

# RECONHECIMENTO DE PADRÕES DE DESGASTES DE RODAS UTILIZANDO REDES NEURAIAS

**Giovanni Augusto Ferreira Dias**

Laboratório para Ensino e Pesquisa de Engenharia Ferroviária  
Instituto Militar de Engenharia – IME

## RESUMO

A utilização de redes neurais aplicada na otimização de processos no transporte ferroviário tem aumentado no decorrer das últimas décadas, principalmente em trabalhos relacionados à previsão de demanda e estudos de capacidade (Shafer, 2003). Neste Trabalho será apresentado um modelo de previsibilidade de desgastes de rodas ferroviárias, através de análise de padrões de desgastes existentes, analisado a partir de medições em tempo real. Para elaboração do sistema de reconhecimento de padrões, será utilizada uma rede neural do tipo MLP (*Multilayer Perceptron*), com o algoritmo *back-propagation*. Os resultados gerados servirão de base para elaboração do planejamento de curto, médio e longo prazo da demanda de manutenção de rodas da Estrada de Ferro Carajás, otimizando assim os custos e a alocação de recursos.

## ABSTRACT

The use of neural networks applied in optimizing processes in rail transport has increased over the last decades, especially in work related to forecast demand and capacity studies (Shafer, 2003). This work will be presented with a wear predictability model of railway wheels through existing wear patterns analysis, analyzed in real-time measurements. For preparation of the pattern recognition system, a neural network MLP type (Multilayer Perceptron) with the back-propagation algorithm is used. The results generated form the basis for preparing the short planning, medium and long term maintenance of the wheel demand Carajás Railroad, thus optimizing costs and resource allocation.

## 1. INTRODUÇÃO

A partir dos dados históricos, é possível extrair informações que permitem a modelagem matemática do comportamento de um determinado fenômeno por meio das técnicas de previsão. Segundo (Assad, 1980), um dos principais modelos para previsão de séries temporais baseia-se em métodos estatísticos, porém nos últimos anos com o avanço da inteligência artificial, surgiu uma importante técnica chamada de Redes Neurais Artificiais (RNAs). Nos modelos baseados em métodos estatísticos, utiliza-se a média móvel, suavização exponencial e regressão linear. No entanto a utilização dessas técnicas está condicionada ao um tratamento matemático dos dados e assim a construção de modelos a partir de equações matemáticas deduzidas. Dependendo da característica do fenômeno e sua observação no meio físico várias variáveis passam a ser incorporada, assim a utilização de métodos estatísticos pode não descrever o comportamento real do fenômeno, oferecendo assim dificuldades no tratamento e na busca de soluções. A utilização de método de previsão utilizando redes neurais analisa dados do passado e utiliza inteligência artificial para previsibilidade de dados futuro a partir de observações de aprendizagem do fenômeno.

Com o avanço da computação e da eletrônica, o monitoramento da condição de ativos ferroviários surgiu como uma solução para aumento de produtividade e disponibilidade de

equipamentos, avançando assim a implantação da manutenção preditiva nas grandes corporações.


Para o planejamento manutenção preditiva condicional, faz-se necessário a implantação de bancos de dados ricos em detalhes para suportar a tomada de decisão, através de monitoramento contínuo e cálculos de tendência a partir de observações on-line. Neste contexto aplica-se a manutenção de rodéis da EFC (Estrada de Ferro Carajás) que atualmente possui uma frota de aproximadamente 18.000 vagões, totalizando 144.000 rodas que circulam diariamente nas operações de transporte de carga pela malha ferroviária. Devido um grande volume de ativos circulantes é necessário um gerenciamento da condição de circulação e integridade dos ativos para garantir a segurança operacional e redução de custos de manutenção. Para fundamentar essa estratégia, a EFC utiliza o conceito de manutenção por condição, onde diariamente as rodas têm seu desgaste monitorado em tempo real para tomada de decisão de retirada do ativo para manutenção imediata, oferecendo maior segurança nas operações. Neste trabalho será utilizado os dados de desgaste monitorado em tempo real, para elaboração de um modelo de predição, oferecendo dados para suporte a tomada de decisão em curto, médio e longo prazo em relação ao planejamento de material, mão de obra e alocação de recursos, visando otimização de processo, redução de custos e aumento de disponibilidade de ativos.

## 2. REDES NEURAIS ARTIFICIAIS

Redes Neurais Artificiais são modelos computacionais inspirados no sistema nervoso de seres vivos. Possuem a capacidade de aquisição e manutenção de conhecimento e podem ser definidas como um conjunto de unidades de processamento, sendo as mesmas representadas por vetores/matrizes de pesos sinápticos (Silva, 2010).

As Redes Neurais Artificiais tem sido empregadas com sucesso para resolver problemas diversos e de características gerais, tendo uma grande área de aplicação. Entre as aplicações mais usuais têm-se: reconhecimento e classificação de padrões, controle, agrupamento e aproximação de funções (Haykin, 1999) (Silva, 2010).

Na Figura 1 é mostrado um modelo básico de uma RNA, onde cada neurônio é representado por uma esfera, e as camadas são mostradas pelo conjunto de esferas conforme identificação em sequência, onde a primeira camada é chamada de entrada que é responsável pela recepção dos dados que serão processados pela RNA, a camada oculta onde é feito o primeiro processamento e a última camada consiste na saída, esta camada recebe informações da camada oculta e é a responsável pelo processamento dos dados, gerando assim o resultado da rede para que seja informado ao meio externo.




**Figura 1:** Modelo Básico de uma rede Neural Artificial (Dias, 2014)

O treinamento de uma rede neural artificial é o processo para ajustar os pesos das camadas, de forma que a saída da rede coincida com o valor desejado para uma determinada entrada. Um dos algoritmos mais utilizados em treinamento de redes neurais artificiais é o *Backward Error Propagation* este algoritmo utiliza o método do gradiente descendente para minimizar o Erro Quadrático Médio (EQM) de saída da rede, sendo classificado como um aprendizado por correção de erro (SILVA, 2010).

Atualmente existem vários tipos de redes neurais, porém neste trabalho discorreremos sobre o tipo MLP, (do inglês, *Multilayer Perceptron*), ou *Perceptron* de Múltiplas Camadas, são redes com camadas intermediárias entre a camada de entrada e a camada de saída. Essa arquitetura é constituída por uma ou mais camadas ocultas, formadas por neurônios computacionais, também chamadas de neurônios ocultos, cuja função é de intervir entre a camada de entrada e a saída da rede de uma forma útil.

A Figura 2 mostra um modelo gráfico de uma rede neural artificial tipo MLP.



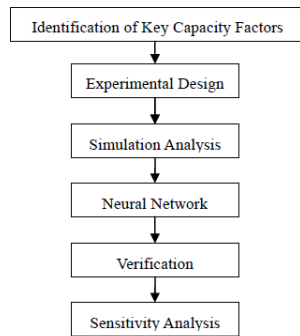
**Figura 2:** Rede Neural Artificial MLP (Multicamada) (Dias, 2014)

### 3. APLICAÇÃO DE REDES NEURAIS NO TRANSPORTE FERROVIÁRIO


A utilização de redes neurais aplicada ao transporte ferroviário vem sendo explorada a partir do desenvolvimento da inteligência artificial (Assad, 1980), porém o grande enfoque da aplicação surgiu a partir 1993, com o trabalho de (David, 1993), onde realizou a aplicação de uma rede neural para otimização de operação ferroviária. Em 2000 com o trabalho (Sibaie, 2000) utilizou a teoria de redes neurais na simulação de desempenho dinâmico de um carro de passageiro circulando em uma via com falha de geometria, com o objetivo de mapear potenciais pontos de descarrilamentos.

Para estudo de capacidade o trabalho de (Huang, 2012), aplicou um modelo baseado em redes neurais para simulação do trafego ferroviário em uma ferrovia Norte Americana, o modelo proposto foi analisado e construído de acordo com o fluxograma ilustrado na Figura 3.

A construção do modelo baseou-se em uma ferrovia com trecho duplicado, onde os dados de entrada foram velocidade média, espaçamento entre pátio e tamanho de trens. Os dados de saída foram à capacidade de trens por dia. A Figura 4 ilustra o dimensionamento e capacidade de trens baseado nos dados de velocidade média.

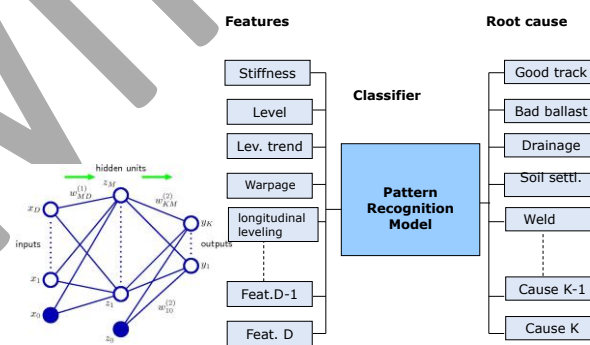


**Figura 3:** Desenvolvimento do processo para estudo de capacidade (Huang, 2012)



**Figura 4:** Capacidade de trens por dia em função da velocidade média entre pátios (Huang, 2012)

Tem-se diversas aplicações de redes neurais na área de manutenção ferroviária, o trabalho de (Berggren, 2011), utiliza um modelo de predição de falhas na via permanente utilizado dados do carro controle tais como : rigidez, empeno, nivelamento e etc., com o objetivo de mapear a origem da falha (solda, drenagem, lastro etc.). A Descrição do modelo é ilustrada na Figura 5.



**Figura 5:** Modelo reconhecimento de padrões de falhas de via permanente. (Berggren, 2011)

#### 4. ESTRATÉGIA DE MANUTENÇÃO DE VAGÕES NA EFC

Atualmente, a oficina vagões na EFC utiliza a estratégia preventiva e corretiva de manutenção. Sendo que a partir de 2013 foi implantado a CBM (*Condition Based Maintenance* - Manutenção Baseada em Condição), objetivando oferecer maior

disponibilidade de ativos e redução de custos. A Figura 6 mostra os tipos de manutenção conforme estratégia do plano diretor.



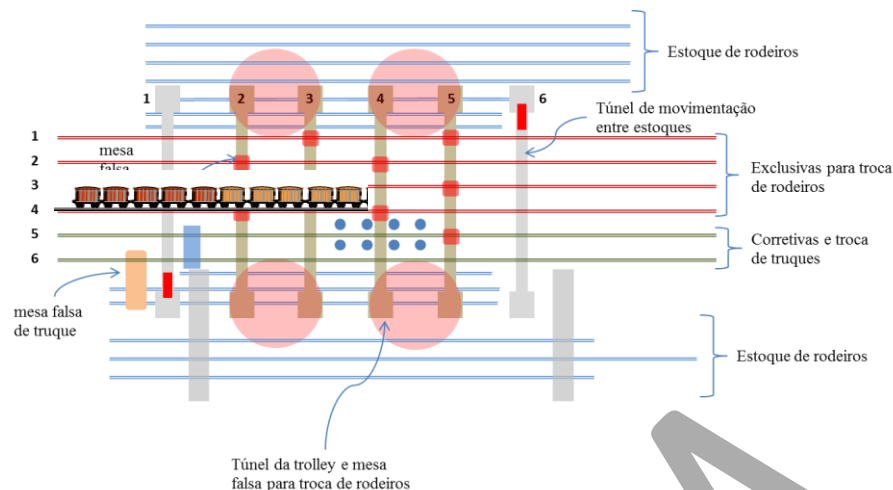
**Figura 6:** Estratégia de Manutenção de Vagões da EFC

A Manutenção condicional tem como balizador o sistema de rodeiro, ou seja, consiste na usinagem das rodas, quando o vagão atinge determinado valor de desgaste removendo o veículo de circulação, o monitoramento do desgaste nas rodas é realizado em tempo real através de sensores instalados ao longo da ferrovia, onde o monitoramento é realizado diariamente pela equipe de engenharia de confiabilidade e inspeção de vagões. A Tabela 1 mostra os itens a serem mantidos para cada tipo de manutenção.

**Tabela 1:** Estratégia de Manutenção da Frota de Minério

	TIPO	FREQUÊNCIA	FLEXIBILIDADE	DESCRIÇÃO
PLANOS DE MANUTENÇÃO	Vagões com Truque Adaptado Frame Brace Truques Motion Control e standard	Condicional	-----	Substituição dos rodeiros, truques e sapatas de freio, inspeção e qualificação dos componentes
	MPVM02	72 MESES	(+/-) 7,2 MESES	Substituição obrigatória do conjunto de choque e tração, Truques e Rodeiros.
	PLANO DE FREIO - MPVM01	12 meses	De 11 até 15 meses	Inspeção, limpeza e teste de freio.
	PLANO DE FREIO - MPVM02	Conjugado com o plano MPVM02	Conjugado com o plano MPVM02	Substituição do conjunto de válvulas, cilindro e ajustador.
	PLANO DE ROLAMENTO	36 MESES	3,6 MESES	Recondicionamento de rolamentos cartuchos e caixa de graxa

A partir de julho/2016 a manutenção passará a ser realizada por lote de 110 vagões, ou seja, caso um rodeiro de determinado vagão apresentar desgaste de roda, o lote completo de 110 vagões passará por uma área de *Pit-Stop*, onde apenas o rodeiro com desgaste deverá ser trocado, após a troca o lote completo deverá ser devolvido para a circulação, por questões operacionais o lote deverá permanecer estacionado no CTR (Central de Troca de Rodeiros), por aproximadamente 2 horas, onde neste intervalo poderá executar outros serviços de manutenção. A Figura 7 ilustra o layout do CTR bem com a estratégia de manutenção por lote.




**Figura 7:** Manutenção por lote de vagões

## 5. MONITORAMENTO EM TEMPO REAL DE RODAS FERROVIÁRIA


Atualmente para suportar a estratégia de manutenção por condição, a EFC adquiriu um sistema capaz de realizar medições dinâmicas de diversos parâmetros do rodeiro ferroviário, durante a sua circulação, na literatura técnica este sistema é chamado de Wayside ou supersite (Dias, 2011).

A partir das informações coletadas, é possível analisar as condições do equipamento para prever possíveis falhas e defeitos que podem ocorrer em um futuro próximo ou distante. Isto torna mais fácil planejar as atividades de manutenção. Atualmente o conjunto de sensores do sistema está instalado no KM 16+888 da EFC.

O Sistema de Medição e Diagnóstico de Rodas *Wheelspec* é um instrumento de medição automático da secção transversal da roda que proporciona medições em alta velocidade e sem contato das rodas do vagão operando em velocidades até 100 km/h. Conforme ilustração da Figura 8. Os dados de medição das rodas são transferidos a um arquivo do sistema de computadores depois que o trem tenha passado, fornecendo dados básicos de 6 parâmetros de medição do perfil do rodeiro, de acordo com a Figura 9.




**Figura 8:** Medições em tempo real




**Figura 9:** Medições em tempo real

## 6. METODOLOGIA

Para elaboração deste trabalho varias etapas foram executadas com o objetivo de analisar e fundamentar a proposta de aplicação de redes neurais no sistema ferroviário, a Figura 10, ilustra de forma detalhada de cada etapa da metodologia e a Figura 11 a topologia do sistema de monitoramento de desgaste.



**Figura 10:** Fluxograma da Metodologia Aplicada

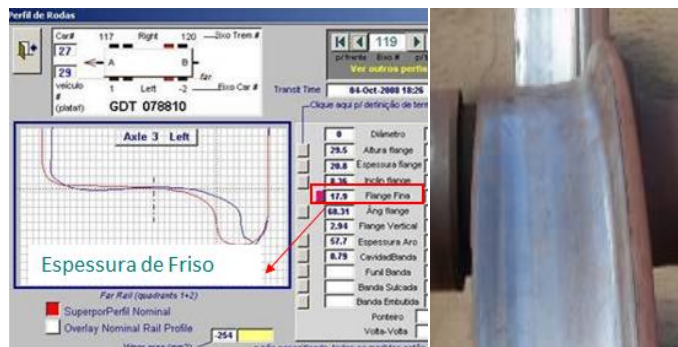


**Figura 11:** Visão Geral da metodologia.

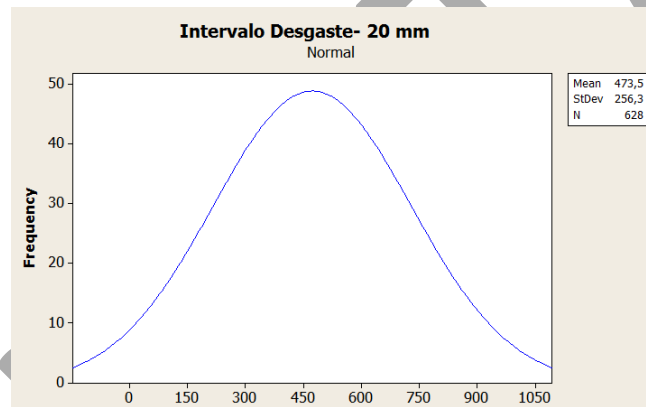
Após a definição do escopo do trabalho, resultados e objetivos que se deseja alcançar, a próxima etapa refere-se à coleta de dados. Para este trabalho utilizou-se os dados em tempo real de medição dinâmica de rodas utilizando o sensor *wheelspec*, conforme já comentado na seção 6. Para cada veículo temos 8 rodeiros, considerando vagões que transportam minério, para cada roda será realizado a coleta da medida espessura de friso conforme ilustração da Figura 12.

O intervalo de coleta corresponde a vagões retirados de circulação entre os meses de Outubro/2014 a Março/1015, devido à medida da espessura do friso está abaixo do padrão adotado pela EFC, a quantidade de vagões monitorados foram 628 vagões com vários

intervalos de desgaste diferentes medidos em dias, conforme distribuição normal ilustrado na Figura 13.



**Figura 12:** Medição de espessura de friso



**Figura 13:** Distribuição Medição de espessura de friso.

Observa-se que pela distribuição existem vários intervalos diferentes para o desgaste em dias, gerando período de coleta diferente para cada intervalo, conforme Tabela 2.

**Tabela 2:** Coleta de dados

Classe em Dias	Quantidade Vagões	Intervalo Medições (Dias)	Medições
[0-60[	28	3	24
[60-120[	23	5	24
[120-180[	34	8	24
[180-240[	42	10	24
[240-300[	109	12	24
[300-360[	44	15	24
[360-420[	101	17	24
[420-480[	14	20	24
[480-540[	13	22	24
[540-600[	30	25	24
[600-660[	29	27	24
[660-720[	32	30	24
[720-780[	44	32	24
[780-840[	21	35	24
[840-900[	26	37	24
[900-960[	38	40	24

O objetivo da padronização é equalizar para todos os intervalos quantidade de medições iguais gerando uma matriz padronizada para construção da RNA. Após a coleta e análise de



dados, inicia-se a etapa de construção da rede neural para treinamento dos dados. A RNA adotada neste trabalho é do tipo MLP onde utilizará o algoritmo *backpropagation* através de simulações do programa MATLAB.

### 7.1 Dados de entrada e saída da RNA

Para elaboração da etapa de treinamento da RNA escolheu-se os dados de 502 vagões, totalizando 96193 dados referente a 8 rodas de cada vagão com 24 medições para cada veículo. A Tabela 3 mostra a quantidade de dados utilizados.

**Tabela 3: Dados para Treinamento da Rede.**

Classe em Dias	Quantidade Vagões	Intervalo Medições (Dias)	Medições	Rodeiros por medida	Quantidade medições	Dados Treinamento
[0-60[	28	3	24	8	5376	4300
[60-120[	23	5	24	8	4416	3532
[120-180[	34	8	24	8	6528	5222
[180-240[	42	10	24	8	8064	6421
[240-300[	109	12	24	8	20928	16472
[300-360[	44	15	24	8	8448	6758
[360-420[	101	17	24	8	19392	15513
[420-480[	14	20	24	8	2688	2150
[480-540[	13	22	24	8	2496	1996
[540-600[	30	25	24	8	5760	4608
[600-660[	29	27	24	8	5568	4454
[660-720[	32	30	24	8	6144	4915
[720-780[	44	32	24	8	8448	6758
[780-840[	21	35	24	8	4032	3225
[840-900[	26	37	24	8	4992	3993
[900-960[	38	40	24	8	7296	5876

Após a definição dos dados de treinamento foi elaborando a matriz de treinamento com os dados de entrada conforme Figura 14.

	Medição 1 (mm)				Dias	Medição 2 (mm)				Dias	Medição 24 (mm)				Dias
	R1	R2	. . .	R8		R1	R2	. . .	R8		R1	R2	. . .	R8	
Vagão 1	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
Vagão 2	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
Vagão 100	R1	R2	. . .	R8	Dias	R1	R2	. . .	R8	Dias	R1	R2	. . .	R8	Dias
.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
Vagão 200	R1	R2	. . .	R8	Dias	R1	R2	. . .	R8	Dias	R1	R2	. . .	R8	Dias
.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
.	.	.	.	.	.	.	.	.	.	.	.	.	.	.	.
Vagão 502	R1	R2	. . .	R8	Dias	R1	R2	. . .	R8	Dias	R1	R2	. . .	R8	Dias

**Figura 14: Matriz de dados de entrada.**

Os dados de saída da RNA corresponde ao intervalo em dias de cada medição, conforme ilustração da Figura 15.

	Dias (data atigimento limite retirada - Data inicio circulação)			
	R1	R2	. . .	R8
Vagão 1	.	.	.	.
Vagão 2	.	.	.	.
.	.	.	.	.
.	.	.	.	.
Vagão 100	R1	R2	. . .	R8
.	.	.	.	.
.	.	.	.	.
Vagão 200	R1	R2	. . .	R8
.	.	.	.	.
.	.	.	.	.
Vagão 502	R1	R2	. . .	R8

**Figura 15: Matriz de dados de saída.**

## 7.2 Treinamento da RNA

O próximo passo da metodologia de construção do modelo, refere-se a etapa de treinamento da RNA, onde dos 628 vagões com dados coletados foram utilizados 502, correspondendo aproximadamente 80% dos dados os outros 20% serão utilizados posteriormente na etapa de teste da RNA, para esta etapa utilizou-se a função tangente hiperbólica, onde obteve-se melhor resultado durante a simulação.

A Tabela 4 fornece os dados referente ao treinamento e assim definiu-se o número de neurônios na camada escondida.

Um parâmetro importante para configuração da RNA chama-se taxa de aprendizagem, onde foi analisado e testado considerando vários valores entre 0,05 a 0,5 o resultado é mostrado na Tabela 5.

**Tabela 4: Dados para Treinamento da Rede.**


Dados de Entrada	Neuronios na camada escondida	Interações	Dados na camada de saída	Convergência
96193	2	1000	4012	Não
96193	4	1000	4012	Não
96193	6	1000	4012	Não
96193	8	1000	4012	Não
96193	10	1000	4012	Não
96193	12	1000	4012	Não
96193	14	1000	4012	Sim
96193	16	1000	4012	Sim
96193	18	1000	4012	Sim
96193	20	1000	4012	Sim
96193	22	1000	4012	Sim
96193	24	1000	4012	Sim
96193	26	1000	4012	Sim
96193	28	1000	4012	Sim
96193	30	1000	4012	Sim

**Tabela 5: Variação da taxa de aprendizagem**

Taxa de aprendizagem	Convergencia	Interações	Tempo de Simulação(Horas)	Erro Médio
0,05	Sim	1000	12,6	0,01
0,08	sim	1000	8,04	0,012
0,1	sim	1000	2,05	0,002
0,2	sim	1000	1,04	0,0022
0,3	Não	1000	0,9	0,1
0,4	Não	1000	0,5	0,4
0,5	Não	1000	0,38	0,66

## 7. RESULTADOS

Após as simulações da etapa de treinamento, a RNA apresentou a configuração conforme ilustração da Figura 16.




**Figura 16: Configuração de RNA para reconhecimento de padrão de desgaste**

Vários testes foram realizados considerando cenários de simulação diferentes de acordo com os dados disponíveis, assim verificou pela quantidade de dados, se a RNA apresentava convergência, conforme mostra a Tabela 6.

**Tabela 6:** Configuração de RNA para reconhecimento de padrão de desgaste.

Dados de entrada (numero de vagões)	Convergencia
100 vagões	Não
200 vagões	Não
300 vagões	Não
400 vagões	Não
500 vagões	Sim
600 vagões	Sim

O comportamento da rede após a convergência apresentou um erro médio quadrático de aproximadamente 0,0002 conforme Figura 17.



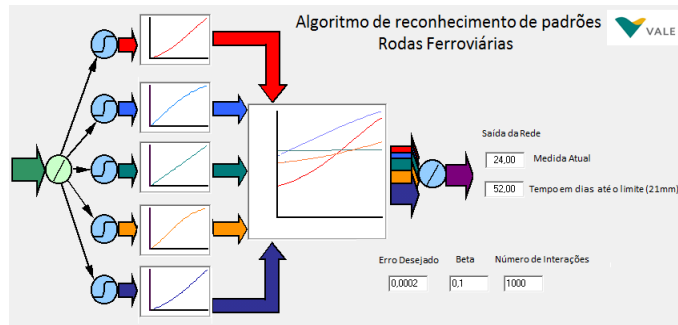
**Figura 17:** Erro médio Quadrático.

Na fase de teste da RNA, foram utilizados os 20% dos dados não utilizados na fase de treinamento correspondendo a 24383 dados para teste referente a 126 vagões.

**Tabela 7:** Teste de convergência da RNA

Classe	Média Resultado Rede	Média Resultado Real	Erro em dias
[0-60[	3	6	3
[60-120[	4	5	1
[120-180[	3	4	1
[180-240[	2	2	0
[240-300[	1	1	0
[300-360[	1	1	0
[360-420[	2	2	0
[420-480[	2	4	2
[480-540[	1	3	2
[540-600[	2	3	1
[600-660[	8	4	4
[660-720[	3	3	0
[720-780[	4	8	4
[780-840[	3	10	7
[840-900[	2	7	5
[900-960[	2	9	7

Com a finalização da construção do modelo a estrutura do simulador é ilustrada na Figura 18.



**Figura 18:** Simulador para reconhecimento de padrões.

Estima-se com a utilização deste simulador a redução do intervalo médio de entrada do lote de vagões na central de troca de rodeiros, visto que calculando a previsibilidade de desgaste será possível utilizar toda a capacidade do sistema substituindo os rodeiros com o tempo menor até o atingimento do desgaste, otimizando a estratégia de manutenção e aumentando a vida útil da roda ferroviária, a Tabela 19 ilustra a projeção de ganhos em relação a vida útil de rodas, estimado em 28%. Considerando um horizonte de 5 anos a redução de rodas sucateadas sairá de um patamar de 15.000 rodas para 10.800 rodas.

**Tabela 8:** Aumento da vida útil de rodas

	Situação Atual	Cenário 1
Vida em Meses	49,41	63,63
Vida Media (Km)	742000	955913

## 8. CONCLUSÕES

Este trabalho apresentou a aplicação de um modelo de reconhecimento de padrões de desgaste de rodas ferroviárias, onde no decorrer deste artigo, verificaram-se as etapas necessárias para construção do modelo.

A partir do simulador construído foi possível determinar o limite em dias até a roda atingir o parâmetro limite de desgaste com uma diferença máxima de 11 dias entre o simulado e o real, oferecendo a área de planejamento suporte na tomada de decisão.

Como contribuição principal deste trabalho, propõem-se a aplicação de redes neurais no processo de manutenção e usinagem de rodas ferroviária, apresentando ao planejador dados que permitem a realizar a programação mais otimizada reduzindo os custos de manutenção e aumentando à disponibilidade de ativos.

## 9. AGRADECIMENTOS

Para realização deste trabalho agradecemos primeiramente a Deus, aos familiares pelo apoio, ao supervisor Yuri Vieira e o gerente Ricardo Schmitt pela acreditar no meu trabalho e proporcionar esta oportunidade, a Valer pelo patrocínio durante a realização da especialização e a todos os colegas de classe da VALE e MRS.

## REFERENCIAS

- Assad, A. (1980). Modeling of rail networks: toward a routing/makeup model. *Transpn. Proc. Instn Mech. Engrs.*
- Berggren, E. G. (2011). Efficient Track Maintenance - Methodology for Combined Analysis of Condition Data. International Heavy Haul Association.
- Braga, A. P., & Carvalho, A. C. (2007). *Redes Neurais Artificiais: teoria e aplicações*. Rio de Janeiro: LTC.
- David, R. T. (1993). *Optimization of Railway Operations Using Neural Networks*.
- Dias, G. A. (2014). Estudo Comparativo de técnicas de desvios de obstáculos dinâmicos em robótica móvel. São Luis: Universidade Federal do Maranhão.
- Haykin, S. (1999). *Neural Network – A Comprehensive Foundation* (2 ed.). Prentice-Hall.
- Huang, Y.C. L.A. (2012). Artificial neural network modeling of Railway Capacity. 14 th Internacional conference on Computing in Civil and Building Engineering, 12.
- Shafer, D. C. (2003). A Hybrid Logistic Regression/Neural Network Model for the Prediction of Broken. *Proc. Instn Mech. Engrs.*
- Sibaie, M. (2000). Computer Model Developed to Predict Rail Passenger Car Response to Track Geometry. FRA – Federal Railroad Administration.
- Silva, I. N. (2010). *Redes Neurais Artificiais para engenharia e ciências aplicadas*. São Paulo: Artliber.