

Aplicação de redes neurais para tomada de decisão e previsão de desgaste de rodeiros

Camila Moscibrocki^{1*}, Samuel Carlos Winiarski¹, Vinicius dos Santos Sanches¹.

¹ Departamento de Engenharia de desenvolvimento ferroviário, Rua Emílio Bertolini, 100 - Cajuru, 82920-030, Curitiba - Paraná.

e-mail: camila.moscibrocki@rumolog.com, samuel.winiarski@rumolog.com, vinicius.sanches@rumolog.com.

Resumo: O desgaste de rodeiros em locomotivas de carga é um problema recorrente em ferrovias ao redor do país e do mundo. A previsão assertiva deste desgaste impacta diretamente na economia dos rodeiros, condução da composição, prevenção de descarrilamento e planejamento das intervenções de manutenção e usinagem de rodas. O objetivo deste artigo é demonstrar o potencial de aplicação de redes neurais artificiais na previsão do desgaste de rodeiros utilizando modelos autorregressivos não lineares com redes de entradas exógenas. Para tanto, uma base histórica de medições de desgaste efetuadas a partir de um perfilômetro a laser fora utilizada para perfilômetro treinar, validar e testar a rede neural. Como variáveis de entrada, o estudo utiliza perfis de roda, histórico de usinagem, tipo de truque, material e processo de fabricação, esperando-se obter como saída o desgaste da roda. A precisão da previsão do desgaste usando a rede neural foi investigada e avaliada em termos de erro percentual absoluto médio, demonstrando que a rede neural pode ser usada de forma eficaz para prever o desgaste de rodas. Os próximos passos para este trabalho serão testar a ferramenta a partir de análises em campo de campo.

Palavras-Chaves: Redes neurais, rodeiros ferroviários, Vagões.

1. INTRODUÇÃO

A análise das condições de contato da interface roda-trilho é relativamente complexa, considerando a geometria de um rodeiro ferroviário sobre os trilhos e sua distribuição não uniforme das forças normais e tangenciais [1].




Fig.1 Forças distribuídas na interface roda-trilho [1].

Diferentes níveis de desgaste podem ocorrer em diferentes pontos na roda e no trilho, onde a previsão do desgaste da roda é um processo complexo, considerando a quantidade de variáveis envolvidas para sua formulação. A manutenção e substituição de rodeiros representam alguns dos principais custos de funcionamento de uma ferrovia, demandando o desenvolvimento de mecanismos de análise do desgaste do contato roda-trilho, os quais vem sendo aperfeiçoados através de métodos experimentais e numéricos.

Dentre estes métodos, as redes neurais e outras técnicas de aprendizado de máquina vem sendo utilizadas com o intuito de prever o comportamento de desgaste dos rodeiros para otimização de processos na ferrovia [1] e para avaliação do projeto do sistema de suspensão dos vagões. Estas técnicas de

aprendizado também têm sido amplamente aplicadas em diversas áreas para otimizar tarefas como programação de manutenção, conforme apresentado na sequência.

Segundo Khudhair [2] uma rede neural de retropropagação é capaz de prever o desgaste de revestimentos de aço banhado com cromo. Para tanto, utilizou-se variáveis como velocidade de deslizamento, carga e tempo de teste para alimentar o modelo de rede neural, obtendo a taxa de desgaste como saída. Os resultados da simulação utilizando o modelo de retropropagação mostram que o desgaste previsto foi próximo ao desgaste real com um coeficiente de correlação de 0,99. Sendo considerado um resultado satisfatório, o estudo concluiu que redes neurais podem ser consideradas uma excelente ferramenta para previsão de desgaste.

Já para Pit, a utilização de uma rede neural para predição de desgaste de trilhos [3] demonstrou-se deficiente na ausência de uma base robusta de dados. Para tanto, fora estudado experimentalmente o comportamento ao desgaste de trilhos bainíticos sem carboneto a partir da modelagem de uma rede neural que utiliza dados da British Steel Swinden Technology Center. Essa modelagem consiste na tentativa de produzir um modelo empírico útil para a previsão do desgaste do trilho, tendo como entradas a dureza do trilho, microestrutura do trilho, dureza da roda, microestrutura da roda e tensão de contato. A saída da rede neural foi a taxa de desgaste do trilho, a qual não apresentou resultados satisfatórios, concluindo que a ausência de uma base robusta impediu que um modelo confiável fosse gerado, onde apenas uma pequena quantidade de dados mostrou resultados promissores.

Por fim, Singh [4] propõe a utilização de uma rede neural de retropropagação para prever o desgaste do flanco de brocas de aço rápido para fazer furos em peças de cobre. As entradas para este modelo foram a força de impulso, torque, taxa de alimentação, diâmetro da broca e velocidade do fuso, obtendo o desgaste do flanco como saídas. Utilizando uma base de dados relativamente reduzida, dos 49 conjuntos de dados obtidos no experimento, 34 foram selecionados aleatoriamente para treinamento do modelo e os 15 restantes foram usados para testar a capacidade de previsão. Os resultados da

simulação mostram que a rede neural é capaz de prever efetivamente o desgaste da broca.

2. REDES NEURAIS ARTIFICIAIS

Atualmente, as Redes neurais artificiais (RNAs) vem sendo utilizadas no cotidiano para solução de problemas complexos que envolvem um grande número de variáveis, graças a sua capacidade de aprendizado, que permite a análise e identificação da correlação de fatores. Um dos tipos de redes neurais mais simples e também amplamente utilizada são as redes neurais diretas (*feedforward*), onde a informação transita a partir da entrada da rede para as saídas, e cada camada se conecta à próxima camada sem um caminho de volta [5]. Essa estrutura permite que todas as conexões tenham a mesma direção, partindo da camada de entrada rumo a camada de saída, conforme apresentado na Fig. 2.




Fig.2 Representação gráfica de uma rede neural direta [5].

Considerando as diferentes condições de contato, esforços e variáveis externas que os rodízios ferroviários estão submetidos, opta-se neste artigo pela utilização de modelos que representem com veracidade sistemas dinâmicos não lineares [6]. A metodologia que melhor atende essa demanda são modelos autorregressivos não lineares com rede neural de entrada exógena (NARX), onde estado de um sistema dinâmico é definido como um conjunto de variáveis que descrevem a situação atual deste sistema [7]. Uma rede NARX possui uma entrada simples que é aplicada a uma linha de atrasos, formando uma memória de "q" elementos, os quais se orientam para uma saída realimentada na entrada através de uma outra linha de atraso de "q" elementos, representados graficamente na Fig. 3.




Fig.3 Representação gráfica de uma rede NARX [8].

A utilização da rede NARX neste artigo também se justifica graças a realimentação da saída para a entrada da rede neural direta como parte de sua arquitetura, o que permite uma fase de treinamento mais precisa, podendo ser usada para prever o desgaste em caso de novas amostras inseridas na base, sem a necessidade de retreinar a rede já consolidada. Na equação 1, pode-se observar a representação da saída de uma rede NARX:

$$y(t) = f((t - 1), u(t - 2), \dots, y(t - 1), y(t - 2) \dots W) \quad (1)$$

Conforme apresentado na equação 1, “u (t)” e “y (t)” representam a entrada e a saída da rede, “n” e “m” são a ordem da memória de entrada e de saída, “W” é uma matriz de pesos e “f” é uma função não linear [7]. A saída em “t” depende dos valores anteriores de “m”, bem como dos valores anteriores da entrada para “n”. Neste estudo, utiliza-se uma NARX de arquitetura paralela (Fig. 4).

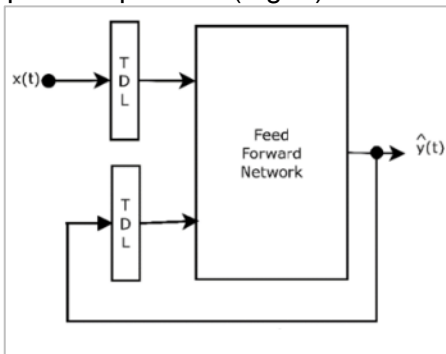


Fig.4 Rede NARX paralela com retroalimentação na saída [9].

Essa modelagem permite que a saída da NARX seja realimentada para a entrada da rede, onde $u(t)$ é a entrada, $y(t)$ é a saída desejada e $\hat{y}(t)$ é a saída estimada. Essa realimentação garante uma maior precisão das saídas da rede modelada, permitindo maior aderência as condições reais as quais os rodeiros estão submetidos.

3. MEDIÇÃO DE DESGASTES DE RODEIRO

Para alimentação da rede NARX proposta, utilizou-se uma base de medições de desgaste de rodeiros composta por 360 rodeiros de primeira vida de 90 vagões graneleiros HFT e HPT da Rumo para a bitola de 1600 mm [10]. Para tanto, utilizou-se um perfilômetro Riftek IKP-5 para coleta das medidas do perfil, onde estas eram comparadas a um perfil de referência de uma roda nova K36, evidenciando as dimensões dos desgastes, conforme apresentado na fig. 5.




Fig.5 perfil de referência de uma roda nova K36 e (em verde) comparado ao perfil da roda medida em campo (em azul) [10].

Os rodeiros selecionados para este levantamento foram submetidos a uma ampla faixa de quilometragem percorrida, utilizados em variados modelos de truques em vagões novos de diferentes lotes de fabricação, com diferentes quilometragens. A tabela 1 apresenta a relação de variáveis consideradas além das medidas de perfil e desgaste.

Tabela 1. Variáveis de entrada consideradas.

Parâmetros	Variáveis
Número do vagão	Número de identificação
Data de início de operação	dd/mm/aaaa
Troca de rodeiro	Sim ou não
Tipo de truque	Ride control, ride master, motion control, barber S2HD
Tipo de roda	K36, P33, D29
Material da roda	Aço convencional ou aço microligado

Processo de fabricação da roda	Fundida ou forjada
Classe de dureza da roda	Classe C
Data de medição com o perfilômetro de rodas a laser	dd/mm/aaaa
Distância percorrida pelo rodeiro	km
Posição e lado do rodeiro no veículo	1E, 1D, 2E, 2D, 3E, 3D, 4E, 4D.

4. MODELAGEM DA REDE NARX PARA PREVISÃO DE DESGASTE DE RODEIROS

Neste artigo, a modelagem da rede NARX para prever o desgaste de rodas foi desenvolvida no MATLAB, conforme ilustrado na Fig. 6.

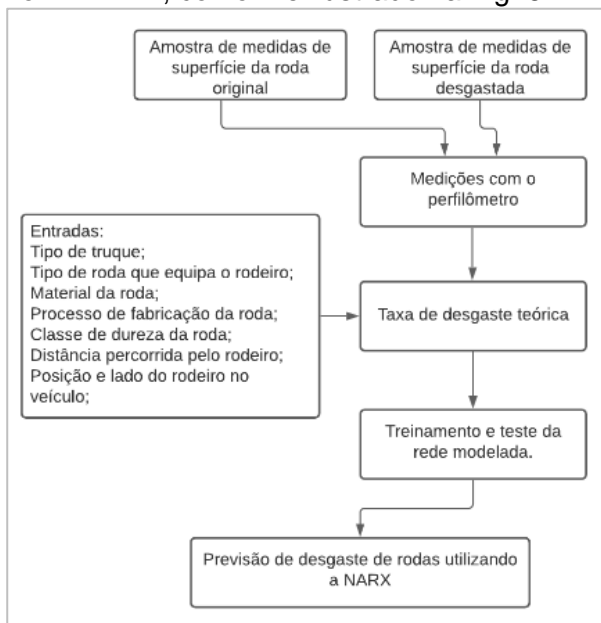


Fig.6 Estrutura básica da rede modelada.

A taxa de desgaste teórica é apresentada na equação 2:

$$T_{dt}(x) = \frac{a_d(x) - a_o}{x} + \frac{\Delta A_t(x)}{x} \quad (2)$$

Onde o primeiro termo da equação refere-se à diferença entre a altura de friso medida da roda desgastada ($a_d(x)$) e a altura de friso original da roda (a_o), divididos pela distância percorrida (x). O segundo termo refere-se à espessura mínima de aro a ser removida para o reperfilamento da roda (ΔA_t), dividido pela distância percorrida [10]. O modelo de rede neural mostrado na Fig. 6 foi usado para a previsão do desgaste dos rodeiros a partir do conjunto de dados que foi fracionado para treinamento, validação e teste da rede NARX, tendo como entradas dois conjuntos principais, sendo estes:

I. Dados de classificação coletados em campo: Tipo de truque, tipo de roda que

equipa o rodeiro, material da roda, processo de fabricação da roda, classe de dureza da roda, distância percorrida pelo rodeiro, posição e lado do rodeiro no veículo, II. Dimensões: espessura e altura do friso da roda.

A partir das 360 amostras coletadas em campo, o conjunto de dados composto por 720 leituras foi fracionado para diferentes etapas do processo, sendo 60% direcionados para treinamento da rede, 20% para validação e 20% para testes de desempenho. A previsão do desgaste de roda foi realizada usando uma rede série-paralelo. A camada oculta da rede é composta por dez neurônios, as entradas de atraso são iguais a 1: 2, bem como os atrasos de feedback. A estrutura da rede modelada pode ser visualizada no MATLAB através do comando "view(narx_net)", conforme fig. 7.




Fig.7 Visualização da rede modelada no MATLAB.

Para ativação dos neurônios que compõem a camada oculta, utiliza-se uma função de transferência que calcula a saída de uma camada a partir de sua entrada líquida [10], conforme apresentado na equação 3.

$$\text{logsig}(x) = (1 + x)^{-1} \quad (3)$$

Para treinamento da NARX, opta-se por utilizar uma função de desempenho para redução do erro entre a saída real e a saída estimada, a partir da diferença média quadrática entre os valores estimados e o valor real, utilizando o erro quadrático médio (MSE) (equação 4).

$$MSE = \frac{1}{N} \sum_{i=1}^N (e_i)^2 = \frac{1}{N} \sum_{i=1}^N (t_i - y_i)^2 \quad (4)$$

Na equação 3, " t_i " é o valor que se pretende atingir durante o processo de treinamento da rede, enquanto que " y_i " são os valores obtidos em saídas aproximadas.

5. DESENVOLVIMENTO DO ALGORITMO

Utilizando os recursos de treinamento de redes neurais do MATLAB, optou-se por efetuar primeiramente um comparativo de desempenho entre as seguintes funções de treinamento mais indicadas para este estudo: Levenberg-Marquardt; Retropropagação resiliente; e Retropropagação de taxa de aprendizagem variável. Os resultados mais aderentes e de rápida convergência se mostraram com a utilização da função de Levenberg-Marquardt (LMA), capaz de resolver problemas de quadrados mínimos não lineares. A função principal do LMA neste processo é executar o treinamento combinando o método do ponto de sela para aproximação da integral dos valores analisados e a aproximação quadrática acelerando a convergência de dados. A partir dos resultados obtidos na fase de treino, pode-se calcular a precisão das previsões realizadas através do erro percentual absoluto médio (MAPE), conforme equação 5.

$$MAPE = \frac{1}{N} \sum_{i=1}^N \frac{|A_i - P_i|}{A_i} \cdot 100 \quad (5)$$

Na equação 4, "A_i" é a saída real extraída da base de dados e "P_i" é o valor de saída previsto pelo sistema, "i" corresponde a série temporal utilizada e "N" é o número de valores observados.

Todo o processo de treinamento, validação e teste é feito na arquitetura em série paralela. Posteriormente, após a execução destas etapas, a rede é transformada em loop fechado para previsão de várias etapas à frente através do comando "price_net_closed = closeloop (price_net)", conforme a fig.8. O MAPE foi usado novamente para calcular a precisão do modelo NARX fechado usando a equação 4.




Fig.8 Visualização da rede modelada no MATLAB readequada para operação em paralelo.

Da amostra original de 360 rodeiros, 20% dos dados foram selecionados e extraídos para

validação e outros 20% para testes de desempenho, onde ambas as amostras tem a taxa de desgaste previamente calculada e serão comparadas aos cálculos de desgaste futuros dos 60% direcionados para é treinamento.

Os resultados obtidos foram divididos em dois grupos distintos, sendo o primeiro composto pelas previsões efetuadas a partir da rede paralela, e o segundo pela rede série-paralela.

1. NARX paralela:

A fig. 9 apresenta os valores obtidos para a espessura do friso considerando a distância percorrida.

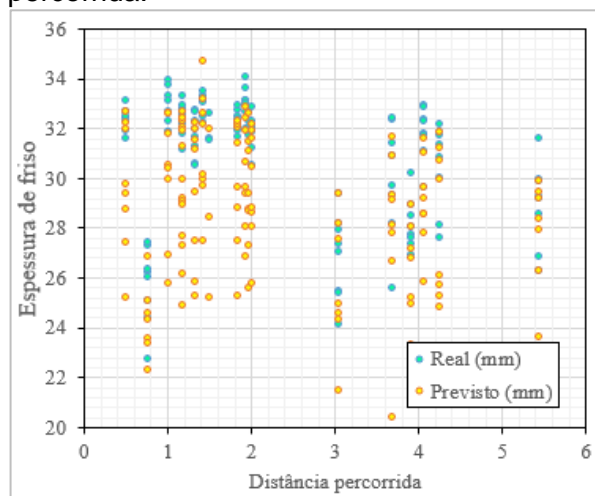


Fig.9 Gráfico comparativo entre valores reais para a espessura do friso e valores previstos pela NARX.

A fig. 10 apresenta os valores obtidos para a altura do friso considerando a distância percorrida.

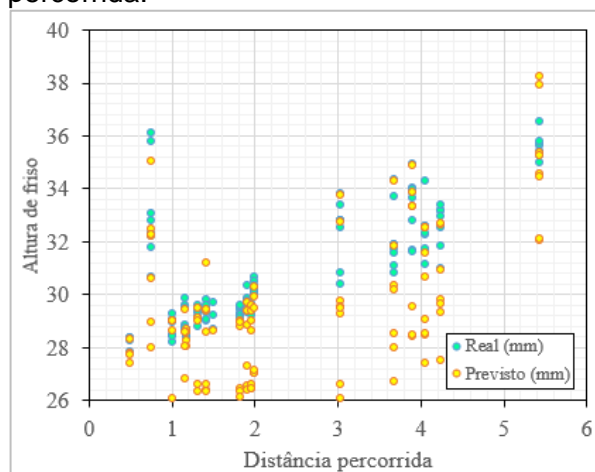


Fig. 10 Gráfico comparativo entre valores reais para a altura do friso e valores previstos pela NARX.

A fig. 11 apresenta os valores obtidos para taxa de desgaste considerando a distância percorrida

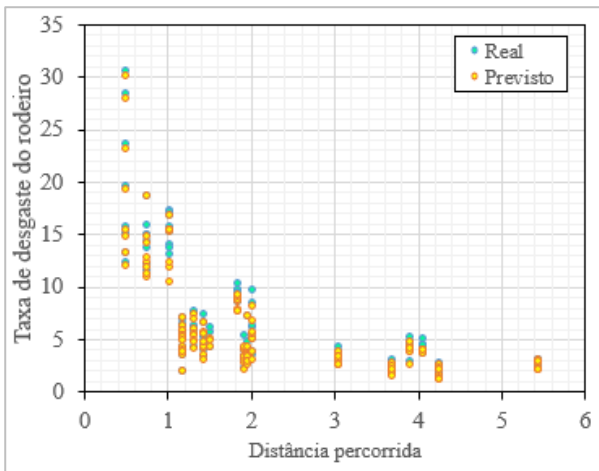


Fig. 11 Gráfico comparativo entre valores reais para a taxa de desgaste e valores previstos pela NARX.

II. NARX série-paralela:

A fig. 12 apresenta os valores obtidos para a espessura do friso considerando a distância percorrida.




Fig.12 Gráfico comparativo entre valores reais para a espessura do friso e valores previstos pela NARX.

A fig. 13 apresenta os valores obtidos para a altura do friso considerando a distância percorrida.

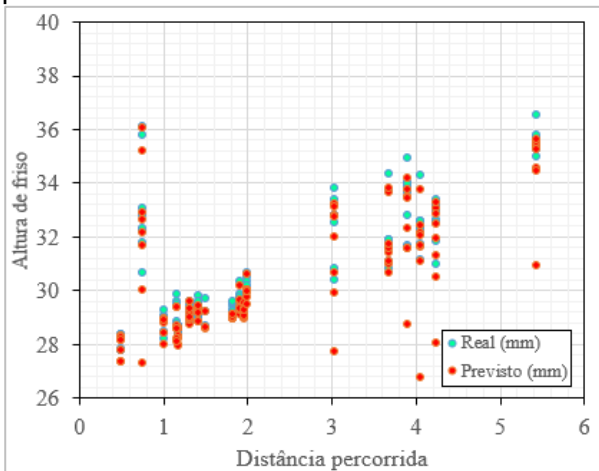


Fig. 13 Gráfico comparativo entre valores reais para a altura do friso e valores previstos pela NARX.

A fig. 14 apresenta os valores obtidos para taxa de desgaste considerando a distância percorrida

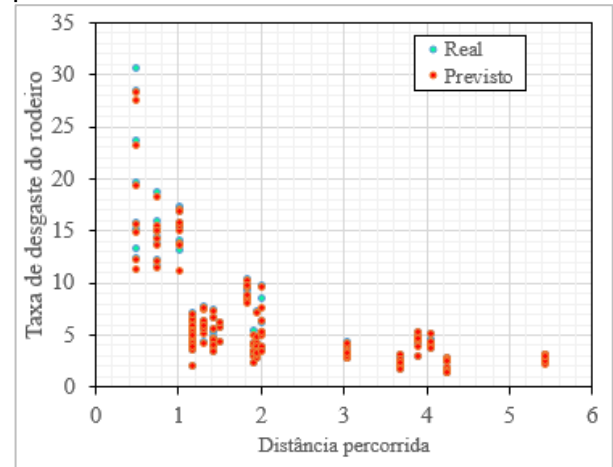


Fig. 14 Gráfico comparativo entre valores reais para a taxa de desgaste e valores previstos pela NARX.

6. RESULTADOS OBTIDOS

A partir dos resultados obtidos, o cálculo do erro MAPE entre o desgaste real e previsto da roda é apresentado na tabela 2.

Tabela 2. MAPE para previsão de desgaste de rodas.

MAPE	Desgaste
MAPE % para NARX Paralela	7,79%
MAPE % para NARX Série-paralela	2,84%

Conforme observado na tabela 2, os resultados mostram uma boa previsão do desgaste de rodas em termos de porcentagem de erro, onde o desgaste previsto pela NARX foi próximo ao desgaste real medido. A precisão da rede NARX foi entre 92,17% e 97,13%. Os resultados ideais durante o treinamento e teste da rede NARX foram obtidos com atrasos de entrada de 1: 2, atraso de feedback 1: 2 e 1 camada oculta com 10 neurônios. Os resultados mostram que o desgaste dos rodeiros pode ser previsto de maneira aderente aos dados coletados em campo usando uma rede neural. É reconhecido, entretanto, que os dados utilizados não cobrem todos os possíveis mecanismos de desgaste encontrados na operação ferroviária. Fatores como variações na carga, ângulo de guinada (Yaw) e coeficientes de atrito e variações de geometria não foram incluídas na base de dados utilizada para treino, teste e validação da rede NARX. Propõe-se que simulações e medições simultâneas através de instrumentação sejam

realizadas sobre os rodeiros, aliadas a informações de irregularidades de via e perfis de roda para uma modelagem mais precisa e aderente o possível. A fim de determinar a melhor arquitetura de rede NARX utilizada neste estudo, uma série de simulações com diferentes arquiteturas foram avaliadas. As configurações utilizadas para previsão do desgaste e comparação foram:

- 6-9-1 (6 entradas, 9 camadas ocultas e 1 camada de saída);
- 6-10-1 (6 entradas, 10 camadas ocultas e 1 camada de saída);
- 6-12-1 (6 entradas, 12 camadas ocultas e 1 camada de saída);

Nestas arquiteturas, o menor MAPE para a configuração série-paralelo foi de 2,87%, utilizando a configuração "6-10-1", bem como para configuração paralelo, apresentando 7,79%. Comumente utiliza-se o erro quadrático médio para treinamento de uma rede NARX. Porém este estudo utiliza o algoritmo de Levenberg-Marquardt como função de treinamento de rede, através da atualização dos valores de peso e viés, apresentando uma convergência mais rápida se comparada a outros métodos. Entretanto, faz-se necessário destacar que conforme o número de pesos na rede NARX aumenta, essa velocidade diminui. O processo de treinamento da rede NARX demonstrou maior eficiência após a execução das etapas de pré-processamento nas entradas e saídas esperadas.

7. CONCLUSÕES

A partir das redes NARX modeladas na arquitetura paralelo e série-paralelo, observou-se que os resultados previstos se aproximam dos valores de desgaste real, produzindo melhores resultados do ponto de vista do erro percentual absoluto médio. A precisão do modelo NARX foi entre 92,17% e 97,13% concluindo-se que uma rede neural artificial pode ser usada de forma eficiente como ferramenta de previsão de desgaste de rodas ferroviárias. Embora os parâmetros considerados tenham sido extraídos de um conjunto limitado de dados coletados em campo, o aprendizado da rede procurou incluir os principais fatores que influenciam o desgaste de rodas.

Uma ferramenta de previsão de desgaste de rodeiros, que seja precisa e aderente a realidade pode ser usada pela ferrovia na compreensão da vida útil restante das rodas e

consequentemente no planejamento de intervenções de manutenção e usinagem, podendo fazer parte de uma estratégia de manutenção preditiva para reduzir custos e melhorar a confiabilidade do processo.

8. REFERÊNCIAS

- [1] D. Milković, *Wayside system for wheel-rail contact forces measurements*, Volume 46, Issue 9, 2013, pp 3308-3318.
- [2] A. Khudhair, *Neural Network Analysis For Sliding Wear of 13% Cr Steel Coatings by Electric Arc Spraying*, Diyala Journal of Engineering, College of Engineering – University of Diyala, 2010, pp. 157-169.
- [3] C. E. Pit, *Wear and microstructure relationships in Carbide-Free Bainitic rail steels* PhD, Cambridge University, Reino Unido, 1999.
- [4] A. Singh, *Predicting drill wear using an artificial neural network*, The International Journal of Advanced Manufacturing Technology, vol. 28, 2006, pp. 456-462.
- [5] R. Quinza, *Computational Methods and Optimization*, Department of Mechanical Engineering, University of Matanzas, Machining of hard materials, 2011, pp 177-208.
- [6] D. Rocha, *Redes neurais para modelagem de sistemas estruturais offshore Dinâmicos não-lineares com histerese*, Universidade Federal do Rio de Janeiro, COPPE, 2007, 157 p.
- [7] C. Fonseca, *Rede Neural Auto-Regressiva Com Entradas Exógenas (NARX) Aplicada ao Controle de Velocidade em Veículos Elétricos*, Departamento de Engenharia da Computação e Automação (DCA) Universidade Federal do Rio Grande do Norte, 2015.
- [8] P. Engel, *Redes Neurais - Processamento Temporal por Redes Recorrentes Dirigidas Dinamicamente*, Universidade Federal do Rio Grande do Sul – Departamento de Informática, 2020, 21 p.
- [9] N. Fan, *Wheel Wear Prediction of High-Speed Train Using NAR and BP Neural Networks*, IEEE International Conference on Internet of Things and IEEE Green Computing and Communications, University of Shanghai, pp 1 – 5, 2017.
- [10] S. Winiarski, *Estudo de LCC de rodeiros de vagões rodas novas*, Relatórios técnicos de vagões, Engenharia de Desenvolvimento Ferroviário Rumo, 2019.
- [11] H. Demuth, *Neural Network Toolbox For Use with MATLAB*, The MathWorks, pp 57-144, 2004.