data Exploration, Classification and Correlation*. Institute of Pharmaceutical and Food Analysis and Technologies, Via Brigata Salerno, Genoa, Italy. Obtido em: *Wine Data Set*, UCI Machine Learning Repository [<http://archive.ics.uci.edu/ml>]. Acesso em: 05 jul. 2019.

HAYKIN, S. (1999); *Neural networks: a comprehensive foundation*. Prentice Hall, 2nd edition, Upper Saddle River, New Jersey, USA. Acesso em: 05 jul. 2019.

MINSKY, M. L.; PAPPERT, S. *Perceptron: an introduction to computational geometry*. Cambridge: MIT Press, 1969. Acesso em: 05 jul. 2019.

NIEMINEN, P. (2010). *Classification and Multilayer Perceptron Neural Networks*, Department of mathematical Information Technology, University of Jyväskylä, Finland. Acesso em: 05 jul. 2019.

SIQUEIRA, H. V., BOCCATO, L., ATTUX, R., LYRA, C., *Unorgnized Machines for Seasonal streamflow series forecasting*, International Journal of Neural Systems, v. 24, p. 1430009-1430016, 2014. Acesso em: 05 jul. 2019.