

Aplicação de uma Rede Neural Artificial na Estimação de Velocidade de um Motor de Corrente Contínua

Prof. Msc. Arlei Fonseca Barcelos
arleifb@hotmail.com
FER - AEDB

Juliana Ribas Monteiro
ribasjuliana@hotmail.com
FER - AEDB

Wallace de Almeida Gomes
wallace1001@ig.com.br
FER - AEDB

Resumo: Com a evolução dos sensores, as variáveis dos processos têm exigido cada vez mais o menor número possível de intervenções na manutenção desses equipamentos, com isso os estudos em inteligência artificial tem se aprofundado cada vez mais com o objetivo de substituir um componente físico por um virtual com maior robustez e desempenho, reduzindo o custo de um projeto, além do crescimento da instrumentação virtual. A proposta desse trabalho é apresentar as etapas de construção de uma rede neural artificial (RNA) e implementá-la no software LabVIEW® utilizando a placa NI USB-6009 para adquirir dados em tempo real, para que então fosse avaliado o desempenho da rede neural artificial em tempo real. Nos resultados obtidos foi possível analisar seu acerto e comparar uma rede neural artificial modelada com dados obtidos de forma manual com uma modelada a partir de dados adquiridos em tempo real.

Palavras Chave: RNA - LabVIEW® - Aquisição de dados - Desempenho -

1 INTRODUÇÃO

O presente trabalho trata-se de uma aplicação de uma rede neural em uma planta (cadeira de rodas motorizada), onde foram obtidos dados de tensão, corrente e velocidade de um motor CC da cadeira através de uma placa de aquisição de dados, onde essas amostras serviram de treinamento para uma rede neural, que depois de estruturada forneceria os valores de velocidade para que então fosse comparada com um tacogerador verificando sua eficácia.

1.1 HIPÓTESE, OBJETIVO E METODOLOGIA UTILIZADA

O trabalho visa confirmar a hipótese de uma rede neural após ter sido estruturada para funcionar em uma aplicação prática e seu comportamento em tempo real, onde há a possibilidade de uma rede neural substituir um medidor de velocidade fazendo com que haja redução de custo em um projeto.

No trabalho apresentado por Mamani (2004), é demonstrada uma simulação de um projeto de uma rede neural onde a mesma é utilizada para estimação de velocidade de um veículo experimental.

O objetivo, então, é projetar uma rede neural fazendo uma aplicação prática de modo a avaliar seu desempenho para que futuramente seja embarcada.

A metodologia proposta no trabalho tem base nos experimentos realizados na planta sendo utilizados *softwares* de construção de redes neurais e implementação dos algoritmos da rede, onde através de gráficos e amostras de resultados foi possível avaliar o desempenho da mesma.

2 REDES NEURAIS ARTIFICIAIS (RNA)

2.1 DEFINIÇÃO

A definição de uma rede neural vista como uma máquina adaptativa é um processador maciçamente paralelamente distribuído constituído de unidades de processamento simples, que tem a propensão natural para armazenar conhecimento experimental e torná-lo disponível para o uso. Ela se assemelha ao cérebro humano em dois aspectos:

- O conhecimento é adquirido pela rede a partir de seu ambiente de trabalho através de um processo de aprendizagem;
- Forças de conexão entre neurônios, conhecidas como pesos sinápticos, são utilizadas para armazenar o conhecimento adquirido.

O procedimento utilizado para realizar o processo de aprendizagem é chamado de algoritmo de aprendizagem que tem como função modificar os pesos sinápticos da rede de uma forma ordenada para alcançar um objetivo de projeto desejado (HAYKIN, 2001).

2.2 PROPRIEDADES DAS RNA'S

O uso das redes neurais pode oferecer as seguintes capacidades segundo Haykin (2001): não linearidade; mapeamento de entrada-saída; adaptabilidade; resposta a evidências; informação contextual; tolerância a falhas; uniformidade de análise e projeto; analogia neurobiológica.

2.3 MODELO DE UM NEURÔNIO

Como explica Haykin (2001), um neurônio é uma unidade de processamento de informação que é fundamental para a operação de uma rede neural, a Figura 1 a seguir mostra

o modelo de um neurônio onde é possível identificar três elementos básicos de um modelo neuronal:

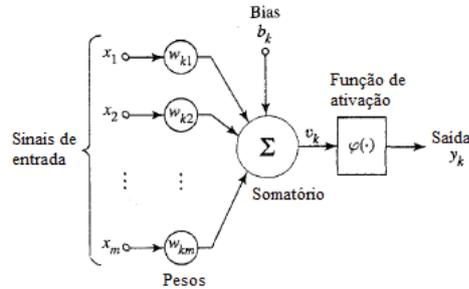


Figura 1: Modelo não linear de um neurônio. Fonte: HAYKIN, 2001.

1. Um conjunto de elos de conexão (ou conjunto de sinapses), cada um caracterizado por um peso ou força própria. Especificamente, um sinal x_j na entrada da sinapse j conectada ao neurônio k é multiplicado pelo peso sináptico w_{kj} .

2. O somador para somar os sinais de entrada ponderados pelas respectivas sinapses do neurônio (combinador linear).

3. Uma função de ativação para restringir a amplitude da saída de um neurônio. A função de ativação é também referida como função restritiva já que restringe (limita) o intervalo permissível de amplitude do sinal de saída a um valor finito.

O bias, representado por b_k , tem o efeito de aumentar ou diminuir a entrada líquida da função de ativação, dependendo se ele é positivo ou negativo, respectivamente. Assim, pode-se descrever um neurônio k por meio das seguintes Equações 1 e 2:

$$U_k = \sum_{j=1}^m W_{kj} * X_j \quad \text{Equação 1}$$

$$Y_k = \varphi * (U_k + B_k) \quad \text{Equação 2}$$

Onde x_1, x_2, \dots, x_m são os sinais de entrada, $w_{k1}, w_{k2}, \dots, w_{km}$ são os pesos sinápticos dos neurônios, U_k é a resposta da multiplicação dos pesos com os sinais de entrada, B_k é o bias que é um parâmetro externo do neurônio, $\varphi(.)$ é a função de ativação, potencial de ativação do neurônio ou campo local induzido e Y_k é a resposta de saída do neurônio.

2.4 FUNÇÃO LINEAR

É similar a função linear por partes, diferenciando por não ter limites, logo sua função pode ser visualizada pela Equação 3 e pelo Gráfico 1:

$$Y = aX \quad \text{Equação 3}$$

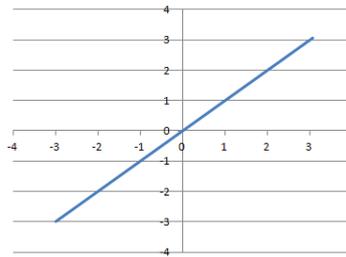


Gráfico 1: Função de ativação linear. Fonte: Própria.

Este tipo de função foi utilizada pela equipe na construção da rede neural artificial.

2.5 REDES NEURAIS *FEEDFORWARD*

São redes que propagam o sinal somente no sentido positivo, ou seja, a propagação do sinal ocorre da entrada para a saída. Para redes pertencentes nesta classe, as saídas de seus neurônios podem somente ser conectar com neurônios pertencentes da próxima camada. São exemplos de redes dessa arquitetura: *perceptron* de uma camada, *perceptron* multicamadas e rede neural (RN) função de base radial, conforme Figura 2.

Este tipo de arquitetura foi utilizado pela equipe na construção da rede neural.

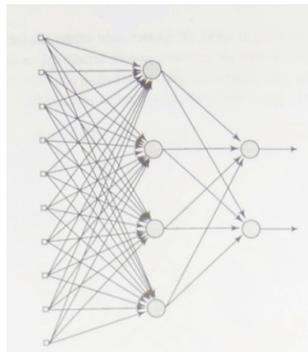


Figura 2: Multicamadas (feedforward). Fonte Haykin, 2001.

3 CONSTRUÇÃO DA RNA ATRAVÉS DOS *SOFTWARES*

O *software* NEUROSOLUTIONS® é uma ferramenta de desenvolvimento de redes neurais gráficas para *Windows*. Esse *software* de última geração combina um *design* de interface modular com a implementação do procedimento de aprendizado avançado utilizando o Excel, onde o usuário através da tabela pode construir a rede neural, tendo como vantagens a possibilidade de analisar a tendência para os novos dados, embora por ser um processo gráfico, não há possibilidade de extração dos valores das sinapses da rede para uma implementação física da mesma. Este *software* foi utilizado apenas como forma didática para aprendizado sobre redes neurais artificiais.

O *software* MATLAB® desenvolvido pela *The MathWorks, Inc*, é um sistema interativo e uma linguagem de programação baseados numa matriz, onde as soluções e problemas são expressos em linguagem matemática. Através da utilização do mesmo é possível realizar análise numérica, operações com matrizes, construção de gráficos e criação de interfaces com o usuário. Este *software* foi utilizado no desenvolvimento do trabalho para modelagem das redes neurais artificiais.

Uma das principais vantagens do *software* MATLAB® é a facilidade de escrever e depurar um programa, se comparado a outras linguagens de programação (tais como C, Basic, Pascal ou Fortran). Além disso, possui diversas funções matemáticas, matriciais e gráficas que simplificam e minimizam a estrutura do programa. Diferente do NEUROSOLUTIONS®, possui tanto a forma gráfica, como em linhas de comando na construção da rede neural, além da capacidade de fornecer os valores das sinapses da rede para uma futura implementação.

3.1 DESENVOLVIMENTO DA APLICAÇÃO DE UMA REDE NEURAL

Segundo Mamani (2004), os passos necessários para o desenvolvimento de aplicações utilizando redes neurais artificiais são os seguintes: coleta de dados; separação em conjuntos; configuração da rede; treinamento da rede; teste da rede; e integração da rede.

4 DESENVOLVIMENTO DA REDE NEURAL ARTIFICIAL

Para o desenvolvimento da RNA foi necessário obter valores de tensão (V), corrente (A) e velocidade (RPM).

4.1 RNA MODELADA COM DADOS COLETADOS MANUALMENTE

Houve a necessidade da coleta manual para uma “pré” avaliação do funcionamento da RNA.

4.1.1 Coleta manual

Os dados foram coletados utilizando um amperímetro DC digital (em série), um voltímetro DC digital (em paralelo) e um tacômetro digital. Foram coletados 501 valores de tensão, corrente e velocidade apenas com a roda livre.

4.1.2 Desenvolvimento da RNA no MATLAB®

Foram coletadas manualmente 501 amostras. Foram separadas 490 amostras para a criação e treino da rede neural para que as restantes, no caso 11, fossem testadas através do próprio algoritmo da rede.

A rede foi criada com os seguintes parâmetros:

- Tipo de rede: *Feed-forward backpropagation*.
- Função de treinamento: *trainlm (Levenberg-Marquardt backpropagation)*.
- Função de adaptação: *learngdm*.
- Função de desempenho: MSE.
- Número de camadas: 2.
- Número de camadas escondidas: 1.
- Número de neurônios da camada escondida: 3.
- Função de ativação da camada escondida: linear.
- Função de ativação da camada final: linear.

Nesta fase, foi necessária a mudança da função de ativação de sigmoideal para linear, pois com esta função foi possível alcançar um resultado satisfatório, esta rede foi treinada com 2000 épocas e obteve 90,689% . O algoritmo da rede é apresentado na Equação 4:

$X1$ = valor de tensão;

$X2$ = valor de corrente

$K1 = X1 * 1,4569 + X2 * (1,1273) + 2,4178$;

$K2 = X1 * 1,1562 + X2 * (3,0272) - 2,342$;

$K3 = X1 * (-0,6667) + X2 * (3,4947) + 4,4933$;

Saída = $K1 * 1,7429 + K2 * 2,133 + K3 * (-3,9843) - 0,48171$

Equação 4

4.2 RNA MODELADA COM DADOS AQUISITADOS EM TEMPO REAL

Primeiramente foi desenvolvido um programa para adquirir dados em tempo real para que pudesse ser desenvolvida a RNA. Foram adquiridos 87.781 dados de tensão (V), corrente (A) e velocidade (RPM), dentro do limite de variação da fonte de 0 a 5 V , com intervalos de 0,1 V . Esses valores são referentes a roda livre e a aplicação de torque.

4.2.1 Placa de aquisição de dados

Foi escolhida a placa da *National Instruments USB-6009 data acquisition* (DAQ) (Figura 3).



Figura 3: NI USB-6009. Fonte: www.ni.com

Ela possui compatibilidade com o LabVIEW®, utilizado para fazer a instrumentação virtual. Como é uma placa que só lê sinal (níveis de tensão), foi necessário utilizar o sensor de corrente por efeito *hall* que gera um diferencial de tensão correspondente a uma corrente. A tensão teve que ser reduzida, pois a placa lê no máximo 10 V , na entrada analógica. Foi necessário também utilizar um tacogerador, pois a placa não possui velocidade suficiente para ler os pulsos do *encoder* que se encontra na planta.

4.2.2 Divisor resistivo

Para a leitura da tensão foi necessário limitar a tensão a 10 V , já que o motor é de 24 V . Assim fez o seguinte divisor resistivo (Equação 5):

$$V_{Entrada} = 2,4 \times V_{Saída}$$

Equação 5

4.2.3 Sensor de corrente por efeito *hall*

O sensor de corrente utilizado foi por efeito *hall* do fabricante Allegro, modelo ACS714LLCTR-30A-T. Sua leitura é de -30 A a 30 A . Sua alimentação é 5 V . Sua Equação 6 é:

$$I = \frac{2,5 - V}{66 \times 10^{-3}}$$

Equação 6

Onde: I é a corrente em A ; V é a tensão em V ; 66×10^{-3} é a sensibilidade (mV/A).

4.2.4 Tacogerador

O tacogerador foi cedido por uma empresa, como não havia nenhuma descrição de qual era o modelo foi necessário realizar um ensaio na planta para descobrir sua curva de tensão *versus* velocidade. A Equação 7 da velocidade lida pelo tacogerador é:

$$Velocidade = -0,06991 + (342,0129V)$$

Equação 7

Onde: Velocidade é a velocidade da roda (RPM); V é a tensão (V).

4.2.5 Circuito elétrico (acionamento, controle e aquisição de dados)

O funcionamento do circuito baseia-se da seguinte forma: o pino 3 do PIC recebe a variação tensão (entrada analógica) que faz com que ocorra a variação do PWM. O pino 16 é a saída PWM que passa pelo optoacoplador e chega ao *gate* do MOSFET. A função do optoacoplador é fazer a isolamento do circuito de controle do circuito de acionamento. Com a variação da largura do pulso, o MOSFET é chaveado, e a energia que chega ao motor é proporcional a essa variação. Assim com a variação de energia no motor controla-se a velocidade. O pino 20 que vai até o LED é apenas para indicar que o programa está sendo executado. A Figura 4 abaixo mostra o circuito de controle e acionamento do motor bem como o circuito para aquisição de dados em tempo real.

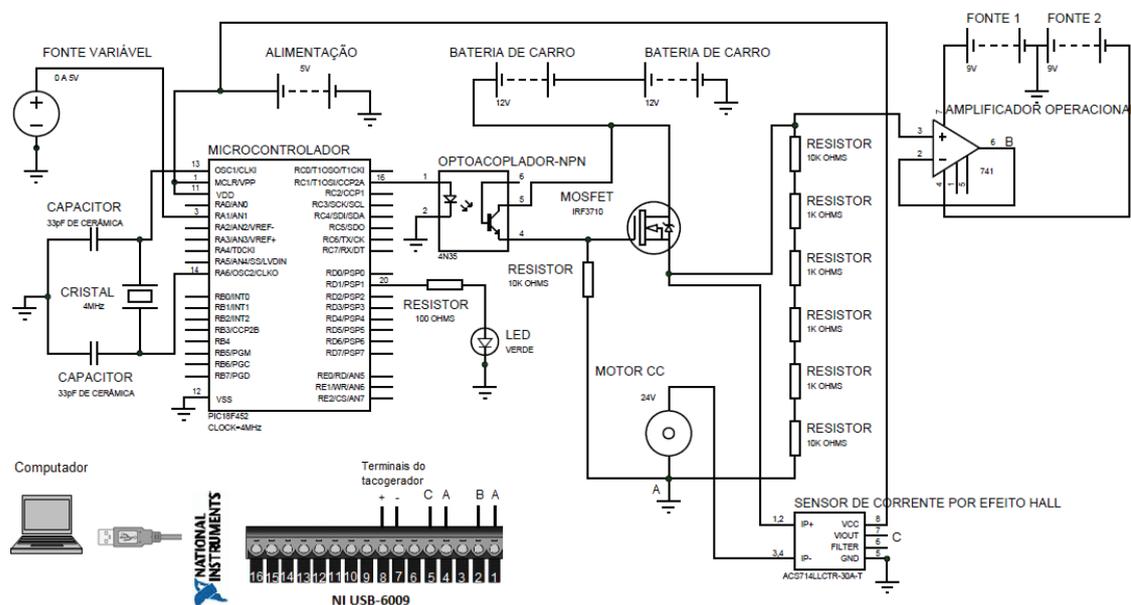


Figura 4: Circuito de controle e acionamento do motor CC. Fonte: Própria.

4.2.6 Software para aquisição de dados

Foi utilizado o software LabVIEW® para aquisição de dados. O diagrama de blocos é mostrado na Figura 5 e o painel frontal na Figura 6.

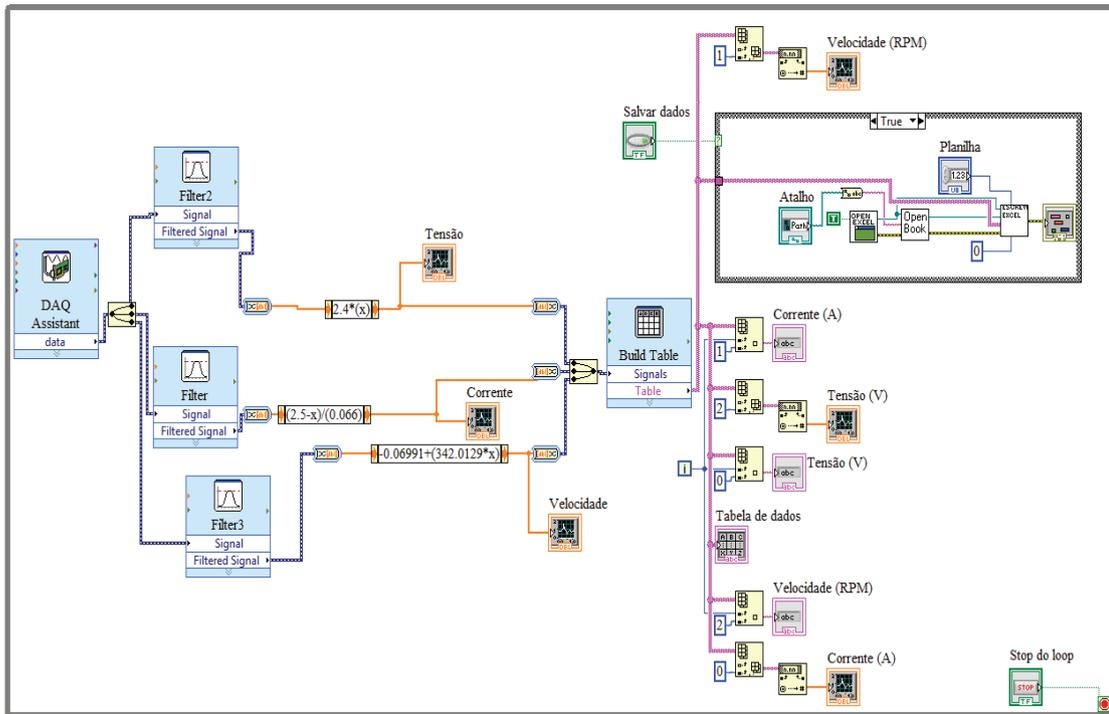


Figura 5: Diagrama de blocos para aquisição de dados. Fonte: Própria.

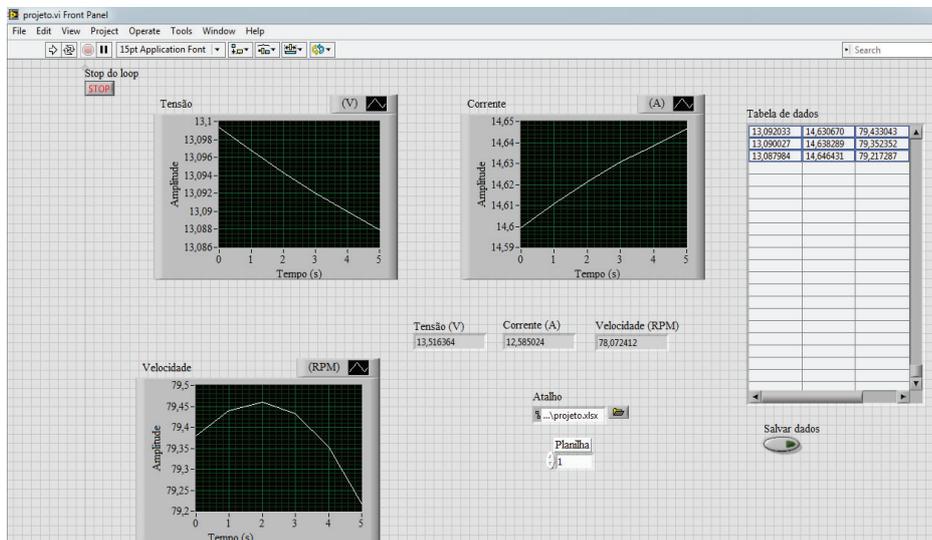


Figura 6: Painel frontal para aquisição de dados. Fonte: Própria.

4.2.7 Desenvolvimento da RNA no MATLAB®

Foram coletadas pelo circuito de aquisição de dados 87.781 amostras (2000 épocas), dos valores de tensão, corrente e velocidade, de modo que foi criada uma nova rede com os seguintes parâmetros (Figura 7):

- Tipo de rede: *Feed-forward backpropagation*.
- Função de treinamento: *trainlm (Levenberg-Marquardt backpropagation)*.

- Função de adaptação: learnqdm.
- Função de desempenho: MSE.
- Número de camadas: 2.
- Número de camadas escondidas: 1.
- Número de neurônios da camada escondida: 3.
- Função de ativação da camada escondida: linear.
- Função de ativação da camada final: linear.

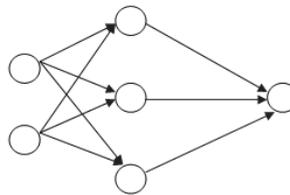


Figura 7: Aspecto RNA criada no MATLAB®. Fonte: Própria.

Onde foi obtida uma correlação de 98,754% conforme mostra o Gráfico 2.

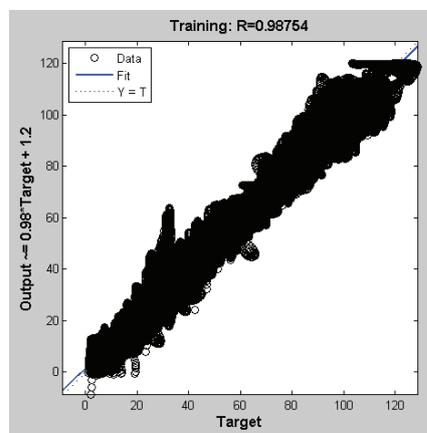


Gráfico 2: Informações do resultado da nova rede. Fonte: Própria.

Após isto, foi criada também uma RNA mudando apenas sua função de ativação para sigmoidal, porém apresentou um valor de eficiência praticamente igual à anterior. Devido a semelhanças entre os valores das redes que usam função linear e sigmoidal, foi decidido implementar a rede que utilizou a função de ativação linear devido a praticidade de implementação da mesma, para isso os valores das sinapses e bias foram extraídos e o algoritmo da rede chegou na Equação 8:

X1= valor de tensão

X2= valor de corrente

$$K1= X1*2,5348 + X2*(-1,3278) + 0,5914$$

$$K2= X1 * 3,8575 + X2 * (-0,67944) - 0,12675$$

$$K3= X1 * 0,39447 + X2 * (0,1779) - 1,0029$$

$$\text{Saída} = K1 * 0,67807 + K2 * 1,8572 + K3 * (-2,7012) + 0,034547 \quad \text{Equação 8}$$

4.3 PROGRAMA DESENVOLVIDO NO LABVIEW® PARA TESTAR AS RNA'S

Posteriormente com a RNA desenvolvida, mostrada no próprio Capítulo 4, obteve-se sua modelagem e foi incluída no programa para adquirir dados em tempo real, servindo também para validar (Capítulo 5) seu funcionamento. Foi também testada a RNA modelada com dados obtidos de forma manual.

Foi desenvolvida a programação no diagrama de blocos, mostrada na Figura 8 e desenvolvido um supervisor no painel frontal, conforme Figura 9.

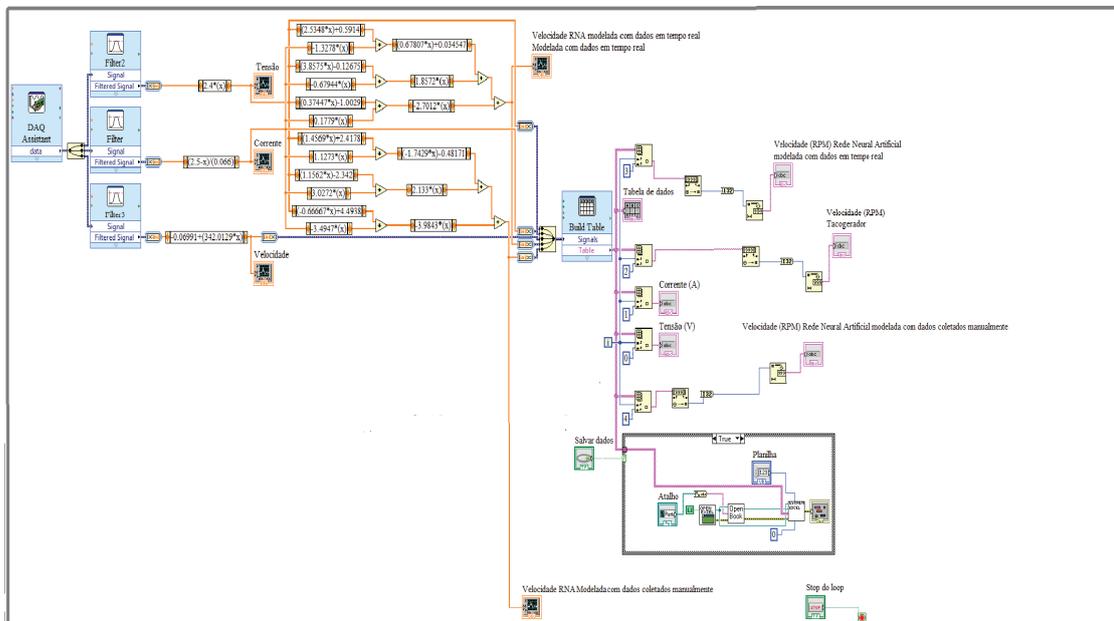


Figura 8: Diagrama para validar a RNA. Fonte: Própria.

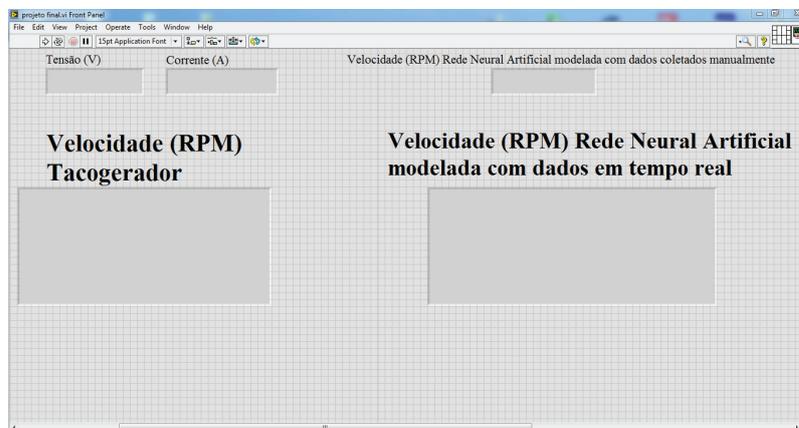


Figura 9: Supervisor. Fonte: Própria.

As Equações 5, 6 e 7, citadas no Capítulo 4, foram colocadas no diagrama de blocos do LabVIEW®. A aquisição de dados era parada com o *stop do loop*. Os dados eram registrados nas colunas da tabela, tensão (V), corrente (A) e velocidade em (RPM), respectivamente e eram salvos numa planilha de Excel.

5 RESULTADOS PRÁTICOS OBTIDOS

Após as RNA's serem modeladas e implementadas no LabVIEW®, como descrito no Capítulo 4, foram salvas algumas amostras para analisar sua eficiência.

A RNA modelada com dados coletados de forma manual foi testada apenas com roda livre, pois foi treinada com valores sem torque.

Já a RNA modelada com dados aquisitados em tempo real foi testada com roda livre e com aplicação de torque, conforme explica a Figura 10.



Figura 10: RNA's, dos treinos até a validação. Fonte: Própria.

5.1 RESULTADOS DA RNA MODELADA COM DADOS COLETADOS MANUALMENTE

Dentro de 4.400 amostras diferentes, com a utilização do Excel, através da Equação 9, que calcula o erro percentual e das funções MÉDIA (com ABS, em módulo) e DESVPAD (do próprio Excel), que calculam a média aritmética e o desvio padrão respectivamente, foi encontrado um valor de erro percentual (médio) de 28,41132126% e um desvio padrão de 17,0738896.

$$\text{erro percentual}(\%) = \left| \frac{\text{velocidade tacogerador} - \text{velocidade RNA}}{\text{velocidade RNA}} \times 100 \right| \text{Equação 9}$$

Foi plotado o Gráfico 3 para analisar a dispersão apresentada pela RNA.

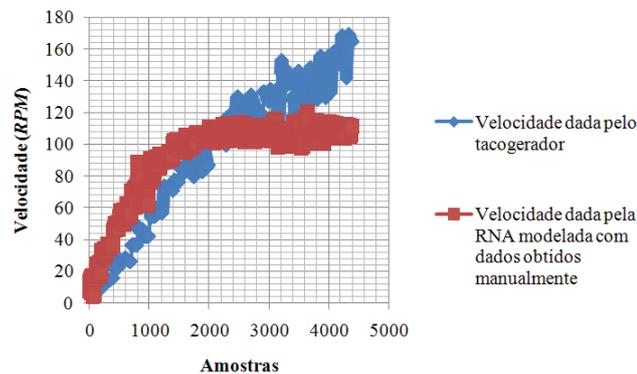


Gráfico 3: Dispersão dos valores da RNA modelada com dados obtidos manualmente. Fonte: Própria.

Deve-se levar em consideração que essa RNA foi treinada com valores coletados manualmente e foi testada com valores aquisitados em tempo real.

A sua correlação (eficiência) no NERUROSOLUTIONS® foi de 98,7% e no MATLAB® foi de 90,689% (Capítulo 4), ambos valores bons mas na prática apresentou menos eficiência, com valores maiores no erro percentual (médio) e no desvio padrão. Pode-se também observar a dispersão, seu afastamento da velocidade dada como referência (do tacogerador) no Gráfico 3. Percebe-se também que ela erra mais com valores mais altos de velocidade.

5.2 RESULTADOS RNA MODELADA COM DADOS AQUISITADOS EM TEMPO REAL

5.2.1 Roda livre

Dentro de 4.339 amostras diferentes, com a utilização do Excel, através da Equação 20, que calcula o erro percentual e das funções MÉDIA (com ABS, em módulo) e DESVPAD (do próprio Excel), que calculam a média aritmética e o desvio padrão respectivamente, foi encontrado um valor de erro percentual (médio) de 15,3994467% e um desvio padrão de 11,09586093.

Foram plotados os Gráficos 4 e 5 para analisar a dispersão apresentada pela RNA.

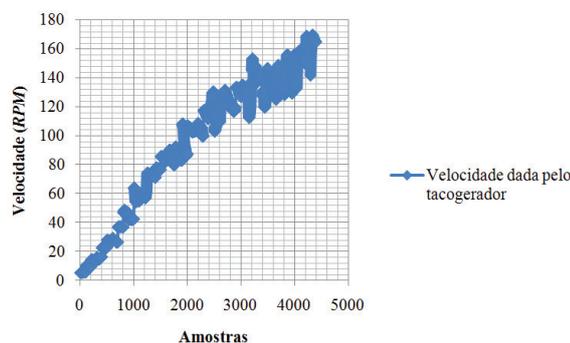


Gráfico 4: Dispersão dos valores do tacogerador. Fonte: Própria.

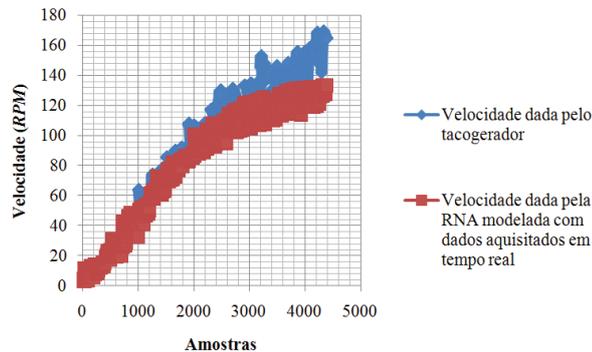


Gráfico 5: Dispersão dos valores da RNA modelada com dados adquiridos em tempo real sem aplicação de torque. Fonte: Própria.

A sua correlação (eficiência) no MATLAB® foi de 98,754% (Capítulo 4), valor muito bom mas na prática apresentou menos eficiência, com valores maiores no erro percentual (médio) e no desvio padrão. Pode-se também observar a dispersão, seu afastamento da velocidade dada como referência (do tacogerador) no Gráfico 5 com valores mais altos de velocidade.

5.2.2 Com aplicação de torque

Dentro de 4.458 amostras diferentes, com a utilização do Excel, através da Equação 20, que calcula o erro percentual e das funções MÉDIA (com ABS, em módulo) e DESVPAD (do próprio Excel), que calculam a média aritmética e o desvio padrão respectivamente, foi encontrado um valor de erro percentual (médio) de 18,55514606% e um desvio padrão de 12,54645041.

Foram plotados os Gráficos 6 e 7 para analisar a dispersão apresentada pela RNA.

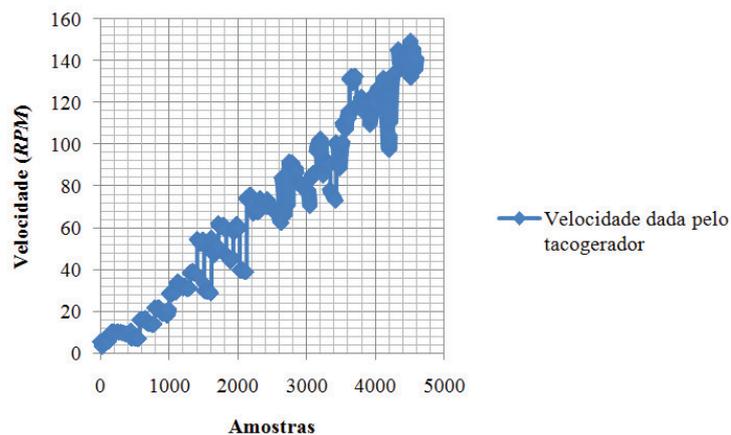


Gráfico 6: Dispersão dos valores do tacogerador com aplicação de torque. Fonte: Própria.

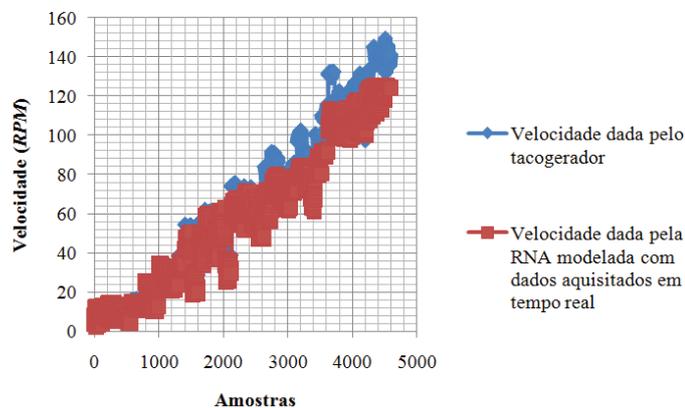


Gráfico 7: Dispersão dos valores da RNA modelada com dados aquisitados em tempo real com aplicação de torque. Fonte: Própria.

A sua correlação (eficiência) no MATLAB® foi de 98,754% (Capítulo 4), valor muito bom mas na prática apresentou menos eficiência, com valores maiores no erro percentual (médio) e no desvio padrão. Pode-se também observar a dispersão, seu afastamento da velocidade dada como referência (do tacogerador) no Gráfico 7 ao longo dos valores de velocidade.

6 CONSIDERAÇÕES FINAIS

A primeira proposta da equipe foi embarcar a RNA na planta. Para a construção da RNA foi necessário o entendimento dos *softwares* NERUROSOLUTIONS® e MATLAB® que demonstraram grande eficiência e praticidade na criação da RNA. Com alguns problemas encontrados, dificuldades em encontrar referências com aplicações práticas da RNA e o tempo gasto na resolução desses, essa proposta teve que ser abandonada. Com isso, os esforços foram voltados para o desenvolvimento e implementação de uma RNA no *software*, de modo a validar o desempenho da RNA na prática comparando seus resultados. Para viabilizar o projeto foi criada uma RNA através de amostras coletadas manualmente, em seguida foi realizado o desenvolvimento de uma aquisição de dados em tempo real, com aplicação da instrumentação virtual, utilizando o *software* LabVIEW® pode-se perceber a flexibilidade e facilidade nas alterações e testes no desenvolvimento do *hardware*. Para que então baseado nesses dados fosse possível criar uma nova rede, que seria implementada para obter resultados em tempo real, de modo a avaliar seu desempenho para uma futura substituição de um medidor de velocidade.

A RNA construída com dados obtidos de forma manual apresentou maior dispersão, ou seja, menos acerto que a RNA construída com dados aquisitados em tempo real, devido à diferença de velocidade, sensibilidade, precisão e erros de observação e operação dos instrumentos de medição utilizados quando comparados com a placa NI USB-6009.

O desempenho da RNA construída com dados aquisitados em tempo real foi melhor, sem aplicação de torque. Com valores altos de velocidade ela começa a apresentar um erro maior ou distanciar mais do valor apresentado pelo tacogerador. Percebeu-se que o tacogerador e tacômetro apresentaram pequenas variações de velocidade devido a um pequeno desbalanceamento da roda, influenciando no comportamento da RNA. A placa NI USB-6009 juntamente com a versão 2012 do LabVIEW® e o computador pessoal utilizado apresentaram também alguns problemas, tais como estouro de memória, mesmo quando os dados eram aquisitados em tempo real (mesmo seu limite de memória não ter alcançado a metade) e também para os primeiros cinquenta valores aquisitados, quando se iniciava o

processo de aquisição apresentavam incoerência, sendo considerados valores equivocados.

O trabalho impôs a equipe a capacidade de resolver os problemas encontrados durante o projeto utilizando a pesquisa e o método científico, de forma que ao observar o problema foi buscado a explicação para o mesmo propondo a resolução, com as ferramentas disponíveis de forma contínua de aperfeiçoamento. E no decorrer do trabalho, foi bastante estudado as teorias sobre RNA's, que foi de grande contribuição para o conhecimento dos integrantes da equipe. Trabalhou o lado da pesquisa científica, onde foi correlacionada a teoria com a prática.

REFERÊNCIAS BIBLIOGRÁFICAS

HAYKIN, S. **Redes neurais: princípios e prática**. 2. ed. Porto Alegre: Bookman, 2001.

MAMANI, A. B. A. **Utilização de redes neurais no controle da velocidade de um veículo experimental**. 2004. p. 122. Dissertação (Mestrado em Engenharia Elétrica) - Universidade de Campinas. Campinas, 2004.

NI. **NI USB-6009**. Disponível em: < www.ni.com>. Acesso em: 6 mai. 2013.