

REDE NEURAL ARTIFICIAL APLICADA NA ESTIMATIVA DA VELOCIDADE DE UM MOTOR DE INDUÇÃO TRIFÁSICO

GABRIEL IEPSEN WESTPHAL¹; JÔNATAS LEMUEL BISPO ZOTTIS²;
MARCELO ESPOSITO³

¹*Universidade Federal de Pelotas – gabrielwestphal8@gmail.com*

²*Universidade Federal de Pelotas – lemueltra@gmail.com*

³*Universidade Federal de Pelotas – engesposito@gmail.com*

1. INTRODUÇÃO

O desenvolvimento de sistemas com a capacidade de aprender e de se adaptar tem sido o objetivo de diversos cientistas. Com a aplicação das redes neurais artificiais (RNA) é possível desenvolver sistemas capazes de realizar a predição sobre o comportamento de um processo, classificação de padrões, controle de processos, entre outras (SANTOS, 2012).

As aplicações que envolvem as RNAs são crescentes, possibilitando uma alternativa aos métodos convencionais, a medida que o poder computacional dos microprocessadores aumenta. Várias pesquisas têm mostrado seu desempenho no tratamento das não linearidades de sistemas dinâmicos, cujo equacionamento é árduo ou com níveis significativos de particularidades devido a aproximações com sistemas lineares, como no caso da modelagem do motor de indução trifásico (MIT) (GOEDTEL, 2007).

O MIT é usado em muitos setores industriais, sendo o principal elemento de conversão da energia elétrica em energia mecânica motriz. E para aplicações que exigem o controle da velocidade, há a necessidade de se conhecer a velocidade no eixo da máquina, seja na forma de uma medida direta ou estimada (KRISHNAN, 2001).

Neste projeto aplicou-se uma RNA para a estimativa da velocidade mecânica no eixo do MIT baseada no método de algoritmos genéticos (AG), que foi utilizado no treinamento *off-line* e na otimização dos pesos sinápticos da rede. No treinamento foram utilizados como dados de entrada as tensões e as correntes elétricas medidas durante o acionamento do motor, bem como dados de saída da velocidade medida diretamente por um *encoder*.

Os AG modificam repetidamente uma população de estruturas artificiais chamadas de cromossomos, aplicando operadores genéticos inspirados nos mecanismos naturais de seleção, reprodução, cruzamento e mutação (MARCOLLA, 2005). Os AG requerem pouca informação do problema e podem otimizar funções com muitas variáveis, descontínuas ou com ruído.

2. METODOLOGIA

A estrutura básica do código para o treinamento da rede é fundamentado no método de AG e consiste inicialmente na definição de alguns parâmetros, como o número máximo de gerações ou iterações e o número de neurônios da camada oculta. No algoritmo é proposta uma população inicial formada por um conjunto aleatório de indivíduos que podem ser vistos como possíveis soluções do problema. Durante o processo evolutivo esta população é avaliada, por meio do cálculo da função objetivo de cada cromossomo e da sua probabilidade de

sobrevivência. Os principais passos do processo de treinamento baseado no método de algoritmos genéticos podem ser observados na figura 1.

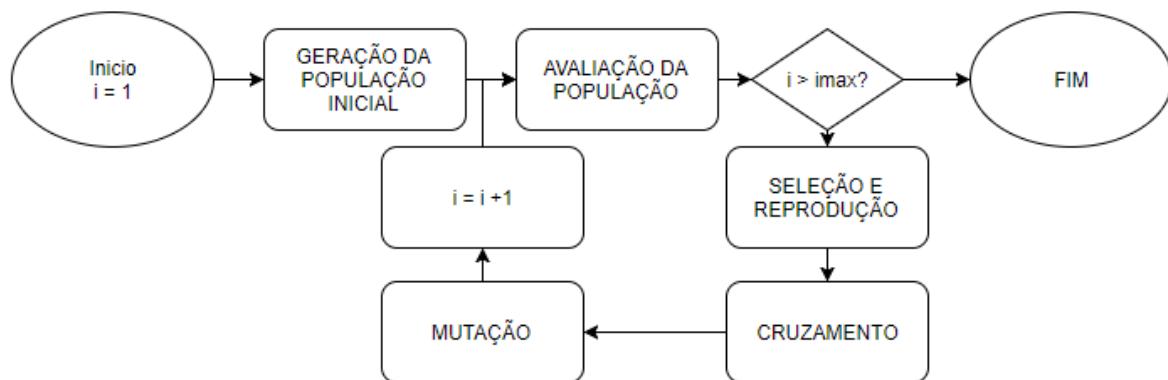


Figura 1 - Diagrama para o treinamento da RNA baseado no método de AG.

Fonte: Adaptada de MARCOLLA, 2005.

A função objetivo utilizada neste trabalho é dada pelo somatório da média dos erros ao quadrado da resposta desejada pela resposta do sistema.

```

E = Y-YPred;% Erro entre a resposta desejada e a do sistema.
EMQTemp = mean(E.^2,1);% Média do erro ao quadrado.
valorfunc = sum(EMQTemp);% Função objetivo.
  
```

A etapa da seleção é aplicada pelo método da *roleta*, onde é atribuída para cada indivíduo da população uma probabilidade de seleção proporcional ao valor da função objetivo. Os operadores de cruzamento e mutação geram a nova população, até que o número máximo de gerações seja alcançado.

Com o treinamento realizado, a função objetivo minimizada e os pesos sinápticos definidos, é executada a previsão ou estimativa da rede (Figura 2), a partir de um conjunto de dados de entrada, diferentes daqueles utilizados para o treinamento. Neste estudo, estes dados foram normalizados por meio da função de ativação tangente hiperbólica.

```

%% Calcula a saída da camada escondida
YEsc = FuncAtiv(X*w1' + repmat(b1', NumPad, 1), IndFunc);
% Entradas vezes os pesos, mais o bias
%% Calcula a saída rede
If IndCamada == 0
    YSai = YEsc; % Saída da camada escondida
else
    YSai = YEsc*w2' + repmat(b2', NumPad, 1); % Saída da rede
  
```

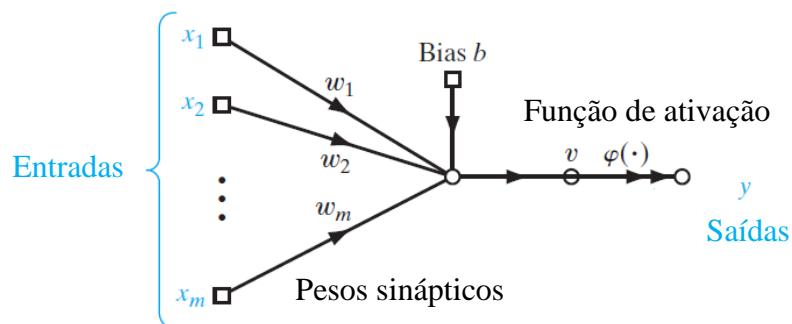


Figura 2 - Estrutura base para o projeto da rede neural na estimação das saídas.

Fonte: Adaptada de HAYKIN, 2008.

As tabelas 1 e 2 apresentam as configurações de dimensionamento e definição da RNA utilizada.

Tabela 1 - Dimensionamento da RNA.

Camada	Número de neurônios
Entrada	6 (nós de entrada)
Oculta	20
Saída	1

Tabela 2 - Definições iniciais da RNA

Método de treinamento	Algoritmos Genéticos
Número máximo de iterações	100
Função de ativação	Tangente hiperbólica

3. RESULTADOS E DISCUSSÃO

Os resultados foram obtidos a partir da simulação do algoritmo de treinamento e predição no software Matlab. A figura 3 apresenta os dados reais normalizados da velocidade no eixo do MIT utilizados para o treinamento, comparados com os dados de predição da RNA, para 100 iterações utilizando o método de AG.

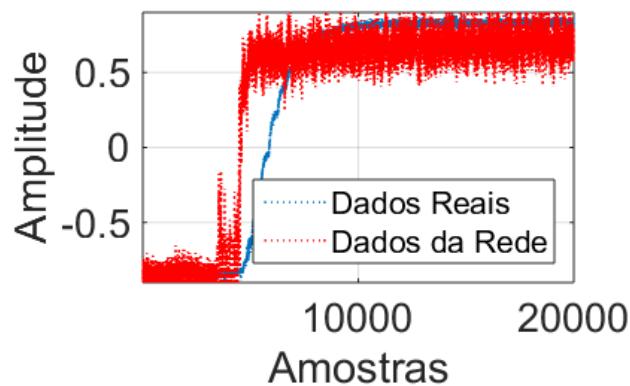


Figura 3 - Dados de treinamento comparados com a predição da rede, ambos normalizados.

Com o treinamento foi definido um conjunto de pesos sinápticos e bias para as camadas oculta e de saída, cujo erro médio quadrático do cromossomo com melhor probabilidade de sobrevivência foi minimizado até atingir 9,91%.

A partir das informações do treinamento foi utilizado um novo conjunto de dados de tensões e correntes do estator, obtidos durante o acionamento do MIT conectado diretamente na rede elétrica trifásica, para a estimativa da velocidade mecânica do rotor.

Os resultados alcançados pela RNA, na estimativa da velocidade mecânica no eixo do MIT podem ser observados na figura 4. Um coeficiente de correlação de 97,73% foi obtido entre a velocidade medida e a velocidade estimada.

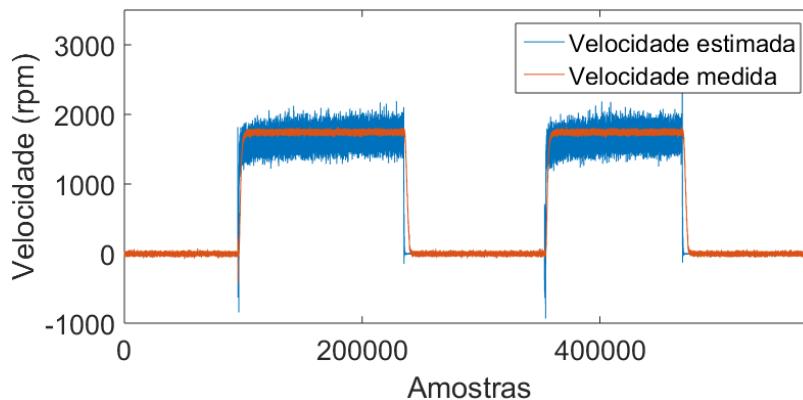


Figura 4 - Velocidade estimada pela rede neural, comparada com a velocidade medida no eixo do MIT.

4. CONCLUSÕES

O método de treinamento *off-line* baseado em algoritmos genéticos otimizou os pesos sinápticos e minimizou a função objetivo até um erro médio quadrático de 9,91%, alcançando resultados satisfatórios, com um coeficiente de correlação de 97,73% entre as variáveis estimadas e medidas, considerando um sistema não linear e de múltiplas entradas como ocorre no caso estudado do motor de indução trifásico. O uso desta técnica apresenta vantagens quando comparada a outras técnicas de estimativa como, por exemplo, observadores de estado e sistemas de referência com modelos adaptativos, que necessitam de conhecimento sobre o modelo matemático do sistema em estudo. O reduzido tempo de processamento computacional na etapa de predição da RNA poderá oportunizar a estimativa *on-line* em trabalhos futuros.

5. REFERÊNCIAS BIBLIOGRÁFICAS

GOEDTEL, A. **Estimador Neural de Velocidade Para Motores de Indução Trifásicos.** 2007. 159 p. Tese (Doutorado) – Escola de Engenharia de São Carlos, Universidade de São Paulo, 2007.

HAYKIN, S. **Neural networks and learning machines.** 3rd ed. Person, 2008.

KRISHNAN, R. **Electric Motor Drives: Modeling, Analysis and Control.** UpperSanddleRiver, NJ: Prentice-Hall, 2001

MARCOLLA, F. R. **Investigação e aplicação de técnicas de modelagem e controle de processo baseadas em redes neurais com ajuste em linha utilizando algoritmos genéticos.** 2005. Dissertação (Mestrado em Engenharia Química). Universidade Federal de Santa Catarina.

SANTOS, T. H. **Estimador Neural de Velocidade aplicado a um driver de controle escalar do motor de indução trifásico.** 2012. 117 f. Dissertação - Programa de Pós-Graduação em Engenharia Elétrica, Universidade Tecnológica Federal do Paraná. CornélioProcópio, 2012.