

# REDES NEURAIAS ARTIFICIAIS PARA A DETECÇÃO DE FALTAS NO GERADOR DE INDUÇÃO DUPLAMENTE ALIMENTADO

**Marcelo Patrício de Santana**

Universidade de São Paulo  
marceloengenheiroe@usp.br

**José Roberto Boffino de Almeida Monteiro**

Universidade de São Paulo  
jrm@sc.usp.br

**Resumo** – Este trabalho apresenta a utilização de redes neurais artificiais (RNA) para a identificação de faltas do gerador de indução duplamente alimentado (GIDA). As faltas em estudo no trabalho são os curto-circuitos fase-terra, fase-fase-terra, bifásico e trifásico. A rede neural utilizada foi a *perceptron* multicamadas e o algoritmo de treinamento o *backpropagation*. As variáveis de entrada da rede são calculadas através do modelo vetorial da máquina. O treinamento da rede, simulação do gerador e operação da RNA foram realizados no Matlab/Simulink. A simulação da falta ocorre após um período com carga equilibrada e é observado o desempenho da RNA para a identificação do tipo de falta. São apresentados alguns gráficos dos resultados da simulação do gerador e da rede, para análise do desempenho da rede neural.

**Palavras-chave** – Gerador de indução duplamente alimentado, Redes neurais artificiais, curto-circuitos, faltas.

**Abstract** – This paper presents the use of artificial neural networks (ANN) to identify faults in the doubly fed induction generator (DFIG). The faults studied in the work are the phase-to-ground, phase-to-phase-to-ground, phase-to-phase and three-phase. The neural network used the multilayer perceptron and the training algorithm the backpropagation. The input variables of the network are calculated using the vector model of the machine. Network training, simulation and operation of the generator of RNA were performed in Matlab/ Simulink. The simulation of failure occurs after a period of balanced load and it is subject to the performance of the ANN to identify the fault type. Are some graphs of the simulation results of the generator and network, to analyze the performance of the neural network.

**Keywords** – Doubly-fed induction generator, Artificial neural network , short circuit, fault.

## 1. INTRODUÇÃO

Os geradores de indução duplamente alimentados vêm sendo muito utilizado nos últimos anos em geração de energia com velocidade variável. Suas principais vantagens são: o conversor de energia é dimensionado em 30% da potência nominal da máquina e o GIDA tem facilidade do controle de potência em velocidades variáveis. Suas principais áreas de aplicação são: geradores eólicos (sendo responsáveis por aproximadamente 60% do mercado mundial), usinas termoelétricas, pequenas centrais hidrelétricas, bombas de armazenamento entre outros [1].

Devido a sua grande utilização, existem diversos estudos para monitoramento do gerador durante sua operação. Isso ajuda evitar condições indesejáveis de operação e detecta possíveis faltas, aumentando assim a sua confiabilidade, o tempo de operação do gerador e redução dos custos operacionais e de manutenção.

Por possuir controle de potências ativa e reativa e operação em velocidade variável, em países da Europa e nos Estados Unidos já existem regras para evitar a desconexão do gerador do sistema, obrigando o GIDA continuar a operação em casos de condições adversas [2, 3].

No entanto, durante as faltas o gerador possui os seguintes problemas:

- aumento da corrente do rotor, que é muito prejudicial ao conversor de potência AC/DC/AC, fazendo em alguns casos a desconexão do sistema para proteger o conversor;
- perda do controle de potência ativa e reativa do gerador, que pode causar oscilações no sistema;
- desequilíbrio das tensões e corrente do estator;
- aumento das ondulações no torque; e
- aumento das perdas e excessivo aquecimento.

Nos geradores de indução duplamente alimentado os principais tipos de faltas que ocorrem e que serão objetos de estudos do trabalho são [2, 3]:

- falta fase-terra;
- falta fase-fase-terra;
- falta bifásica; e
- falta trifásica.

Existem diversos trabalhos realizados na área para a identificação de faltas [2–6]. Em sua maioria, o treinamento da RNA considera somente os valores RMS (eficazes) de tensão e corrente para o treinamento da rede. Quando a identificação de falta for de um GIDA, velocidade variável, uma RNA treinada somente com esses valores pode possuir erros na identificação do tipo de falta. Isso pode ocorrer quando a RNA identifica a classificação da falta pela diferença dos valores das correntes ou tensão nas 3 fases. Sendo um problema quando as faltas são simétricas, como no curto-circuito trifásico, confundindo a rede com a operação normal do sistema.

As redes neurais artificiais foram escolhidas nesse problema de identificação de faltas pelos seguintes motivos [4, 9]:

- excelente desempenho em classificações de padrões, já que o problema do trabalho é a identificação do tipo de falta;
- precisão na determinação de padrões não lineares; e
- rápida velocidade de operação da RNA, com o único cálculo uma multiplicação de matriz. Exigência do problema do trabalho onde a velocidade de determinação do tipo de falta tem que ser rápida.

Nesse contexto, o trabalho realiza a identificação dos principais tipos de faltas no GIDA utilizando a rede *perceptron* multicamadas com o algoritmo de treinamento *backpropagation*. As entradas da rede são grandezas calculadas no modelo vetorial do GIDA.

## 2. ABORDAGEM PROPOSTA

Em muitos casos de faltas e variações de tensão na rede elétrica, a proteção do sistema desconecta o GIDA e somente o reconecta depois do fim do problema. A conexão e desconexão do gerador de energia elétrica causam transientes de tensão e frequência. O problema é maior quando se trata de vários geradores, como por exemplo, em uma usina eólica. Esse é o motivo de na Europa e nos EUA já existirem leis que limitam a desconexão do GIDA e exigem sua operação em algumas faltas e variações de tensão [2].

Existem muitas pesquisas na área para solucionar o problema de identificação de faltas e controle do GIDA para manter a máquina operando em condições adversas. O problema de realizar o controle deste gerador é que toda a modelagem matemática vetorial considera uma aproximação linear do gerador, que considera as cargas equilibradas para utilização da transformada de Park e Clark [4, 7]. Em faltas ocorre um desequilíbrio entre as cargas e o modelo matemático do gerador se torna não linear e de difícil previsão do comportamento. Por esse motivo, para manter a máquina operando, é necessário um sistema de identificação de faltas para alterar o controle do GIDA, considerando assim essa não linearidade do novo sistema.

Para solucionar o problema da identificação de faltas foram realizados os seguintes sete passos:

- modelo vetorial do GIDA;
- redes neurais artificiais;
- determinação das variáveis de entrada;
- variáveis de saída;
- simulação no Matlab/Simulink;
- construção da base de dados; e
- treinamento da rede.

Os sete passos serão descritos detalhadamente em subtópicos.

### 2.1 Modelo vetorial da MIDA

A modelagem vetorial de máquinas serve para transformar um sistema trifásico em um bifásico, sem alterar suas características de torque, velocidade e potência. Esse modelo resulta em simplificações de cálculos e facilidades no controle da máquina, fazendo com que seu controle seja similar ao de um motor CC [7].

Nesse modelo as grandezas trifásicas da máquina são convertidas em um sistema ortogonal  $(\alpha\beta)$ , onde todas as grandezas são representadas nele. Esse novo referencial é composto de uma parte real e outra imaginária [7].

O GIDA é representado pelas seguintes equações matriciais, que representam o seu comportamento dinâmico em um único referencial [8].

$$\vec{u}_E = R_E \vec{i}_E + \frac{d}{dt} \vec{\Psi}_E + j\omega_\lambda \vec{\Psi}_E \quad (1)$$

$$\vec{u}_R = R_R \vec{i}_R + \frac{d}{dt} \vec{\Psi}_R + j(\omega_\lambda - P\omega_{mec}) \vec{\Psi}_R \quad (2)$$

Sendo que:

- $u_E$  e  $u_R$ : tensão no estator e rotor, respectivamente;
- $i_E$  e  $i_R$ : corrente no estator e rotor;
- $\Psi_E$  e  $\Psi_R$ : fluxo no estator e rotor;
- P: quantidade de pólos da máquina;
- $\omega_{mec}$ : velocidade mecânica do gerador; e
- $\omega_\lambda$ : velocidade do referencial genérico escolhido.

Para representar os fluxos, que serão utilizados no treinamento da rede neste trabalho, será utilizada a corrente de magnetização do rotor e a do estator. Essa grandeza é responsável diretamente pela produção dos seus respectivos fluxos e seu equacionamento matemático é apresentado em 3 e 4 [8]:

$$im_R = i_{dr} \times \sigma + i_{de} \quad (3)$$

$$im_E = \sigma 2 \times i_{de} + i_{dr} \quad (4)$$

Os valores de corrente estão escritos em componentes  $d$  e  $q$ , que são os valores no referencial escolhido. A corrente de magnetização do estator estará no eixo do fluxo do estator e a corrente de magnetização do rotor no eixo do fluxo do rotor.

## 2.2 Redes neurais artificiais

A rede neural escolhida no trabalho foi a rede *perceptron* multicamadas com o algoritmo de treinamento *backpropagation*. Isso porque ela tem uma estrutura simples e o algoritmo de treinamento tem obtido bom desempenho em classificações de padrões e em outros casos [9, 10]. No algoritmo *backpropagation* foi inserido o termo *momentum* para que a convergência seja mais rápida.

## 2.3 Determinação das variáveis de entrada

Para treinar e operar a rede neural é necessário que sejam selecionados valores de entrada e saída. As variáveis de entrada da rede neural foram estimadas pelo modelo vetorial da máquina, através das medições das tensões do estator e rotor e da corrente do estator. A velocidade da máquina foi utilizada somente no treinamento da rede, não sendo necessário seu valor na operação. As variáveis são:

- velocidade da máquina: importante por que a maioria das aplicações do GIDA é com velocidade variável;
- corrente de magnetização do estator: representa o fluxo no estator
- corrente de magnetização do rotor: representa o fluxo no rotor. Tanto essa como a do estator, dependendo do modelo vetorial, são importantes para o controle da máquina;
- torque eletromagnético: apresenta a maior oscilação nas faltas e é uma importante variável a ser controlada;
- corrente do estator no referencial do fluxo do estator: tem as maiores oscilações na falta, já que é conectada a carga;
- corrente do rotor no referencial do fluxo do rotor: tem que ser controlada para evitar a queima dos conversores de potência, que no GIDA são conectados no rotor; e
- tensão do rotor: no GIDA essa é a variável de controle.

## 2.4 Variáveis de saída

As variáveis de saída representam as classes que a rede tem que determinar, podendo ela ser um tipo de falta ou uma situação sem falta no GIDA. Existem sete entradas, conforme determinado anteriormente, e cinco saídas que representam quatro tipos de faltas e a situação sem falta.

A figura 1 representa as entradas e saídas da rede neural.

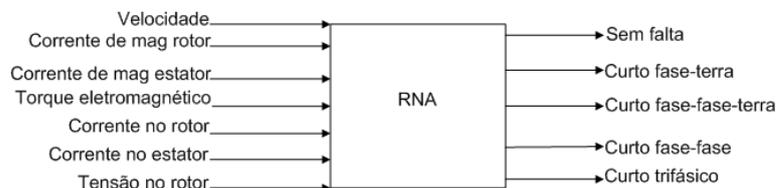


Figura 1: RNA para identificação de falta

## 2.5 Simulação no Matlab/Simulink

Com as variáveis de entrada e saída determinadas, foi realizada a simulação no Matlab, com o GIDA fornecido pelo Simulink. Para o cálculo das variáveis no modelo vetorial utilizou multímetros e amperímetros fornecidos pelo Simulink. Seus valores entraram no bloco S-function, onde são calculadas todas as componentes vetoriais necessárias para o treinamento da rede.

O diagrama de blocos resultante do Matlab é o da figura 2.

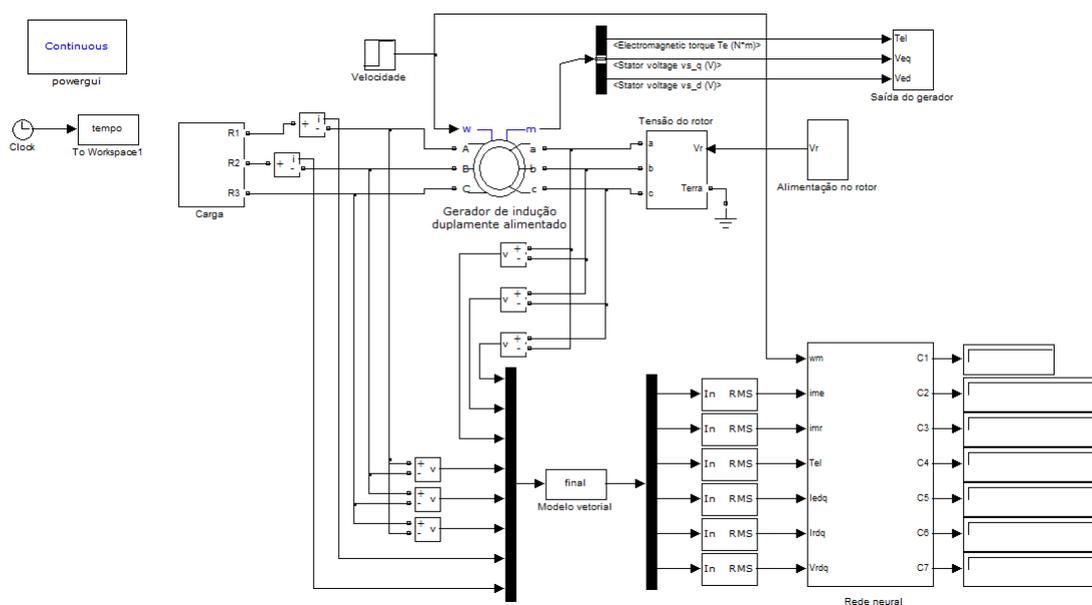


Figura 2: Diagrama de blocos no matlab

## 2.6 Construção da base de dados

Para coleta dos dados para o treinamento da rede, foram simulados os cinco tipos de falta. A simulação possui 4 velocidades, 4 cargas e 3 tensões no rotor diferentes, onde suas combinações totalizaram amostras diferentes em cada tipo de falta. A única exceção é o curto-circuito trifásico onde os valores da saída independem da carga, sendo esse o motivo dela possuir uma menor quantidade de amostras.

Os tipos de falta e suas respectivas quantidades são mostrados na Tabela 1.

Tabela 1: Simulações das faltas.

Tipo da falta	Quantidade
Sem falta	30
Falta fase-terra	30
Falta fase-fase-terra	30
Falta fase-fase	27
Falta trifásico	10
Total	127

Após as simulações, os dados de saída foram armazenados em arquivo para a realização do treinamento.

## 2.7 Treinamento da rede

Antes do treinamento é necessário definir os códigos de cada classe, ou seja, definir os valores para cada saída. Isso faz com que durante a falta a rede neural forneça um valor que corresponda a um defeito. Os códigos são mostrados na tabela 2.

Tabela 2: Códigos de saída.

Classe	Tipo da falta	Código
C1	Sem falta	10000
C2	Curto fase-terra	01000
C3	Curto fase-fase-terra	00100
C4	Curto fase-fase	00010
C5	Curto trifásico	00001

Com os dados de entrada e saída configurados é necessário mais detalhes sobre a rede *perceptron* multicamadas e o treinamento *backpropagation* com *momentum*.

A rede é composta por 5 neurônios de saída, conforme o código da tabela 2. A quantidade de neurônios na camada intermediária é variável e serão testados 10, 15, 20 e 30 neurônios. A determinação da melhor rede será utilizando um *cross-validation* onde é utilizado 90% das variáveis para treinamento e o restante é utilizado para o teste.

A taxa de aprendizagem considerada foi 0,1. A precisão é de  $10^{-6}$  ou um máximo de 10000 épocas. O fator de *momentum* 0,9. No treinamento de operação são considerados os seguintes valores para a saída:

$$y_p = 1, \text{ se } y^{saida} > 0,5 \quad (5)$$

$$y_p = 0, \text{ se } y^{saida} < 0,5$$

O treinamento da rede é utilizando os valores das tabelas 1 e 2.

## 3. RESULTADOS

A tabela 3 mostra a porcentagem de acertos de 4 tipos de RNA, com cada uma com diferente quantidade de neurônio na camada intermediária. Não foi aumentada a quantidade de neurônios para evitar erros com *overfitting* (memorização excessiva).

Tabela 3: Porcentagem de acerto das RNA.

Qtde de neurônio	C1	C2	C3	C4	C5
10	100	100	40	74	100
15	100	100	40	88.9	100
20	100	100	40	62.7	100
30	100	100	40	100	100

Baseado nos resultados apresentados na tabela 3 emprega-se 30 neurônios na camada intermediária. Além de possuir a maior porcentagem de acertos, não ocorreu nenhum erro na previsão das classes C1, C2, C4 e C5 (contando tanto os dados de treinamento quanto o de teste). Nos outros 60% de erro na identificação de C3, a saída ofereceu C4, não ocorrendo nenhuma indeterminação como nas outras redes. Todos os testes chegaram ao limite máximo de 10.000 épocas.

Para testar a rede neural em uma falta durante uma operação com carga equilibrada do gerador foi simulado 3 casos, falta trifásica, fase-fase-terra e fase-terra, com cada um mostrando duas variáveis diferentes de entrada da rede:

- falta trifásica: A falta ocorre em 0.2 segundos. Os sinais analisados são os valores da corrente de magnetização do estator e a corrente do rotor, figuras 3 e 4 respectivamente. E por último a figura 5 mostra a ativação do neurônio do estado C5, que representa a falta trifásica. Os sinais dos outros neurônios foram omitidos, pois eles são zero, com exceção do neurônio C1 que representa condição sem falta, que ocorre até 0.2 segundos.

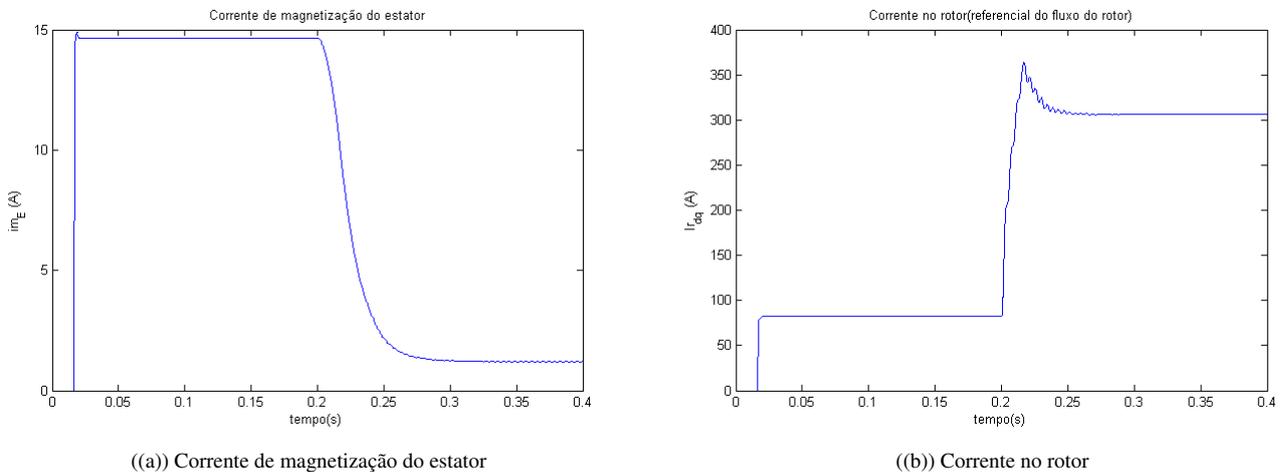


Figura 3: Saídas do GIDA em falta trifásica

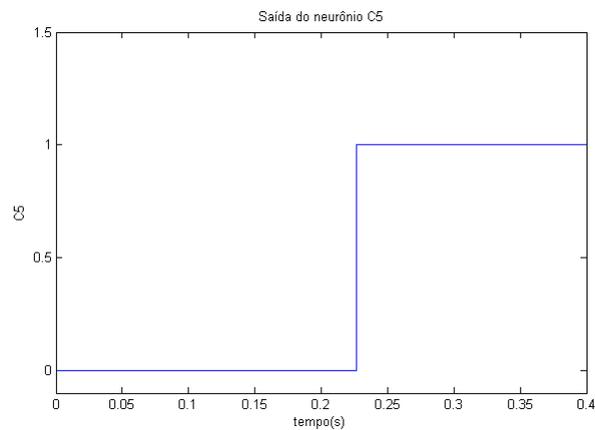


Figura 4: Sinal do neurônio C5

- falta fase-fase-terra: A falta ocorre em 0.2 segundos. Os sinais analisados são os valores do torque eletromagnético e a corrente de magnetização do rotor, figuras 6 e 7 respectivamente. O último gráfico é da figura 8, com o neurônio de ativação do estado 4. Os sinais dos outros neurônios foram omitidos já que eles são zero.

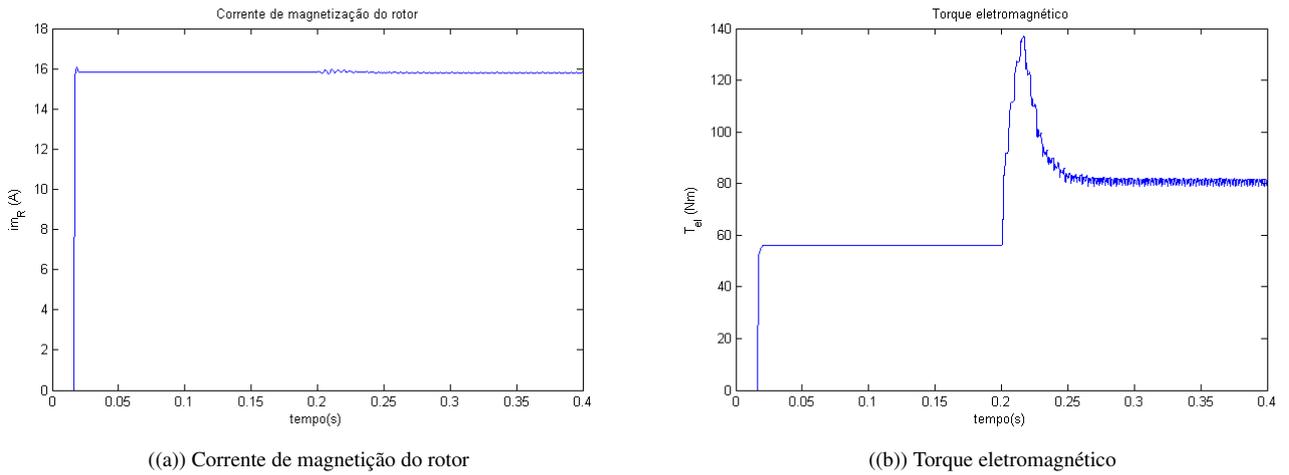


Figura 5: Saídas do GIDA em falta fase-fase-terra

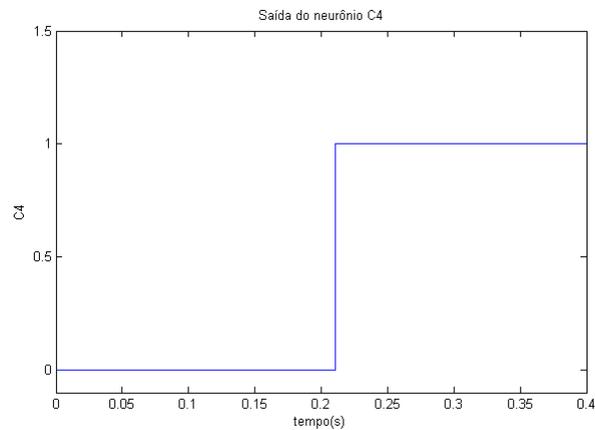


Figura 6: Sinal do neurônio C4

- falta fase-terra: A falta ocorre em 0.2 segundos. Os sinais analisados são os valores do torque eletromagnético e a corrente do estator, figura 9 e 10 respectivamente. O último gráfico é o da figura 10, o neurônio de ativação do estado 2. Os sinais dos outros neurônios foram omitidos, pois eles são zero.

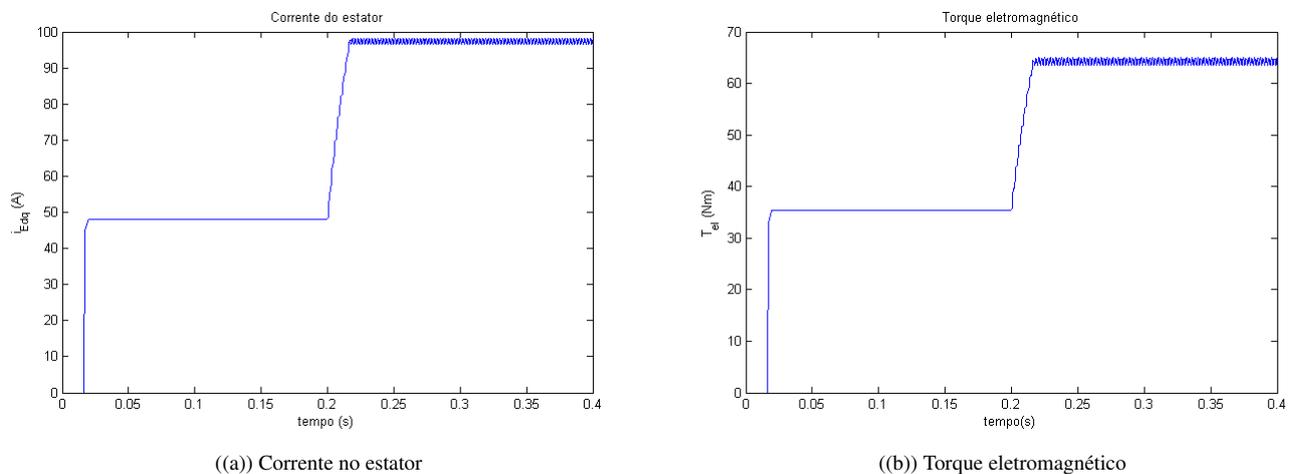


Figura 7: Saídas do GIDA em falta fase-terra

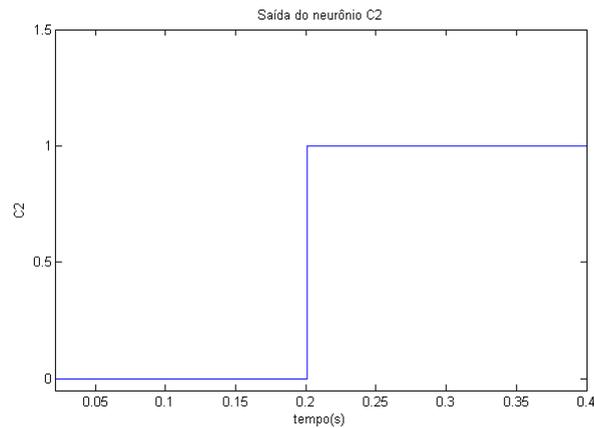


Figura 8: Saída do neurônio C2

## 4. CONCLUSÃO

A operação do PMC com 30 neurônios na camada intermediária apresentou os melhores resultados, conseguindo identificar 4 das 5 classes do banco de dados de entrada para o treinamento da rede sem nenhum erro, o único ocorrendo pela similaridade dos sinais de saída dos curtos fase-fase e fase-fase-terra. Mesmo nos casos de erro a RNA identifica o outro tipo de falta similar, evitando indeterminação de falta, problema que deve ser evitado nessa aplicação.

Os gráficos apresentados na seção anterior e o treinamento da rede mostraram que a RNA utilizando as variáveis calculadas no modelo vetorial é uma alternativa para identificação do tipo de falta do GIDA. Além de um acerto maior que 80%, os tempos de identificação da falta foram de 47ms na falta trifásica, 16ms na falta bifásica e 1.05ms na falta fase-terra.

## REFERÊNCIAS

- [1] D. Svehkarenko *On design and analysis of a novel transverse flux generator for direct-driven wind application*. Tese de doutorado, Royal Institute of Technology, Stockholm, Suécia, 2010
- [2] S. A. D. Ramroom *Fault detection of fault ride through for doubly-fed induction generator based wind energy systems*. Tese, Toronto, Canadá, 2008.
- [3] A. Yazidi, H. Henao, G.A. Capolino, D. Casadei, F. Filippetti, C. Rossi *Simulation of a Doubly-Fed Induction Machine for Wind Turbine Generator Fault Analysis*. Diagnostics for Electric Machines, Power Electronics and Drives, 2005.
- [4] DJ.Khodja, B.Chetate *Development of Neural Networks module for fault identification in asynchronous machine using various types of reference signals*. PhysCon 2005, St. Petersburg, Russia, 2005.
- [5] A. Ourici, *Fault Classification of a Doubly FED Induction Machine Using Neural Network*. World Academy of Science, Engineering and Technology, Argélia, 2009
- [6] S. Kolla , L. Varatharasa *Identifying three-phase induction motor faults using artificial neural networks*. ISA Transactions 39 (2000), Bowling Green, EUA, 2000
- [7] I. Barbi, *Teoria Fundamental do Motor de Indução*. Editora da UFSC, Série Didática, Florianópolis, 1985.
- [8] M. L. de Aguiar *Apostila da disciplina modelos dinâmico de máquinas* São Carlos, 2011. Disponível em: <>[http://www.sel.eesc.usp.br:8085/ Disciplinas/disciplinas/arq\\_lista.jsp?id=23](http://www.sel.eesc.usp.br:8085/ Disciplinas/disciplinas/arq_lista.jsp?id=23). Acessado no dia 29 de junho de 2011.
- [9] I. N. da Silva, D. H. Spatti, R. A. Flauzino *Redes Neurais artificiais para engenharia e ciências aplicadas curso prático* Artliber editora Ltda, 2010.
- [10] N. S. Vyas, D. Satishkumar *Artificial neural network design for fault identification in a rotor-bearing system*. Mechanism and Machine Theory, India, 2000.