

RECONHECIMENTO DE LETRAS E NÚMEROS USANDO REDES NEURAIS ARTIFICIAIS

Luiz H. A. dos Santos, Elton M. Junior, André A. P. Biscaro
Universidade do Estado de Mato Grosso, luizhenriquetec-eng@hotmail.com,
junior_mazette@hotmail.com, aapbiscaro@unemat-net.br

Introdução

As Redes Neurais Artificiais (RNAs) são modelos computacionais inspirados no sistema nervoso central de um ser humano, em particular o cérebro, capazes de realizar o aprendizado de máquina, bem como o reconhecimento de padrões [1]. As RNAs surgiram por volta das décadas de 50 e 60 e uma das primeiras informações mencionadas sobre a neuro computação foi desenvolvida pelos cientistas McCulloch e Pitts. O estudo desenvolvido foi publicado em 1943 e, a partir desse momento, começaram a surgir máquinas baseadas e inspiradas no funcionamento do cérebro humano [2]. As RNAs possuem características importantes, sendo que os neurônios de uma rede estão conectados entre si e dispostos em camadas. A disposição dos neurônios nas camadas e o padrão de conexão entre estas definem a arquitetura da RNA. As redes sem realimentação (feedforward) têm neurônios agrupados em camadas. O sinal percorre a rede em uma única direção, da entrada para a saída. Os neurônios da mesma camada não são conectados. Já nas redes com realimentação, a saída de alguns neurônios alimenta neurônios da mesma camada, inclusive o próprio, ou de camadas anteriores [3]. Além das redes possuírem arquiteturas diferenciadas, elas passam por padrões de treinamentos e/ou aprendizado. Existem três tipos de treinamento, sendo eles: (1) treinamento supervisionado, no qual é apresentado um conjunto de treinamento, consistindo de entradas e correspondentes saídas desejadas; (2) treinamento por reforço, no qual para cada entrada apresentada, é produzida uma indicação (reforço) sobre a adequação das saídas correspondentes produzidas pela rede e (3) aprendizado não-supervisionado, no qual a rede atualiza seus pesos sem o uso de pares entrada-saídas desejadas e sem indicações sobre a adequação das saídas produzidas [4]. As redes neurais tem ganhado muito espaço em estudos e aplicações como, por exemplo: reconhecimento de imagens, estudo de falhas elétricas, controlabilidade de sistemas, entre muitas outras áreas [5]. Sendo assim, o presente estudo trata do reconhecimento de padrões aplicado à letras e números em forma de imagem. Pode-se desenvolver RNAs para solucionar diversos problemas encontrados no dia-dia [6]-[7]. Um exemplo de aplicação é o reconhecimento de placas de automóveis que, através da imagem da placa do veículo, pode-se treinar um rede para o reconhecimento das letras e números ali presentes.

Metodologia

Dependendo do que se pretende fazer, algumas estruturas de redes neurais podem funcionar melhor que outras, em função de sua topologia e treinamento, além de muitos outros parâmetros que influenciam na resposta da rede. A RNA proposta neste trabalho está voltada para reconhecimento de caracteres, ou reconhecimento de padrões, onde definimos alguns padrões ou caracteres que desejamos obter e, à medida que sua entrada é alterada espera-se uma saída conforme os padrões desejados. Tem-se uma letra em forma de imagem e espera-se que a rede reconheça essa letra conforme ela é lida. Nesse projeto foi construído em forma matricial (3x3) nove letras e um número como primeiro momento para as entradas e saídas, sendo elas: T, L, U, I, Y, C, O, H, X, 4. O objetivo é montar uma rede neural com esses

caracteres e treiná-la para ter a saída igual à entrada e depois aplicar erros nesses caracteres, a fim de que a rede neural consiga identificar esses caracteres com erros corretamente.

Para a construção da RNA foi utilizado o software Matlab. A princípio foram construídas várias redes neurais com diversos tipos de treinamento, com a variação do número de neurônios, da função de ativação e de outros parâmetros. A rede neural utilizada foi a Perceptron Multicamadas, cujo algoritmo de treinamento é o *backpropagation*, no qual os sinais de amostra de treinamento são inseridos nas estradas e são propagadas, camada-a-camada, até produzir as respectivas saídas desejadas. Utilizou-se um aprendizado supervisionado. O passo inicial foi definir os *Inputs* (entradas) e os *Targets* (saídas desejadas), que estão na forma matricial dos valores 1 e 0, formando as imagens desejadas ou caracteres. As cores de preto são o valor 1 e os brancos representam o valor 0. Uma rede feed-forward de duas camadas, com neurônios ocultos e de funções de ativação sigmóides (*patternnet*), pode classificar vetores arbitrariamente bem, tendo em conta os neurônios suficientes em sua camada oculta. A rede foi treinada com *backpropagation* de gradiente conjugado escalado (*traincg*). Com nove neurônios na camada de entrada e quatro neurônios na camada de saída, com o treinamento *trainlm* (*LevenbergMarquardt backpropagation*) e com sua performance MSE (mean squared error) a sua função de ativação que deve ser contínua e diferenciável. Nessa rede foi utilizado a *tansig* (tangente hiperbólica). As matrizes 3x3 se tornaram matrizes linhas 9x1 para as entradas do sistema, cada matriz compõe uma linha formando um total de dez padrões (dez imagens), e para a saída foi utilizada uma matriz 1x4 para cada uma das nove letras e um número codificados de forma binária. Cada linha representará uma imagem das letras, totalizando dez imagens.

Resultados e discussão

Foram feitos diversos treinamentos de redes com a mudança de estilo de treinamento, mudando a função de ativação e outros parâmetros. A princípio a rede foi treinada com as entradas corretas, mais aumentou-se o número de amostras colocando-se não dez, mas sim 40 amostras de treinamento, para a rede realizar uma amostragem mais completa e sair com melhores resultados. As saídas foram dispostas numa matriz de 10x4 elementos, para ver quanto ela consegue se aproximar da saída desejada. Os resultados foram bons, sendo que se conseguiu treinar a rede 100%, conforme esperado. Após o treinamento da rede foram mudadas as entradas da rede, inserindo-se erros nas letras e números apresentados a ela e, simulou-se a rede com esses erros para ver se ela conseguia chegar à saída desejada ou, pelo menos, próximos do desejado. A rede foi treinada com parâmetros corretos e foram feitos quatro testes com entradas diferentes e defeituosas. No terceiro teste foi aplicada uma entrada com quarenta imagens todas defeituosas, e foram aplicadas na rede neural para verificar sua eficiência e se ela conseguia acertar todas as imagens ou se as confundia com alguma outra imagem. A rede neural simulada com as quarenta imagens de entrada obteve um acerto de 27 imagens das 40, equivalente a 67,5% de acerto para os 10 tipos de imagens treinadas.

Conclusões

Observa-se que as redes neurais tem sido amplamente utilizada em muitas áreas. No reconhecimento de padrões ou imagens, por exemplo, observou-se que a rede projetada teve uma eficiência em torno de 67,5%, mas é possível melhorar e muito o desempenho desta rede neural aumentando a sua matriz de visualização dos elementos de entrada, colocando ela em pixels maiores e melhores. Assim, quando houverem defeitos em alguns pixels, ela não irá

confundir a imagem com outra. Também podemos treinar a rede neural para não confundir com alguma imagem errada, apresentando padrões distorcidos à rede.

Alterando os parâmetros da rede e outras funções, podemos utilizar para treiná-la e conseguir uma eficiência favorável, pois no reconhecimento de placas de veículos é utilizado essa ideia, onde são fotografadas e apresentadas às RNAs para o reconhecimento de padrões das letras e números ali presentes. As redes neurais são muito eficientes e visam trabalhar como um cérebro humano, buscando o melhor parâmetros e eficiência possível, e ajudando a melhorar todo sistema que é aplicado.

Palavras-Chave: Redes neurais artificiais, reconhecimento de padrões, treinamento, tecnologia

Fomento

Os autores agradecem à FAPEMAT pelo apoio financeiro através do auxílio ao projeto de pesquisa em andamento (processo No. FAPEMAT.227421/2015) e pela bolsa de iniciação científica (processo No. FAPEMAT.0477444/2016).

Referências

- [1] HAYKIN, S. **Neural networks: a comprehensive foundation**. New Jersey: Prentice-Hall, 1998, 842 p. Inclui índice. ISBN: 0132733501.
- [2] McCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **Bulletin of Mathematical Biophysics**, v. 5, n. 115, p. 115-133, 1943. DOI:10.1007/BF02478259.
- [3] SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes neurais artificiais: para engenharia e ciências aplicadas**. São Paulo: Artiber, 2010, 399 p.
- [4] TAFNER, M. A. As redes neurais artificiais: aprendizado e plasticidade. **Revista Cérebro e Mente**. Campinas, v. 2, n. 5, mar. 1998. Disponível em <<http://www.cerebromente.org.br/n05/tecnologia/plasticidade2.html>> Acesso em: 05 de mai. 2017.
- [5] CARDON, A.; MULLER, D. N. **Introdução às redes neurais artificiais**. Porto Alegre, nov. 1994. Disponível em: <http://www.inf.ufrgs.br/~danielnm/docs/intro_rna.pdf>. Acesso em 10 de abr. 2017.
- [6] CASTRO, L. N.; VON ZUBEN, F. J. Tópico 5: redes neurais artificiais. **Notas de aula**. IA006 DCA/FEEC/Unicamp. Campinas. Disponível em: <ftp://ftp.dca.fee.unicamp.br/pub/docs/vonzuben/ia006_03/topico5_03.pdf>. Acesso em: 17 de abr. 2017.
- [7] CARVALHO, A. P. L. F. Redes neurais artificiais. In: **LABORATÓRIO DE INTELIGÊNCIA COMPUTACIONAL – LABIC**. São Paulo: USP. Disponível em: <http://conteudo.icmc.usp.br/pessoas/andre/research/neural/> Acesso em: 02 de mai. 2017.