

## Aplicação de Redes Neurais Artificiais para Predição do Comportamento Tribológico e Térmico de Materiais de Atrito Durante o Processo de Frenagem

Rafael Lucas Machado Pinto (UFMG) rafaelucas@gmail.com , Juan Carlos Horta Gutiérrez (UFMG) horta@demec.ufmg.br

**Resumo:** Sistemas de freio têm a finalidade de reduzir ou manter a velocidade de um veículo, levá-lo à imobilidade ou mantê-lo imóvel. O princípio básico dos sistemas de freios por atrito é a conversão da energia cinética do veículo em energia térmica. Neste estudo, buscou-se analisar os parâmetros de operação de um sistema de freio a disco para motocicletas utilizando-se um banco de ensaios baseado no procedimento Krauss, descrito pela norma ABNT NBR 6143/1995. Optou-se por conduzir um Experimento fatorial completo  $2^3$ , em que os três fatores de controle considerados (tipo de disco de freio, tipo de pastilha e o valor da pressão de acionamento da manete de freio) foram alterados deliberadamente em dois níveis cada. Analisou-se as propriedades dos materiais envolvidos novos e após um determinado tempo de uso, denominado materiais assentados. Para avaliar o desempenho do sistema de freio durante o processo de frenagem, analisaram-se cinco variáveis resposta simultaneamente: temperatura final, coeficiente de atrito, desaceleração, momento da força de frenagem e pressão de contato pastilha/disco. A partir deste experimento fatorial, optou-se por aplicar as técnicas de redes neurais artificiais (RNA) como forma de predizer o comportamento do sistema de freios analisado utilizando-se o software Qwiknet v2.23 para treinar (aprendizado do comportamento do sistema), testar e comparar com ensaios não utilizados no treinamento. Com bases nos resultados obtidos, o modelo obtido apresentou bons resultados quanto ao objetivo proposto de predição do comportamento das variáveis resposta estudadas.

**Palavras chave:** Sistema de Freios, Experimento Fatorial, Predição, Redes Neurais.

## Application of Artificial Neural Networks for Prediction of Tribological and Thermal Behavior of Friction Materials During Braking Process

**Abstract:** Brake systems are intended to reduce or maintain the speed of a vehicle, to immobilize it or to keep it immobile. The basic principle of friction brake systems is the conversion of the vehicle's kinetic energy to thermal energy. In this study, we sought to analyze the operating parameters of a disc brake system for motorcycles using a test bench based on the Krauss procedure, described by ABNT NBR 6143/1995. It was decided to conduct a complete Factorial Experiment  $2^3$ , in which the three control factors considered (brake disc type, pad type and brake lever actuation pressure value) were deliberately changed on two levels each. The properties of the new materials involved and after a certain use time, called settled materials were analyzed. To evaluate the performance of the brake system during the braking process, five response variables were analyzed simultaneously: final temperature, friction coefficient, deceleration, braking force moment and pad / disc contact pressure. From this factorial experiment, it was decided to apply the artificial neural networks (RNA) techniques as a way to predict the braking system behavior analyzed using Qwiknet v2.23 software to train (system behavior learning), test and compare with trials not used in training. Based on the obtained results, the obtained model presented good results regarding the proposed objective of predicting the behavior of the studied response variables.

**Key-words:** Brake System, Factorial Experiment, Prediction, Neural Networks.

## 1. Introdução

De acordo com Makrahy *et al.* (2013), sistemas de freio têm a finalidade de reduzir ou manter a velocidade de um veículo, levá-lo à imobilidade ou mantê-lo imóvel. Segundo SARIP (2011), o princípio básico de um sistema de freio por atrito é converter a energia cinética do veículo em energia térmica pressionando dois materiais, um contra o outro, em contato para desenvolver atrito entre duas superfícies.

Sanders *et al.* (2001) ressalta que o coeficiente de atrito depende da velocidade de escorregamento, da pressão de contato e da temperatura na interface do par tribológico. Neis (2012) menciona que as variáveis que influenciam no desempenho (desgaste e atrito) dos materiais de fricção utilizados para frenagem são composição química e microestrutural tanto do disco quanto da pastilha, velocidade de deslizamento entre o par de atrito, pressão de contato, filme de fricção, histórico térmico e de carga do material, temperatura e rugosidade do disco, além das condições ambientais de realização dos testes.

De acordo com Russel e Norvig (2013) a Inteligência Artificial (IA) é um dos campos mais recentes em ciências e engenharia. O trabalho nesta área começou logo após a segunda guerra mundial. Atualmente, a IA abrange uma enorme variedade de subcampos, do geral (aprendizado e percepção) até tarefas específicas, como jogos de xadrez, demonstração de teoremas matemáticos, criação de poesia, direção de um carro em uma estrada movimentada e diagnóstico de doenças. A IA é relevante para qualquer tarefa intelectual; é verdadeiramente um campo universal.

Segundo Leite (2015) vários autores acreditam que abordagens tradicionais para o controle de processo de manufatura não são capazes de atender na totalidade ou são incapazes, muitas vezes, de resolver os problemas por não conseguirem incluir aspectos “humanos” de controle de processo, como a imprecisão e indefinição, que são inerentes ao modelo mental do tomador de decisão. Desta forma, desde o seu surgimento, a IA tem evoluído em várias técnicas, com aplicações em sistemas de manufatura.

O presente trabalho aplicou a metodologia de planejamento de experimentos fatoriais Completo 2<sup>3</sup> em um banco de ensaios através do procedimento Krauss, descrito pela norma ABNT NBR 6143/1995, responsável em analisar as condições das pastilhas de freio a disco através da determinação do coeficiente de atrito e desgaste através da bancada de ensaios Krauss. Os dados para o desenvolvimento deste estudo foram coletados a partir de um banco de ensaios desenvolvido por um dos autores deste trabalho (PINTO, 2014). Este banco de ensaios buscou simular o comportamento de um sistema de freio de motocicletas, com o objetivo de avaliar o comportamento de variáveis de entrada que influenciam um típico sistema de freios. Como variáveis de saída ou resposta a serem analisadas tem-se a temperatura alcançada pelo par de atrito e propriedades tribológicas do sistema.

Este estudo justifica-se pelo fato de que, conhecendo-se o comportamento das principais variáveis durante a frenagem para cada um dos materiais de fricção ensaiados, torna-se possível avaliar e comparar o desempenho de cada material através da medição dos parâmetros correspondentes, tornando-se possível tomar decisões quanto ao critério de escolha dos materiais de fricção. Além disso, contribui também para otimizar processos de melhorias neste fundamental dispositivo de segurança veicular. A expectativa direta de sistemas de frenagem é unicamente evitar acidentes de trânsito. Portanto, sistemas de freios dimensionados e operados sob criteriosas avaliações quanto aos principais parâmetros que influenciam a frenagem podem contribuir para que um sistema de freio não falhe quando

submetido a condições extremas de aplicações, como em uma frenagem de emergência.

Desta forma, o desenvolvimento de redes neurais para prever o comportamento do sistema de freio quanto às variáveis resposta estudadas pode contribuir para obter as configurações ideais dos parâmetros de operação dos sistemas de freios. Pode contribuir, no contexto da Engenharia de Produção, para a redução do tempo e recursos gastos com ensaios para o desenvolvimento de materiais de atrito. Buscar-se-á, então, o estudo e validação da aplicabilidade do uso de RNA para modelar os parâmetros de operação do banco de freios analisado.

## 2. Breve Revisão Bibliográfica sobre o problema

### 2.1. Inteligência Computacional e Redes neurais artificiais

Pham e Pham (2001) salientam que a Inteligência Computacional (IC) aplicada à manufatura refere-se às pesquisas dentro da IA que envolvem modelagem de sistemas reais considerados inteligentes. Trata-se de uma área do conhecimento que se inspira no funcionamento do cérebro humano, utilizando-se técnicas que buscam o processo de treinamento como forma de tornar possível o processo de tomada de decisão automático semelhante aos dos seres humanos. Vem sendo empregada, por exemplo, no controle e previsão de variáveis em processos de manufatura e operação através da utilização de redes neurais artificiais (RNA) (EFE, 2011).

De acordo com Corrar, Paulo e Filho (2012) a técnica de RNA é útil quando há a necessidade de se reconhecerem padrões a partir do acúmulo de experiência ou de exemplos, e cuja representação é complexa. Uma rede neural é capaz de “aprender” a partir de exemplos. Trata-se de um modelo de processamento de dados que emula uma rede de neurônios biológicos, capaz de recuperar rapidamente uma grande quantidade de dados e reconhecer padrões baseados na experiência. São sistemas que se adaptam utilizando uma abordagem de processamento distribuído, no qual os neurônios se comunicam por meio de uma rede de elos interconectados.

Segundo Corrar, Paulo e Filho (2012) as redes neurais são compostas pelos chamados neurônios artificiais, que representam os elementos processadores, interligados entre si. Elas lembram o cérebro humano em dois sentidos:

- A rede é capaz de aprender a partir de informação captada em seu ambiente;
- Ela é capaz de guardar o conhecimento adquirido, por meio da força da conexão entre os neurônios.

Como as RNAs têm a capacidade de aprender e guardar conhecimento adquirido, elas têm sido utilizadas principalmente no reconhecimento de padrões baseados na experiência, tanto para realizar as classificações, como para fazer previsões.

### 2.2. Regra de Aprendizado por Retropropagação (*Backpropagation*)

Segundo Matsunaga (2012) o algoritmo Backpropagation procura achar iterativamente a mínima diferença entre as saídas desejadas e as saídas obtidas pela rede neural, com o menor erro possível. Busca ajustar os pesos entre as camadas através da retropropagação do erro encontrado em cada interação. Trata-se de um dos tipos de treinamento supervisionado, em que a rede é analisada em duas situações, tanto na sua propagação (camada por camada) quanto, e principalmente, na sua retropropagação (movimento contrário à propagação). Na primeira, os pesos sinápticos  $w_{ji}$  (que conecta a saída do neurônio  $i$  à entrada do neurônio  $j$ )

da rede são todos fixos. No segundo, os pesos são todos ajustados.

Ainda de acordo com Matsunaga (2012), um padrão de entrada é fornecido como um estímulo aos elementos da primeira camada da rede que é propagado por cada uma das outras camadas até a geração da saída  $a$ . Em seguida, esta saída é comparada com a saída desejada  $a_d$ , gerando um sinal de erro  $e$  para cada elemento de saída. Tal sinal de erro é retropropagado da camada de saída para cada elemento da camada intermediária anterior que contribui diretamente para a formação da saída. Porém, cada elemento da camada intermediária recebe apenas uma fração proporcional do sinal do erro total referente à contribuição relativa de cada elemento na formação da saída original. Este processo se repete em todas as camadas até o instante em que cada elemento da rede recebe um sinal de erro que descreva sua contribuição relativa para o erro total. A partir do sinal de erro recebido, os pesos sinápticos são então atualizados para cada elemento, de tal forma que a rede possa convergir para o valor de saída desejada  $a_d$ . A Figura 1 ilustra o princípio de funcionamento do algoritmo *Backpropagation*.

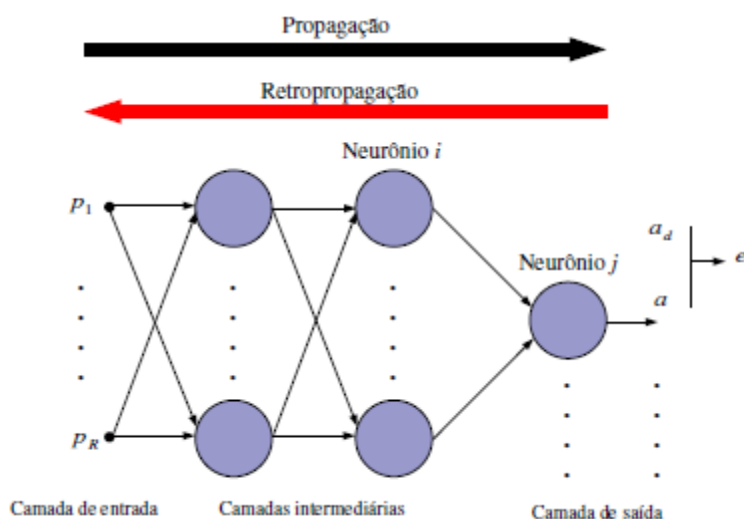


Figura 1: Algoritmo Backpropagation.

De acordo com Luger (2013) os neurônios em uma rede multicamadas, como na Figura 1, estão conectados em camadas, com unidades de uma camada  $n$  passando as suas ativações apenas para neurônios da camada  $n+1$ . O processamento de sinais em múltiplas camadas significa que os erros no interior da rede podem se espalhar e evoluir em formas complexas e imprevisíveis por meio das camadas sucessivas. A retropropagação fornece um algoritmo para atribuir aos neurônios a sua parcela de culpa pelo erro da rede e ajustar os pesos de forma correspondente.

### 3-Materiais e Métodos

#### 3.1. Descrição do banco de ensaios

A montagem do banco de ensaios buscou reproduzir os mesmos efeitos produzidos em uma motocicleta comercial de baixa cilindrada. O sistema de freio utilizado corresponde ao de uma motocicleta com as seguintes características: motor de 4 tempos, refrigerado a ar, 125 cc de cilindradas, potência de 11,8 cv a 6800 rpm, torque de 0,816 Kgf.m a 6000 rpm. A Figura 2 ilustra o banco de ensaios elaborado para este experimento. Optou-se por conduzir um estudo relacionado ao setor de motocicletas pela representatividade do setor e pelos prováveis

ganhos em termos de segurança e conforto que aperfeiçoamentos no sistema de frenagem podem proporcionar aos condutores e passageiros de motocicletas. O banco de ensaios foi equipado com um motor elétrico de 3 cv de potência.




Figura 2: Perspectiva do banco de ensaios

Optou-se por conduzir os ensaios utilizando-se a norma existente para automóveis (ABNT NBR 6143/1995) para o caso de motocicletas, tendo em vista que o princípio básico de funcionamento para os dois sistemas de freios a disco serem similares. A obtenção da força de frenagem foi obtida por meio de um dinamômetro projetado especificamente para os experimentos, representado pela Figura 3, baseado no princípio de funcionamento de uma alavanca. Para medição da força produzida pela alavanca utilizou-se uma célula de carga *Electronic Scale*, com resolução de 2,5gf, com capacidade de até 40kgf.

Para monitorar a velocidade de rotação do disco, foi utilizado um tacômetro eletrônico da marca Cycle Computer. A escolha de tal mecanismo justificou-se pelo mesmo apresentar baixo custo e ser capaz de medir rotações de até 999 rpm, o que atende bem à exigências da norma adotada ( $660 \pm 10$  rpm). A temperatura do disco foi obtida por meio de um pirômetro digital com sistema infravermelho de captura da marca *Infrared Thermometer*. As medições foram feitas na região do disco de freio imediatamente após a área de contato da pastilha, conforme Figura 4. A temperatura registrada será aquela de maior valor encontrado, sendo a medição realizada continuamente durante a frenagem.




Figura 4: mecanismo para obtenção da força tangencial.



Figura 4: região de medição da temperatura.

### 3.2. Procedimento de Ensaio

De acordo com a norma utilizada, o procedimento de ensaio de frenagem deve ser realizado da seguinte forma:

- Cada frenagem deve ter duração de 5 segundos;
- O intervalo de tempo entre frenagens, ou seja, com o freio desaplicado, deve ser de 10 segundos;
- Um ciclo de frenagem é constituído por 10 frenagens. O ensaio é composto por 10 ciclos, totalizando 100 frenagens.

### 3.3. Fatores e respostas analisadas

Os ensaios foram realizados utilizando-se 2 tipos diferentes de pastilhas – um par de pastilhas “assentado”, que foi utilizado em uma moto similar, e um par de pastilhas “novo”. Foram utilizados dois tipos de discos de freio – um disco classificado como “novo” e o mesmo disco com redução de 10% da espessura, dito disco “assentado”. O disco foi usinado por torneamento para alcançar tal nível de assentamento. Utilizou-se também duas pressões pneumáticas diferentes para acionamento da manete de freio: 0,10 MPa e 0,15 MPa, que geram pressões hidráulicas médias de acionamento do êmbolo do cilindro de freio de, respectivamente, 0,24 MPa e 0,47 MPa. A Tabela 1 apresenta a descrição de cada fator de controle manipulado em dois níveis no experimento. Tal arranjo experimental caracteriza um Planejamento Fatorial  $2^3$ . Utilizou-se o software Minitab 17 para gerar o experimento e sua sequência aleatorizada de realização dos mesmos.

Fatores Controláveis	Nível -1	Nível +1
X1: Tipo de Disco	Assentado	Novo
X2: Tipo de Pastilha	Assentada	Nova
X3: Valor da Pressão	0,10 MPa	0,15 MPa

Tabela 1: Níveis dos fatores Controláveis.

Foram analisadas 5 variáveis de resposta: temperatura final, coeficiente de atrito, desaceleração, momento da força de frenagem e pressão de contato pastilha/disco, conforme pode ser observado na Tabela 2. Para o coeficiente de atrito, desaceleração, momento da força de frenagem e pressão de contato, quanto maiores forem os seus valores melhor, uma vez que proporcionam maior efetividade durante a frenagem. Para a temperatura final, quanto menor o seu valor melhor, uma vez que o sistema de freio fica menos sujeito a perdas de eficiência devido a efeitos térmicos, como, por exemplo, o *fade*.

Variável Resposta	Unidade
Y1: Temperatura	[°C]
Y2: Coeficiente de atrito	[-]
Y3: Desaceleração	[m/s]
Y4: Momento da Força	[N.m]
Y5: Pressão de contato	[Pa]

Tabela 2: Níveis dos fatores Controláveis.

### 3.4. Modelo de RNA para predição

Foi utilizado o software *Qwiknet* V.2.23, que é um software específico para redes neurais, para treinamento e predição de um conjunto de dados coletados. Foram adotados os seguintes parâmetros de rede: Taxa de aprendizado=0,1 e Momentum=0,0. Os resultados obtidos são apresentados na seção 4.

## 4. Resultados

### 4.1. Rede Neural Qwiknet V2.23

Segundo Gongalves (2014) a Rede Neural executada no Qwiknet V.2.23 é chamada de “*Multilayer Perceptron*”, que é uma rede composta de diversas camadas. De acordo com Xavier (2003) esta rede neural foi concebida para resolver problemas mais complexos, os quais não poderiam ser resolvidos pelo modelo de neurônio básico. Para isto são necessárias mais conexões, os quais só existem em uma rede de perceptrons dispostos em camadas. Ainda de acordo com Xavier (2003), os neurônios internos são de suma importância na rna, pois foi provado que a falta destes inviabiliza a resolução de problemas linearmente não separáveis. Essa rede é composta por várias unidades de processamento, em que o funcionamento é simples. Essas unidades normalmente são conectadas por canais de comunicação que estão associados a determinado peso. As unidades fazem operações somente sobre seus dados locais, recebidas pelas suas conexões. Desta forma, o comportamento inteligente de uma rna vem das interações entre as unidades de processamento da rede.

Xavier (2003) salienta que a maioria dos modelos de rna está vinculado a alguma regra de treinamento, de tal forma que os pesos de suas conexões são ajustados de acordo com os padrões apresentados. Assim, a rede neural é capaz de extrair regras básicas a partir de dados reais. As arquiteturas das rna’s normalmente são organizadas em camadas, que são classificadas em três grupos: camada de entrada, responsável por receber os padrões; camadas intermediárias, onde ocorre a grande parte do processamento; camada de saída, responsável por concluir o resultado final e apresentá-lo.

O programa Qwiknet V.2.23 permite uma relação flexível e intuitiva que permite projetar, treinar e testar redes neurais em um ambiente gráfico. Ainda de acordo com tal autor, o software apresenta as seguintes características:

- *Learning rate*: a taxa de aprendizado controla a taxa à qual a rede aprende. De uma maneira geral, quanto mais alta a taxa de aprendizado, mais rápido a rede aprende. Entretanto, se a taxa de aprendizado é muito alta, a rede pode ficar instável.
- *Momentum*: este parâmetro controla a influência da última mudança de peso na atualização de peso atual. Normalmente, resulta em uma aprendizagem mais rápida, mas pode causar instabilidade em alguns casos se for muito grande.
- *Weights*: os campos Mínimo e Máximo permitem ao usuário fixar os mais baixos e as mais altas variâncias.

Neste estudo, no processo de criação dos neurônios artificiais foi utilizado o algoritmo denominado *On Line Backprop – Rand*, uma variação do algoritmo retropropagação. Neste, a propagação de informação através da rede ocorre da seguinte forma: os valores de entrada são transmitidos de uma camada para a outra e transformados através de pesos de conexões entre os neurônios. A Figura 5 ilustra este processo.




Figura 5: Elementos do processo – algoritmo *On Line Backprop – Rand*

O tipo de função combinação utilizada foi a soma ponderada, em que cada entrada  $x$  é multiplicada por seu respectivo peso ( $W$ ) e esses produtos são somados, chegando-se a um único valor ( $Y$ ), que representa o total das entradas ponderadas por seus pesos conforme a equação 1.

$$Y_j = \sum_j^n X_i \cdot W_{ij} \quad (1)$$

A função ativação utilizada foi a logística ou sigmóide, representada pela equação 2, que é uma função não linear.

$$\text{sigmóide} = \frac{1}{1+e^{-x}} \quad (2)$$

Sendo  $x$  o resultado da função combinação, obtido anteriormente em  $Y_j$ . Já a função transferência foi utilizada somente como forma de transferir o valor da função ativação conforme o parâmetro limiar lógico. A Figura 7 representa o processo de aprendizagem.

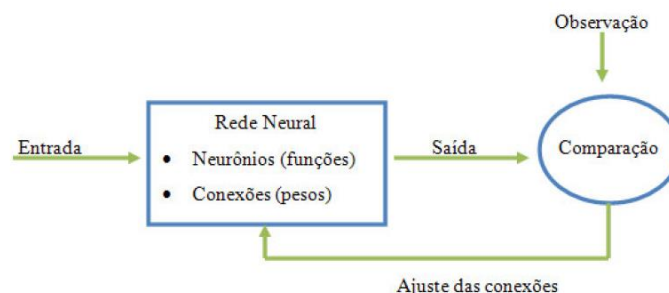


Figura 7: Processo de Aprendizagem da RNA.  
Fonte: adaptado de Gonçalves (2014).

De acordo com Corrar *et al.* (2012) dependendo do software utilizado, é necessário que os dados passem por um processo de padronização. Por causa das funções utilizadas no processamento dos dados, a rede trabalha melhor com valores que estejam entre zero e um. Para isso, neste trabalho utilizou-se a seguinte forma de cálculo de padronização, representado pela equação 3.

$$y = \frac{(y_0 - y_{min})}{(y_{max} - y_{min})} \quad (3)$$

Onde  $y_0$  é o valor a normalizar;  $y_{max}$  e  $y_{min}$  são valores mínimos e máximos entre os valores reais das variáveis.

A preparação dos dados de entrada para treinamento consistiu na criação de uma planilha contendo as 8 combinações referentes ao Planejamento de Experimentos 2<sup>3</sup>. As três variáveis de entrada são manipuladas em dois níveis cada. Cinco variáveis de saída são analisadas: temperatura, coeficiente de atrito, desaceleração, momento da força de frenagem e pressão de contato. Desta forma, todos estes dados foram submetidos às fórmulas de normalização, onde são obtidos os dados padronizados. Em seguida, este dados são formatados em arquivo tipo texto, no formato que o software é capaz de fazer a leitura e compreensão, conforme supracitado. Desta forma, após a padronização dos dados, o arquivo é submetido ao software. Em seguida, seleciona-se a opção “*Training Data*” para selecionar o arquivo de dados a serem treinados. Alguns parâmetros importantes, tais como a função de ativação, critérios de parada e algoritmo de treinamento, são selecionados. Nota-se que o software reconheceu as instâncias [INPUTS] e [OUTPUTS] corretamente, indicando 3 entradas e 5 saídas. Após realizar o treinamento, submete-se a rede ao treinamento, conforme Figura 7. Nesta figura estão representados, também, a configuração dos parâmetros de treinamento da rede, como taxa de aprendizado, momentum, bem como os critérios de parada do algoritmo selecionado.



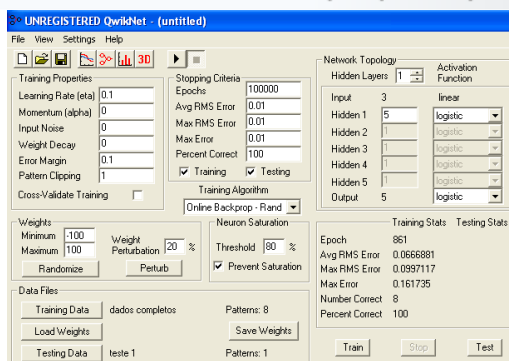


Figura 7: Interface do software utilizado

Já a Figura 8 representa a rna utilizada neste estudo. Os quadrados representam as entradas e os círculos os neurônios da camada intermediária e de saída. Neste estudo, optou-se por utilizar cinco neurônios na camada oculta. Conforme pode ser visto nesta figura, a rede obteve 100% de acerto em seu processo de treinamento para as instâncias analisadas. Representa uma rede *Perceptron* multicamada com realimentação, onde os sinais de saída da camada intermediária são realimentados para a mesma camada intermediária, mesmo procedimento ocorre para os sinais de saída da camada neural de saída. Assim, por intermédio do processo de realimentação, as redes com este tipo de arquitetura produzem as saídas atuais levando-se também em consideração os valores das saídas anteriores. Segundo Silva, Spatti e Flauzino (2010), um dos destaques mais relevantes das redes neurais artificiais está na capacidade de aprender a partir da apresentação de amostras (padrões) que exprimem o comportamento do sistema, sendo que, sem seguida, após a rede ter aprendido o relacionamento entre as entradas e saídas, esta é capaz de generalizar soluções. A rede será então capaz de produzir uma saída próxima daquela esperada (desejada) a partir de quaisquer sinais inseridos em suas entradas. O conjunto desses passos ordenados visando o treinamento da rede é denominado de algoritmo de aprendizagem. Ao longo de sua aplicação, a rede será então capaz de extrair características discriminantes do sistema a ser mapeado por intermédio de amostras que foram retiradas de seu contexto.




Figura 8: Configuração da RNA

A Figura 9 representa o Histórico de treinamento da RNA utilizando o algoritmo *Back-Propagation Rand*. Foram necessárias 861 épocas para se obter 100% de acerto para as

diferente combinações analisadas. Obteve-se erro máximo de 0,1617 e um erro quadrático médio (rms) de 0,0666. A Figura 10 ilustra a evolução do erro RMS com o tempo de treinamento. Como era de se esperar, à medida aumenta o número de interações, o erro rms diminui.

```

Training History
File Help

*****QwikNet_Training_History_Follows*****

*** Tue Oct 31 15:57:40 2017
Epochs          1 - 861
Train_algorithm  Online Back-Propagation (Randomize)
Learning_Rate    0.1
Momentum         0
Input_Noise      0
Weight_Decay     0
Final_RMS_error  0.0666881
Final_Max_error  0.161735
Training_data_file C:\Documents and Settings\Rafael\Desktop\Redes Neurais Qwiknet 10-10-2017\Novos dados
    
```

Figura 9: Resultado do treinamento da Rede Neural.

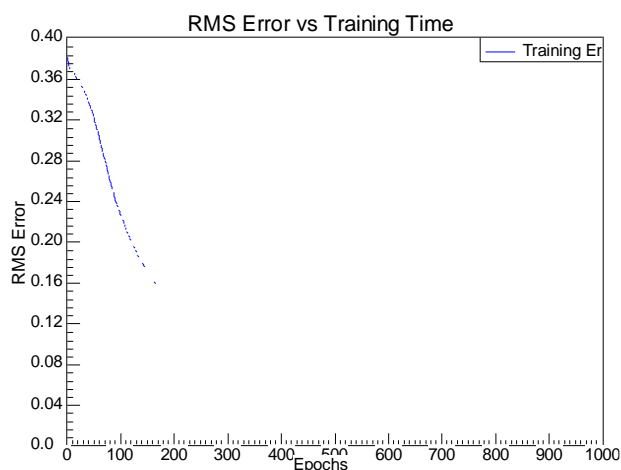


Figura 10: Gráfico do erro RMS para treinamento da RNA

A Figura 10 ilustra o processo de treinamento e erro da Rede Neural conforme o número de épocas, apresentando parada baseada na margem de erro estabelecido, após 861 épocas. Em seguida, gravou-se esses pesos da rede (parâmetros necessários para futuras utilizações desse treinamento). Nesse ponto, tem-se uma rede neural treinada para responder qualquer entrada, dentro dos limites estabelecidos, para prever o comportamento das variáveis resposta analisadas neste estudo.

#### 4.1.1. Teste da Rede Treinada

Após realizar o treinamento da rede, é possível utilizá-la com outros conjuntos de dados como forma de se realizar a predição das variáveis resposta relativas ao desempenho do sistema de freio. Selecionou-se uma das combinações não utilizadas para treinamento com o intuito de avaliar a capacidade de predição da mesma. Para inserir estes dados no software é necessário apertar o ícone “Testing Data” na tela principal e selecionar o arquivo. O software solicita também o número de entradas e de saídas do conjunto de dados de treinamento. O processamento ocorre com o clique no ícone “Test”, que solicita um nome de arquivo para inserir as saídas obtidas pela rede. A Tabela 3 apresenta os resultados obtidos.

Variável resposta analisada	Temperatura [°C]	Coefficiente de atrito [-]	Desaceleração [m/s <sup>2</sup> ]	Momento da Força [N.m]	Pressão de contato [Pa]
Valor obtido no ensaio	99,71	0,29	3,6	12,86	181238,03
Valor estimado pela RNA Qwiknet	99,97	0,29	3,3	12,87	199582,32
Diferença (%)	0,26	-0,49	-8,33	0,04	10,12

Tabela 3: Resultados da predição obtidos pelo software Qwiknet.

Para a rna obtida utilizando-se o software Qwiknet V2.23, o modelo foi submetido a um processo de predição de cinco variáveis resposta de vital importância para a operação e manufatura de sistemas de freios. Analisando-se os resultados ilustrados pela Tabela 3, o modelo apresentou ótimos valores de predição para as variáveis resposta temperatura, coeficiente de atrito e momento da força de frenagem, cujo desvio do valor predito em relação ao valor real do ensaio foi inferior a 1%. Já para as variáveis resposta desaceleração e pressão de contato, a diferença obtida entre os valores predito e real foi de, respectivamente 8,3 e 10,12%.

## 5. Conclusão

O presente estudo buscou aplicar técnicas de inteligência artificial, especificamente redes neurais artificiais, em sistemas de freio veicular, como forma de prever o comportamento do sistema de freio quanto às variáveis resposta estudadas e para obter as configurações ideais dos parâmetros de operação dos sistemas de freios. O estudo consistiu em coletar dados em um banco de ensaios desenvolvido por Pinto (2014). Três variáveis de entrada foram manipuladas, a saber: tipo de disco, tipo de pastilha e pressão de acionamento da manete de freio. Já como variáveis resposta, foram analisadas: temperatura, coeficiente de atrito, desaceleração, momento da força de frenagem e pressão de contato pastilha-disco.

Após a coleta de dados, o próximo passo foi a criação da rna. Neste estudo, optou-se por utilizar o software Qwiknet V2.23 (específico para rna). Em seguida, foi necessário configurar a rede. Esta etapa envolveu a organização da rede para que fosse compatível com o problema que buscou-se resolver.

Com a rede configurada, e os pesos devidamente ajustados, realizou-se o processo de treinamento da rede, obtendo-se uma taxa de acerto de 100% para as combinações experimentais utilizadas como padrões de treinamento. Para tanto, foram necessárias 861 épocas.

Na etapa de testes, o modelo apresentou capacidade de predição satisfatória, sendo que a diferença máxima entre os valores preditos e experimentais foi 10,12%. Como sugestão para trabalhos futuros, como forma de minimizar os erros obtidos e as incertezas relativas ao banco de ensaios, recomenda-se a realização de experimentos com mais réplicas de cada combinação experimental e melhorar o processo de medição de variáveis (obtenção de instrumentos mais precisos).

Desta forma, este estudo contribui para a redução do tempo e recursos gastos com ensaios para o desenvolvimento de materiais de atrito, bem como para a melhoria do desempenho em termos de projeto, manufatura e operação de sistemas de freios veiculares.

## Referências

ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS, Rio de Janeiro NBR 6143:1995 – *Pastilha do Freio a disco – Determinação do atrito e desgaste através da bancada de ensaio Krauss.*

**CORRAR, L. J., PAULO, E., FILHO, J. M. D.** *Análise Multivariada Para Os Cursos De Administração, Ciências Contábeis e Economia*. Editora Atlas, 2012.

**EFE, M. O.** *Background of neurocontrol*. In: Wilamowski, B. M.; IRWIN, J. D. *Industrial electronics handbook: inteligente systems*. 2. edition, part II, chapter 1, CRC Press, 2011

**GONÇALVES, F. M.** *Ferramentas para Análise de Autogestão e Sustentabilidade do Uso de Água em Perímetros Irrigados*. Tese de Doutorado – Programa de Pós-Graduação em Engenharia Agrícola – Departamento de Engenharia Agrícola – Universidade Federal do Ceará, 2014.

**LEITE, W. O.** *Modelagem e Otimização de Desvios em Peças Termoformadas a Vácuo Utilizando Modelos de Regressão Múltipla e Redes Neurais Artificiais*. Tese de Doutorado. Programa de Pós Graduação em Engenharia de Produção, Universidade Federal de Minas Gerais, 2015.

**LUGER, G. F.** *Inteligência Artificial*, 6. Ed. – São Paulo: Pearson Education do Brasil, 2013.

**MAKRAHY, M. M., GHAZALY, N. M., ABD EL-GWWAD, MAHMOUD, K. R., ABD-EL-TAWWAB, A. M.** *Optimization of Operation Parameters on a Novel Wedge Disc Brake by Taguchi Method*. *American Journal of Vehicle Design*, v. 1, n. 2, pp. 30-35, 2013.

**NEIS, P.D.** *Projeto e Construção de um Tribômetro com Controle Independente da Temperatura do Disco*. Tese de D.Sc., – Programa de Pós-Graduação em Engenharia Mecânica – Universidade Federal do Rio Grande do Sul, 2012.

**PHAM, D. T.; PHAM, P. T. N.** *Computational intelligency for manufacturing*, In: QWang, J. et al. (ed). *Computational intelligence in Manufacturing handbook*. 1. Edition, part I, Boca Raton: CRC Press, LCC, 2001. ISBN 0-8493-0592-6.

**PINTO, R.L.M.** *Análise de variáveis que influenciam no desempenho de frenagem veicular através de ensaios baseados na metodologia de Krauss*. Dissertação de Mestrado em Engenharia de Produção, Universidade de Federal de Minas Gerais, Belo Horizonte, 2014.

**RUSSEL, S. J., NORVIG, P.** *Inteligência Artificial*. Tradução Regina Cecília Simille – Rio de Janeiro: Elsevier, 2013.

**SANDERS, P.G., DALKA, T.M., BASH, R.H.** *A Reduced-Scale Brake Dynamometer for Friction Characterization*. *Tribology International*, v. 34, pp. 609-615, 2001.

**SARIP, S.B.** *Lightweight Friction Brakes for a Road Vehicle with Regenerative Braking* Thesis of D. Sc., School of Engineering Design and Technology of the University of Bradford – England, 2011.

**SILVA, I. N., SPATTI, D. H., FLAUZINO, R. A.** *Redes Neurais Artificiais; para Engenharia e ciências aplicadas* – São Paulo: Artliber, 2010.

**XAVIER, E. A.** *Aplicação de Inteligência Artificial Computacional na Gerência de Redes Através da Automação do Uso de Agentes Móveis*. Dissertação de Mestrado. Programa de Pós-Graduação em Ciência da Computação – Universidade Federal de Santa Catarina, 2003.