

Perceptron de Múltiplas Camadas com Pesos Otimizados por Enxame de Partículas

Leonardo Camilo Dantas
Fabricio Aparecido Breve

Depart. de Estatística, Matemática Aplicada e
Computação

Universidade Estadual Paulista (UNESP)
Rio Claro/SP - Brasil
leonardo_cdan@hotmail.com

Resumo—As redes neurais artificiais são utilizadas nas mais diversas áreas do conhecimento humano. Contudo, antes de sua utilização, precisam ser treinadas para que possam realizar a tarefa proposta. Há vários métodos para o seu treinamento, que consiste em ajustar os pesos sinápticos. Para treinar as redes perceptron de múltiplas camadas o algoritmo *backpropagation* é o mais conhecido, mas dependendo da estrutura da rede e do problema envolvido o algoritmo pode não apresentar os melhores resultados. Então, é interessante buscar novas técnicas de treinamento que sejam mais eficientes.

Área: Matemática e Inteligência Computacional.

I. INTRODUÇÃO

As redes neurais são aplicadas em inúmeras áreas, tais como controle de processos, robótica, classificação de dados, avaliação de crédito e muitas outras. Então, seu estudo torna-se muito importante. As redes neurais formadas por uma única camada de neurônios, conseguem resolver apenas problemas de características lineares, ou seja, de objetos distintos entre si. Por exemplo, caso tivéssemos que separar um conjunto de pedras, divididas em duas categorias, pedras lisas e rugosas. Neste, caso a rede neural de camada simples é suficiente.

Contudo, os objetos que nos cercam, em grande parte são de características não separáveis linearmente, logo a rede neural de camada simples não terá capacidade suficiente para chegar em resultados confiáveis. Ampliando o problema apresentado, agora temos pedras com ambas as características, não totalmente lisas e não totalmente rugosas, com isso a rede apresentará uma deficiência ao fazer a classificação, podendo colocar pedras de características mais lisas junto às rugosas, ou o contrário.

Assim, a solução para o problema é o aumento de camadas da rede neural. Aumentando as camadas, a rede conseguirá uma maior generalização dos objetos e conseqüentemente seu desempenho será melhor[1]. Porém, o aumento de camadas, causa uma dificuldade para ajustar os pesos sinápticos. Neste, trabalho os pesos sinápticos foram ajustados usando a técnica de enxame de partículas (*Particle Swarm Optimization – PSO*) [2]. A base de dados utilizada para os testes, foi a base *Wine* constituída de três subclasses.

II. CONCEITOS E TÉCNICAS

A arquitetura da rede neural de múltiplas camadas foi desenvolvida contendo duas camadas ocultas. A configuração proposta é suficiente para conseguir aproximar qualquer função[2], as camadas ocultas também são chamadas de extratoras de características, são nestas camadas que ocorrem a maior parte do processamento[3].

A Figura 1 ilustra a estrutura da rede proposta:

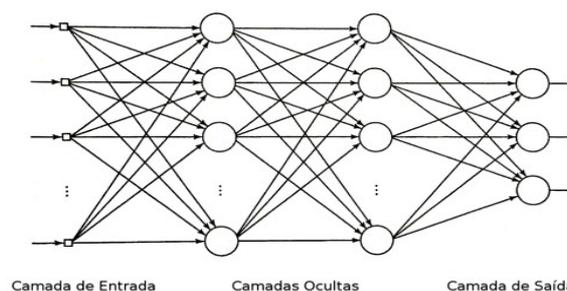


Figura 1: Arquitetura da rede neural.

A função utilizada para a ativação do neurônio é a sigmóide, segue a sua fórmula:

$$f(x) = \frac{1}{1 + \exp(-\alpha \cdot x)} \quad (1)$$

onde o valor de x é o somatório das entradas com seus respectivos pesos sinápticos e o valor de α foi fixado igual a 1.

A técnica utilizada para treinar a rede neural, foi o enxame de partículas. Cada partícula carrega todos os valores dos pesos sinápticos de todos os neurônios da rede. A ideia, desta técnica, particularmente aplicada a esta rede neural, consiste no “movimento” das partículas dentro do espaço de soluções, buscando bons valores, ou seja, boas aptidões.

Para que as partículas movimentem-se pelo espaço de soluções, estas possuem uma inércia, conhecimento da sua melhor posição e a melhor posição de sua vizinhança (cooperação). A atualização da posição é calculada somando

essas três forças vetoriais, conforme ilustra a Figura 2. No cálculo da atualização da i -ésima partícula usa-se a Fórmula (2) [2].

$$x_i(t+1) = x_i + v_i(t+1) \quad (2)$$

A velocidade da partícula é atualizada seguindo a Fórmula[2]:

$$v_i(t+1) = v_i + \beta_1(p_i - x_i) + \beta_2(p_g - x_i(t)) \quad (3)$$

onde:

v_i é a velocidade da partícula;

p_i melhor posição da partícula;

p_g melhor posição da vizinhança;

x_i posição da partícula;

t tempo;

β_1 e β_2 são valores aleatórios no intervalo]0,2].

A Figura 2, ilustra as forças vetoriais que influenciam o movimento da partícula:

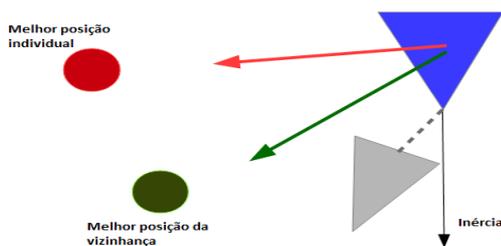


Figura 2: Forças vetoriais influenciando o movimento da partícula.

III. METODOLOGIA DE DESENVOLVIMENTO

A rede neural de múltiplas camadas, é composta por duas camadas ocultas, totalizando 4 camadas, onde cada uma contem 10 neurônios com exceção da última, composta de 3 neurônios.

Para o treinamento foi utilizado o método supervisionado, que consiste num agente externo indicando à rede a resposta desejada para o padrão de entrada[3]. Os testes foram feitos na base *Wine*, composta por 178 amostras, sendo que 59 são da classe 1, 71 da classe 2 e 48 para a classe 3. No treinamento foram utilizadas 30 amostras da classe 1, 35 da classe 2 e 24 para a classe 3, totalizando 89 amostras, escolhidas aleatoriamente e o restante foi utilizado no teste.

O algoritmo é descrito a seguir:

Tabela 1: Algoritmo

função()
inicializa limite
inicialização das partículas
inicialização das velocidades
faça
cálculo da aptidão
determinação da melhor partícula
atualização das velocidades
atualização das posições
enquanto (acertos < limite)
executar e mostrar resultado do treino
executar e mostrar resultado do teste
fim função

O critério de parada foi definido quando a aptidão de alguma partícula atingisse 88 acertos, ou seja, praticamente 100%, pois foram 89 amostras para o treinamento.

Iç. RESULTADOS PRELIMINARES

A Tabela 2, mostra a matriz de confusão obtida no treinamento da base *Wine*:

Tabela 2: Matriz confusão do teste

	Classe 1	Classe 2	Classe 3
Classe 1	89,65%	10,35%	0,00%
Classe 2	2,77%	94,44%	2,77%
Classe 3	0,00%	4,16%	95,83%

O resultado mostra que a classe 2 provavelmente não é linearmente separável em relação as outras duas classes, pois há erros. Por outro lado, as classes 2 e 3 são linearmente separáveis. O percentual de acertos foi considerado bom.

ç. CONSIDERAÇÕES FINAIS

Através do resultado apresentado, fica evidente que os ajustes de pesos sinápticos das redes neurais artificiais, podem ser feitos utilizando o enxame de partículas. O próximo passo será a aplicação de Algoritmos Genéticos na otimização da estrutura da rede neural, objetivando um bom resultado com o mínimo de recursos, ou seja, procurando usar o mínimo de camadas e neurônios por camada.

REFERÊNCIAS

- [1] BRAGA, Antônio; CARVALHO, André; LUDEMIR, Teresa; Redes Neurais Artificiais: Teoria e Aplicações. 2.ed. Rio de Janeiro, LTC, 2007.
- [2] BREVE, Fabricio; Notas De Aulas: Particle Swarm Optimization, UNESP-Rio Claro(SP), 2013.
- [3] FERNANDES, Anita; Inteligência Artificial: Noções Gerais. 1.ed. Florianópolis, VisualBooks, 2008.