

# APLICAÇÃO DE REDES NEURAIAS ARTIFICIAIS PARA DIAGNÓSTICO E CONTROLE DE DEFEITOS DE BITOLA EM VIA PERMANENTE FERROVIÁRIA

**Itamar Souza**

itamar\_souza@yahoo.com.br

**Giovane Quadrelli**

giovane.quadrelli@ucp.com.br

**Roberto Yung**

fyung.roberto@gmail.com

**Tiago Nazaré**

tiago\_bit@yahoo.com.br

**Ricardo Nunes**

ricardomodugno@gmail.com



*A indústria ferroviária é pautada por elevada movimentação de cargas e altos custos associados à manutenção das condições operacionais, destacando-se a proporção de custos para manutenção da via permanente em relação aos demais componentes de material rodante. Além disso, as condições da ferrovia mudam na medida que a própria operação ferroviária acontece. Nesse contexto, as sistemáticas de detecção de anomalias de maneira precoce é o grande objetivo de todo aparato de inspeção existente e implementado nas ferrovias. Essas inspeções acontecem desde times realizando rondas a pé com detecção visual de defeitos até a utilização de carros controles com elevada tecnologia embarcada com sistemas de câmeras, lasers, GPS e unidades de processamento de dados com algoritmos voltados para os mais diversos propósitos. Dentre os defeitos existentes, o defeito de bitola é objeto de estudo dessa pesquisa e a proposição da utilização de um algoritmo baseado em Redes Neurais Artificiais para a auto-organização dos blocos defeituosos é o resultado gerado, que se mostrou com elevado potencial para contribuir para a elaboração de escopos preventivos de manutenção na medida em que viabiliza a identificação de locais com condições propícias ao surgimento dos defeitos mesmo sem que o defeito esteja instalado e as tolerâncias nas medidas definidas para a classe de via de manutenção e operação ainda não tenham excedido aos patamares definidos para o local inspecionado.*

*Palavras-chave: Redes Neurais, Ferrovia, Defeito de bitola, manutenção, Mapas Auto-Organizáveis*

## 1 Introdução

É crescente o uso de aplicações baseadas em inteligência artificial para aumentar a capacidade das corporações para a interpretação de grandes volumes de informações e transformá-las em ações que permitam o aumento na efetividade no uso dos recursos e redução dos custos globais para operação e manutenção dos sistemas produtivos.

Este artigo apresentará os principais aspectos relacionados à defeitos de bitola em empresas ferroviárias, os mecanismos de inspeção e práticas de manutenção comumente adotadas e fará a proposição de uma metodologia baseada em Redes Neurais Artificiais, que permite facilitar a identificação da degradação dos componentes e ampliar a efetividade dos escopos de manutenção preventiva nesses locais antes de figurarem defeitos que geram ônus à operação ferroviária (falhas que levam à redução de velocidade dos trens ou mesmo acidentes ferroviários).

Essa pesquisa não possui a finalidade de discutir quais os melhores materiais para se utilizar na via permanente (por exemplo, dormentes de madeira, polímero, aço ou concreto) e não qualificará as práticas de manutenção desses componentes nas ferrovias. A velocidade de degradação de cada local inspecionado pelo veículo de inspeção não será impedimento para a criação da metodologia contemplada por este artigo.

Assim, devido ao fato de a velocidade de degradação não ser um fator de estudo, a metodologia proposta por esse artigo é definida de modo a não ser relevante a tonelagem das cargas dos locais avaliados pois baseia-se no monitoramento das medidas críticas de seus parâmetros de Engenharia, tornado o método mais valioso e com maior poder de generalização para as demais ferrovias.

A MRS Logística, concessionária responsável pela operação ferroviárias nos estados de MG, RJ e SP, por exemplo, apresenta em sua demonstração de caixa relativa ao período de 2017 um lucro líquido base caixa de R\$1.585,9 milhões. Na mesma publicação, são apresentados os gastos globais com Manutenção, que totalizaram R\$751,8 milhões (MRS Logística, 2018).

Os projetos relacionados à expansão, confiabilidade de infraestrutura e modernização de via permanente totalizam R\$ 374,8 milhões, 49,8% do total alocado para a manutenção como um todo.

É nesse contexto que se abre espaço para novas abordagens a gestão dos ativos de via permanente, em que qualquer ação que culmine no aumento da frequência de intervenção e substituição de cada componente gera impacto direto no caixa da empresa, sendo convertido

em ganho real de receita.

O processo de gestão da manutenção de via permanente ainda possui grande interferência da subjetividade na determinação dos escopos de manutenção. Essa subjetividade pode ser associada à ausência ou não utilização de métodos e técnicas voltadas para a identificação objetiva de anomalias e pela baixa capacidade para interpretação e análise dos dados gerados pelos veículos de inspeção (carros controle).

Nesse trabalho serão colocados em evidência os defeitos de bitola ferroviária, modo de falha característico das ferrovias e que está diretamente associado à redução da vida útil dos dormentes devido ao caráter corretivo de seu tratamento quando as tolerâncias extrapolam os limites permitidos pelas características do projeto de via e exigências operacionais em termos de velocidade e carga por eixo transportada. Como citado anteriormente, será apresentada um método para identificação e direcionamento dos planos de manutenção baseado nas medidas obtidas por carro controle para bitola carregada e bitola sem carga.

Devido às características do problema apresentado, esse trabalho terá como abordagem a pesquisa quali-quantitativa. Por se tratar da análise de questões de interesse prático relacionados aos defeitos de bitola ferroviária e para o aperfeiçoamento das sistemáticas de manutenção de uma via férrea, trata-se de uma pesquisa de natureza aplicada. Com base nos objetivos desse estudo, trata-se de uma pesquisa exploratória, pois caracteriza problemas específicos que poderão ser extrapolados para o âmbito das demais ferrovias a partir de procedimentos estruturados a partir da pesquisa de campo. Cabe ressaltar que essa pesquisa possui procedimentos de caráter experimental, pois analisa a influência das variáveis relacionadas à variação da bitola da via férrea.

## **2 Revisão da Literatura**

### **2.1 Redes Neurais Artificiais e a ciência dos dados**

Segundo (LIN & LEE, 1996), Redes neurais artificiais (RNAs) são sistemas que são deliberadamente construídos para fazer uso de alguns princípios organizacionais semelhantes aos do cérebro humano. Eles representam a nova geração promissora de sistemas de processamento de informações. As RNAs são boas em tarefas como correspondência e classificação de padrões, aproximação de funções, otimização, quantização vetorial e agrupamento de dados, enquanto os computadores tradicionais, por causa de sua arquitetura, são ineficientes nessas tarefas, especialmente tarefas de correspondência de padrões. No entanto, os computadores tradicionais são mais rápidos em tarefas computacionais algorítmicas e operações aritméticas precisas.

Um diagrama esquemático de um neurônio biológico típico é mostrado na Figura 1. A Figura 2 mostra um modelo matemático simples do neurônio biológico mencionado acima, proposto por (McCULLOCH & PITTS, 1943), geralmente chamado de neurônio M-P. Neste modelo, o elemento  $i$  de processamento calcula uma soma ponderada de suas entradas e saídas  $y_i = 1$  (disparo) ou 0 (não dispara) de acordo com o fato de essa soma de entrada ponderada estar acima ou abaixo de um certo limite  $\theta_i$ :

$$y_i(t + 1) = a\left(\sum_{j=1}^m w_{ij}x_j(t) - \theta_i\right),$$

onde a função de ativação  $a(f)$  é uma função de etapa unitária:

$$a(f) = \begin{cases} 1, & \text{se } f \geq 0 \\ 0, & \text{caso contrário.} \end{cases}$$




Figura 1 - Diagrama esquemático de um neurônio biológico




Figura 2 - Diagrama esquemático de um neurônio de McCulloch e Pitts.

Em resumo, uma RNA é uma estrutura de processamento de informação distribuída paralelamente com as seguintes características (LIN & LEE, 1996):

1. É um modelo matemático inspirado na estrutura de um neurônio.
2. Consiste em muitos elementos de processamento altamente interconectados.
3. Suas conexões (pesos) preservam o “conhecimento”.
4. Um elemento de processamento pode responder dinamicamente ao seu estímulo de entrada, e a resposta depende completamente de sua informação local; isto é, os sinais de entrada chegam ao elemento de processamento através de conexões de impingir e pesos de conexão.
5. Ele tem a capacidade de aprender, recordar e generalizar a partir de dados de treinamento, atribuindo ou ajustando os pesos de conexão.
6. Seu comportamento coletivo demonstra o poder computacional e nenhum neurônio individual carrega informações específicas (propriedade de representação distribuída).

## 2.2 Mapas Auto-Organizável (SOM - *Self-Organizing Map*)

Mapas auto-organizados aprendem a agrupar dados com base na semelhança, topologia, com uma preferência (mas nenhuma garantia) de atribuir o mesmo número de instâncias a cada

classe. São usados tanto para agrupar dados quanto para reduzir a dimensionalidade dos dados. Eles são inspirados pelos mapeamentos sensoriais e motores no cérebro dos mamíferos, que também parecem organizar automaticamente as informações topologicamente (The MathWorks, Inc., 2018).

O Mapa Auto-Organizável é um processo de regressão não-paramétrico não supervisionado para representar dados não-lineares e de alta dimensão em uma exibição ilustrativa de baixa dimensão. Os pontos de dados de entrada são mapeados para unidades de auto-organização (unidades SOM) em uma grade geralmente unidimensional ou bidimensional. O mapeamento é aprendido a partir das amostras de dados de treinamento por um processo de aprendizado estocástico simples, onde as unidades SOM são ajustadas por pequenos passos com relação aos vetores de recursos que são extraídos dos dados e apresentados um após o outro (em ordem aleatória) (Kohonen, 1982) (Kohonen, 1995) (Kohonen, Hynninen, Kangas, & Laaksonen, 1996).


### **2.3 Via Permanente Ferroviária**

O transporte ferroviário exige grande controle dos parâmetros de confiabilidade de seus ativos. Dentre eles, destaca-se a importância da Via Permanente para todo o sistema. Segundo (COIMBRA, 2008), A ferrovia é composta por diversos subsistemas dos mais complexos possíveis que possuem influência no processo produtivo, pois interferem diretamente na confiabilidade, qualidade e segurança do mesmo.

Um dos subsistemas de maior importância e fundamental para a operação de uma ferrovia é a Via Permanente.

Segundo (RIVES, L., & PUENTE, 1977), a Via Permanente é constituída por duas vigas metálicas contínuas longitudinais denominadas trilhos, fixados aos apoios transversais espaçados regularmente, denominados dormentes que compõem a grade, que repousam sobre um colchão amortecedor de material granular, denominado lastro que por sua vez, absorve e transmite ao solo as pressões correspondentes às cargas suportadas pelos trilhos (Figura 3).

Figura 3 - Constituição da Via Permanente




Fonte: (RIVES, L., & PUENTE, 1977) adaptado de (BRINA, 1979)

## 2.4 Bitola


De maneira simplificada, (PORTO, 2004) define bitola como a distância entre os trilhos é uma característica da via e é denominada bitola (Figura 4). Uma via, entretanto, pode ter mais de um tipo de bitola, permitindo que seja utilizada por mais de um tipo de trem (Figura 5). Padronizou-se no mundo bitolas de 1.0m, 1.435m e 1.6m, sendo que a tolerância no tamanho da bitola varia em função do país, da organização ferroviária e da velocidade da via.

Figura 4 – Bitola Ferroviária – medida entre boletos dos trilhos de uma mesma via.



Fonte: (PORTO, 2004)

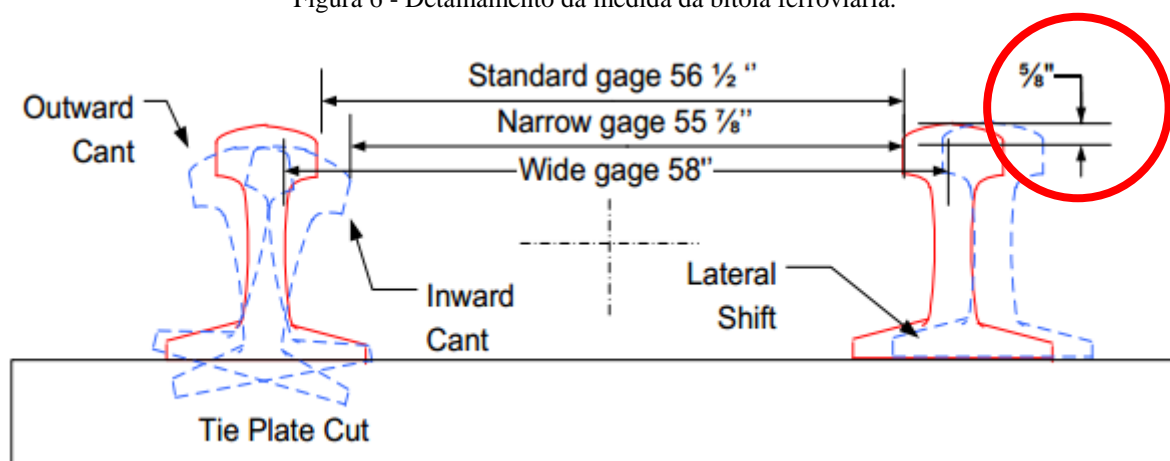
Figura 5 - Exemplo de bitola mista. Bitola larga ( $b_1$ ) e bitola estreita ( $b_2$ ).



Fonte: (PORTO, 2004)

A bitola ferroviária possui alterações ao longo da vida útil dos componentes e do resultado de seu desgaste. Segundo a FRA (Federal Railroad Administration, 2017), bitola é a medida entre os boletos dos trilhos nos ângulos ajustados a partir dos trilhos em um plano de 5/8 de polegada abaixo do topo do boleto.

Figura 6 - Detalhamento da medida da bitola ferroviária.



Fonte: (Federal Railroad Administration, 2017)

A ferrovia onde esta pesquisa é realizada adota uma variação da tabela de defeitos da FRA para determinação da velocidade média aplicável a cada trem em função da geometria da ferrovia:

Tabela 1 - Classes de Via e tolerâncias para velocidades de circulação

Parâmetro	Classe 01	Classe 02	Classe 3	Classe 4	Classe 5
Bitola estática (sem carga)	38 mm	32 mm	32 mm	25 mm	25 mm
Bitola dinâmica (carregada)	45 mm	39 mm	39 mm	32 mm	32 mm
Vel. Média Autoriza (km/h)	0 – 16	17 – 40	41 – 64	65 – 96	97 – 128

Fonte: (Federal Railroad Administration, 2017)

Nesse trabalho, o trecho da via analisado possui como requisito operacional uma exigência de velocidade regulamentada para até 64 km/h (classe 3). Contudo, devido à criticidade do corredor, é estratégia da empresa adotar maior rigor na manutenção, em que as tolerâncias das medidas são de Classe 4.

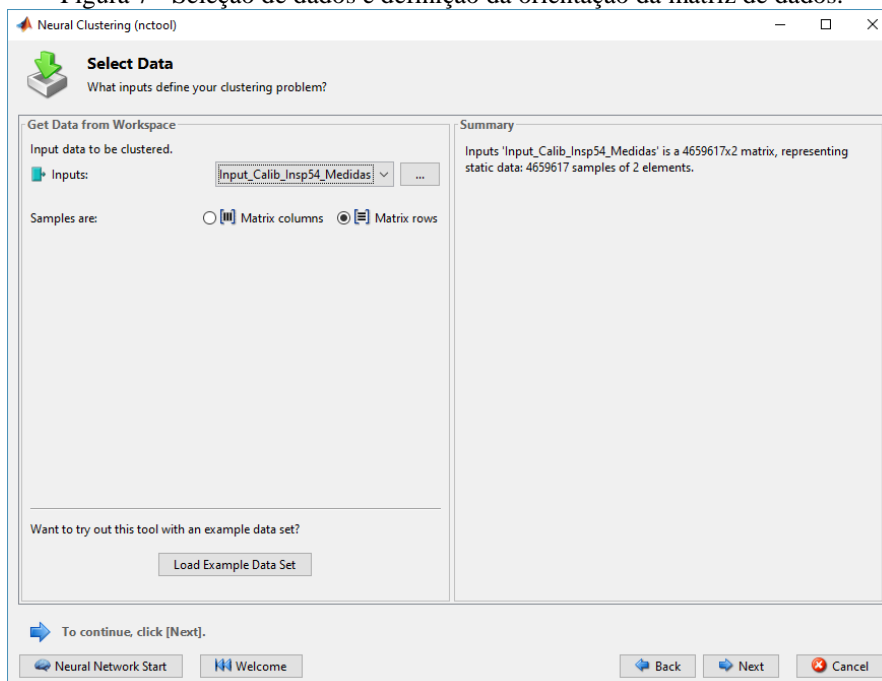
### 3 Criação da Rede Neural Artificial

A criação da rede neural utilizou o conjunto de ferramenta presentes no comando “*NNSTART*” do MATLAB. Esse *software* para analisar e projetar os sistemas e produtos. A linguagem MATLAB baseada em matriz é a maneira mais natural para expressar a matemática computacional. Gráficos integrados facilitam a visualização e obtêm insights a partir dos dados. O ambiente de *desktop* convida a experimentação, exploração e descoberta. Essas ferramentas e recursos do MATLAB são rigorosamente testados e projetados para funcionar em conjunto (The Mathworks, Inc., 2018).

Nessa etapa da pesquisa, foram utilizadas as medições realizadas na Inspeção 54 em toda a linha 01 da malha ferroviária, totalizando uma matriz de 4.659.617 amostras das medidas de bitola sem carga e com carga e um total de 1.420,251 km de inspeção. Na Figura 7 é

apresentada a tela de inclusão dos dados que serão utilizados para criação da Rede Neural Artificial (RNA), usando o módulo de agrupamento de dados (*Neural Clustering – nctool*). Esse módulo é destinado à construção de aplicações criação de mapas auto-organizáveis (SOM).

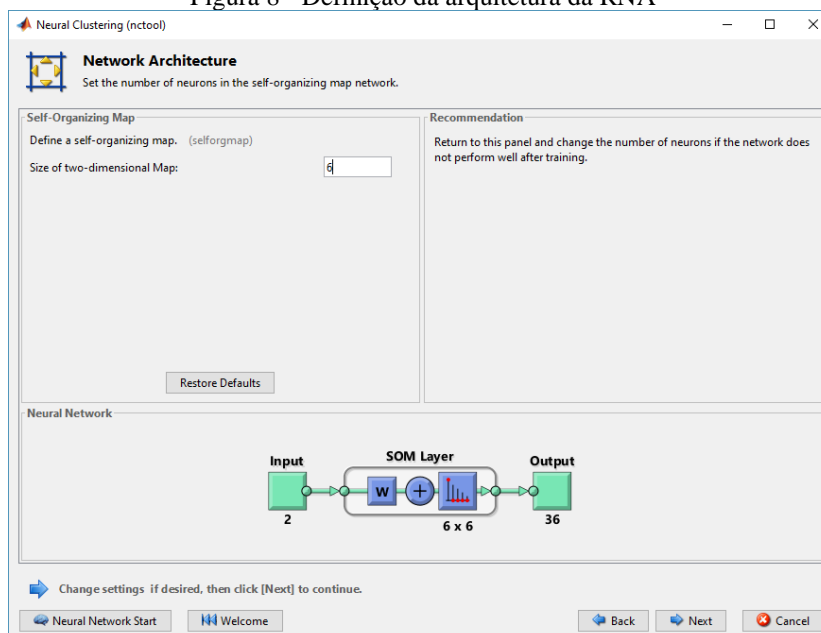
Figura 7 - Seleção de dados e definição da orientação da matriz de dados.



Fonte: ferramenta “nctool” para clusterização com redes neurais do Matlab (The Mathworks, Inc., 2018)

Em seguida, foi definida a arquitetura da RNA. Para essa etapa, os 2 parâmetros de entrada foram submetidos à uma malha que agrupa cada uma das amostras em 36 agrupamentos distintos Figura 8, que possuem graus de correlação entre si mais fortes ou mais brandos Figura 9.


Figura 8 - Definição da arquitetura da RNA



Fonte: ferramenta “nctool” para clusterização com redes neurais do Matlab (The Mathworks, Inc., 2018)



Figura 9 - Mapa auto-organizável - Distância de vizinhos



Fonte: ferramenta “*nctool*” para clusterização com redes neurais do Matlab (The Mathworks, Inc., 2018)

Quando o espaço de entrada é de alta dimensionalidade, não é possível visualizar todos os pesos ao mesmo tempo. Nesse caso, o gráfico de distâncias dos pesos dos vizinhos (*SOM Neighbor Weight Distances*). A Figura 9 indica as distâncias entre os neurônios vizinhos (The Mathworks, Inc.1, 2018).


Esta figura usa o seguinte código de cores:

- Os hexágonos azuis representam os neurônios.
- As linhas vermelhas conectam neurônios vizinhos.
- As cores nas regiões que contêm as linhas vermelhas indicam as distâncias entre os neurônios.
- As cores mais escuras representam distâncias maiores.
- As cores mais claras representam distâncias menores.

As faixas mais claras, localizadas com um gradiente a partir do canto superior esquerdo agrupam as amostras com maior semelhança entre si. Da mesma forma, no canto inferior direito existe outro bloco com os neurônios que possuem menor distância entre si, porém, mais distantes em relação às faixas mais claras.

Após essa etapa, dá-se prosseguimento ao entendimento das características reais de cada agrupamento.

Figura 10 - SOM Sample Hits - alocação das amostras nos blocos



Fonte: ferramenta “*nctool*” para clusterização com redes neurais do Matlab (The Mathworks, Inc., 2018)

A

Figura 10 traz todas as amostras avaliadas em seus devidos blocos. Com isso, são avaliadas as características reais de cada grupo e é criada a ferramenta para avaliação dos demais locais da ferrovia com a identificação do nível de degradação dos parâmetros de defeitos analisados, nas classes de via definidas para o local.

## 4 Análise e interpretação dos resultados

### 4.1 Inspeção 54 – calibração da RNA

O algoritmo gerado é generalizável, ou seja, avalia inspeções futuras conservando os mesmos critérios para agrupamento das amostras. Abaixo, segue tabela gerada a partir da inspeção 54 que fora utilizada para a interpretação dos resultados:

Tabela 2 - Amostras da Inspeção 54 - Blocos e classificação das classes de via

Cluster	Ok	Bit. Din. < Bit. Est.	Bit. Fechada	Def. Classe 01	Def. Classe 02	Def. Classe 04
CL01	5.552	724	1.398	-	-	-
CL02	49.460	3.082	35	-	-	-
CL03	139.800	11.982	-	-	-	-
CL04	124.725	11.235	-	-	-	-
CL05	89.828	4.554	-	-	-	-
CL06	2.980	-	-	82	276	8.313
CL07	107.722	3.856	13	-	-	-
CL08	164.684	10.113	-	-	-	-
CL09	125.181	12.708	-	-	-	-
CL10	109.602	9.288	-	-	-	2
CL11	65.103	3.143	-	9	5	22
CL12	35.978	1.204	-	2	3	591
CL13	150.862	7.903	-	-	-	-
CL14	108.379	-	13	-	-	-
CL15	213.305	4.102	-	-	-	-
CL16	185.902	4.553	-	-	-	-
CL17	90.174	8.748	-	-	-	27
CL18	115.356	2.478	-	-	-	-
CL19	173.856	-	-	-	-	-
CL20	122.010	13.671	-	-	-	-
CL21	203.801	-	-	-	-	-
CL22	100.796	12.785	-	-	-	-
CL23	127.632	6.092	-	-	-	-
CL24	94.692	-	-	-	-	4
CL25	222.021	-	-	-	-	-
CL26	207.857	-	-	-	-	-
CL27	205.880	-	-	-	-	-
CL28	189.990	-	-	-	-	-
CL29	172.742	-	-	-	-	-
CL30	129.183	-	-	-	-	-
CL31	100.952	-	3	-	-	-
CL32	137.142	-	-	-	-	-
CL33	94.660	-	-	-	-	-
CL34	121.410	-	-	-	-	-
CL35	61.973	-	-	-	-	-
CL36	165.408	-	-	-	-	-

Fonte: elaborado pelos autores

Na Tabela 2 estão agrupados os blocos gerados pelo algoritmo SOM e a quantidade de defeitos de bitola relativos à mesma base de dados com os critérios utilizados pela Engenharia do operador ferroviário ao se analisar a classe de via dos corredores de transporte.

Cada unidade constante da Tabela 2 é um ponto de medição (amostra) em sua tradução quanto à velocidade tecnicamente segura para a circulação dos trens. Por exemplo, o bloco CL12 possui:

- 02 amostras com Classe de Via 01
- 03 amostras com Classe de Via 02
- 591 amostras com Classe de Via 04

Conforme apresentado anteriormente, as classes de via indicam as velocidades toleráveis para a circulação segura dos trens. Assim, caso o padrão operacional para essas 02 amostras de CL12 que estão com Classe de Via 01 seja de 60 km/h, imediatamente deverá ser implementada restrição de velocidade, forçando todos os trens que passarem por esse ponto circulem em velocidades inferiores a 16 km/h (Tabela 1).

#### **4.2 Aplicação do algoritmo SOM**

A inspeção da ferrovia com carro controle nesse operador logístico é baseada em ciclos que são determinados em função do volume de carga transportada em cada região, sendo que no fluxo de trens carregados possui frequência aproximada de 3 meses.

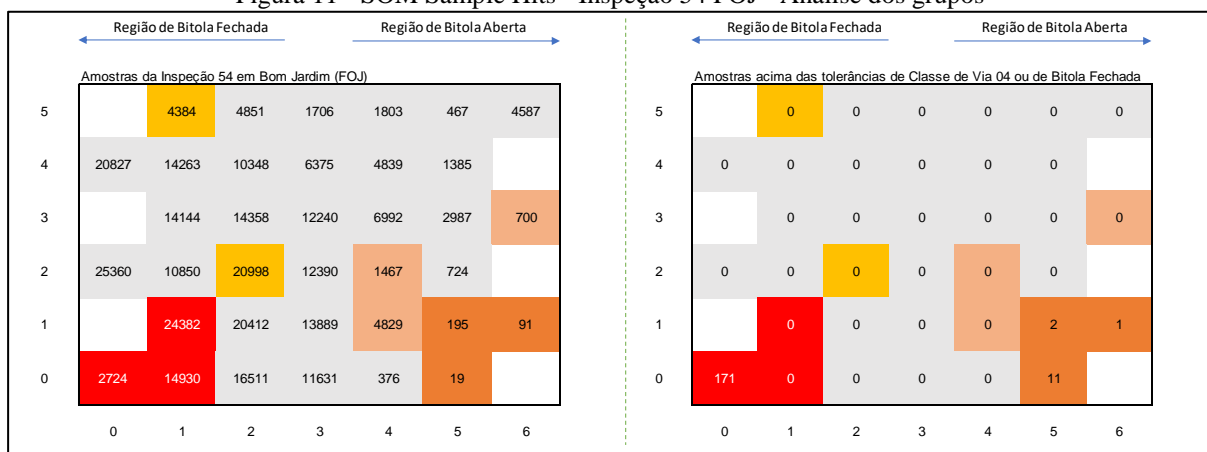
Assim, após calibrado, o passo seguinte foi a aplicação no trecho que corresponde à região próxima ao município de Bom Jardim de Minas, Minas Gerais, nas inspeções de número 55, 56 e 57.

A região de Bom Jardim de Minas possui ferrovia com predominância de tangentes (retas) e transporte de trens carregados. A região também é composta por grande extensão de túneis e é mantido dentro das tolerâncias para a Classe de Via 04 (regime de manutenção), porém com circulação de trens a 60 km/h (regime operacional na classe de via 3).

Para os defeitos de bitola, a FRA considera a mesma tolerância para Classes de Via 2 e 3 e para 4 e 5. Será convencionado nesse artigo, por se tratar da análise do defeito de bitola na região de Bom Jardim, a adoção do termo Classe de Via 2 (regime operacional) e Classe de Via 4 (regime de manutenção) - vide Tabela 1.

É importante salientar que entre os ciclos de inspeção as equipes de manutenção continuam a execução das atividades preventivas e corretivas, portanto, o grande objetivo dos escopos de manutenção são, ao menor custo possível, empreender ações para aumento da vida útil dos componentes e redução das taxas de degradação da ferrovia.

Figura 11 - SOM Sample Hits - Inspeção 54 FOJ - Análise dos grupos




Fonte: elaborado pelos autores.

Na Figura 11 são apresentados 2 gráficos com as amostras realizadas na inspeção 54 no trecho de Bom Jardim. À esquerda são agrupadas todas as amostras e à direita apenas os defeitos dentro da classe de via inspecionada.

Os resultados gerados pelo algoritmo precisam ser interpretados e, com isso, é gerado significado aos dados. Para isso, foram identificadas as regiões que apresentaram defeitos na classe de via 04, ou seja, desvios em relação à bitola padrão superiores aos tolerados para as classes de via 03 ou inferiores e defeitos de bitola fechada.

Nas regiões destacadas em cores foram identificados defeitos corretivos na inspeção 54. Os pares (0,0), (1,0) e (1,1) são os grupos com as medidas de bitola mais fechadas. Os pares (5,0), (5,1) e (6,1) são os pares com as medidas de bitola mais abertas. Os demais pares são estágios iniciais dos defeitos de bitola fechada (à esquerda de cada tabela) e de bitola aberta (à direita de cada tabela).

Figura 12 - SOM Sample Hits - Inspeção 55 FOJ - Análise dos grupos

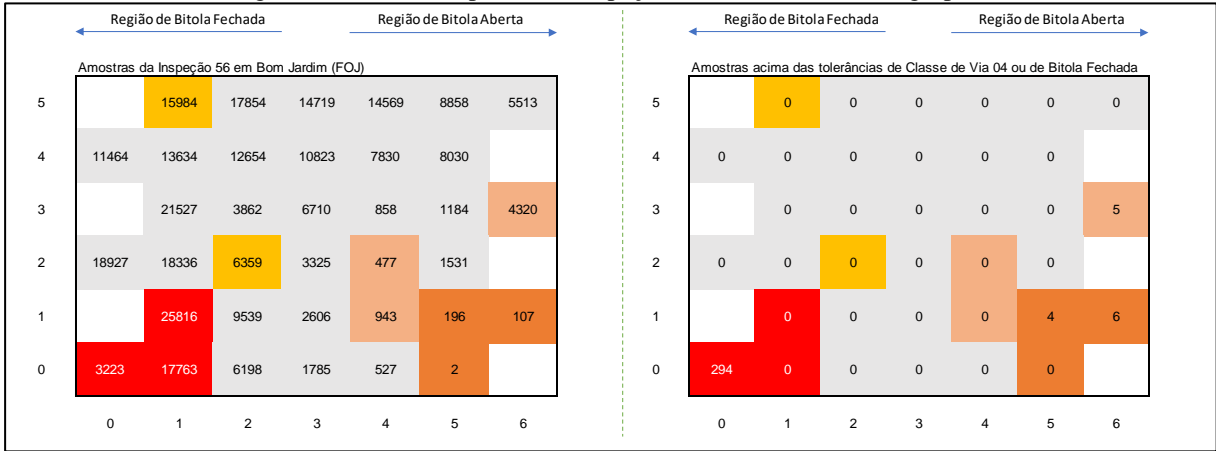


Fonte: elaborado pelos autores.

A Figura 12 possui o mesmo significado que a anterior, porém com dados da inspeção 55 realizada em Bom Jardim. Fica claro analisar pela parte da direita que não foram identificados nenhum defeito de bitola aberta seja com carga ou sem carga nos pares (5,0), (5,1) e (6,1), que serão chamados a partir daqui de *clusters defeituosos*. Do ciclo 54 para o 55, o

processo de manutenção executado pela ferrovia, somado à degradação do trecho pela passagem de trens, trouxe uma redução de 17% de amostras nesses *clusters*. Como resultado adicional, não houve a incidência de quaisquer defeitos corretivos na inspeção 55.


Figura 13 - SOM Sample Hits - Inspeção 56 FOJ - Análise dos grupos



Fonte: elaborado pelos autores.

A Figura 14 apresenta os resultados da inspeção 56. Nesse ciclo, houve um aumento de 20% na quantidade de amostras alocadas nos *clusters defeituosos*. Na prática, isso significa que o direcionamento dado aos esforços de manutenção foi menos efetivo do que a degradação proveniente das variações geradas pelo passar de trens no período compreendido entre a inspeção 55 e a inspeção 56.


Figura 14 - SOM Sample Hits - Inspeção 57 FOJ - Análise dos grupos



Fonte: elaborado pelos autores.

Na inspeção 57 o cenário foi outro. Novamente os *clusters defeituosos* tiveram seu avanço contido e como resultado, zero falhas corretivas registradas pelo carro controle. Fica evidente que o saneamento das anomalias presentes nos *clusters defeituosos* possuem correlação direta com o surgimento de defeitos corretivos. Na Figura 14, quando existe a comparação para parte à esquerda com o mesmo lado da Figura 13, os *clusters defeituosos* reduziram em 51% e zero falhas corretivas identificadas pela parte a direita da figura.

Gráfico 1 - Evolução da quantidade de amostras boas e fora da tolerância em Cluster Defeituoso



Fonte: elaborado pelos autores.

Assim, após analisar os resultados e identificar quais são os *clusters* indesejados, fica estabelecida uma ferramenta para identificação dos locais com características indesejadas na malha, permitindo aumentar o tempo de resposta mediante a atuação preditiva e geração de escopos de manutenção que sejam efetivos para o modo de falha analisado.

Sob a ótica de defeitos de bitola, a priorização apresentada no Quadro 1 é o ponto inicial a ser considerado para priorização das ações em campo a ser executadas pela equipe da ferrovia. Após analisar as leituras das inspeções e resultados de desvios comparados com a Tabela 1 - Classes de Via e tolerâncias para velocidades de circulação, foi gerada uma referência para as ações de direcionamento de esforços do time de manutenção. É importante dizer que essa referência do Quadro 1 não elimina a importância do Especialista e times de campo analisarem as informações relacionadas às demais anomalias instaladas nos locais indicados para aí sim gerar o escopo final de intervenção. Contudo, aceleram em muito a seleção dos locais que efetivamente devem ser avaliados em função de sua semelhança a outros locais onde a anomalia evolui para defeitos na classe de via de referência para o local.

Quadro 1 - Priorização da atuação da manutenção

	Propensão a defeitos de bitola aberta mais severos => Prioridade 1 para manutenção
	Propensão a defeitos de bitola aberta mais brandos => Prioridade 2 para manutenção
	Propensão a defeitos de bitola fechada mais severos => Prioridade 3 para manutenção
	Propensão a defeitos de bitola fechada mais brandos => Prioridade 4 para manutenção

Fonte: elaborado pelos autores.

## 5 Considerações Finais

No presente estudo é apresentada a aplicação de um algoritmo baseado em Redes

Neurais Artificiais para criação de um mapa auto-organizável dos defeitos de bitola em uma ferrovia do sudeste mineiro.

A solução, contudo, possui limitações que são recomendações para estudos futuros. A primeira delas é quanto à geração efetiva dos escopos de manutenção. Isso significa que mediante análises das intervenções de manutenção realizadas no passado em cada um desses locais é possível avaliar quais ações efetivamente trouxeram os melhores resultados com o menor custo. Essa informação combinada com o algoritmo gerado para detecção de *clusters* defeituosos tem elevado potencial para criação de novo algoritmo, agora voltado para a geração automática do escopo mínimo de manutenção para fazer com que no local da intervenção de manutenção o defeito de bitola recue até os parâmetros estudados.

Outra limitação do estudo tange aos aspectos relacionados aos defeitos de bitola fechada. Na prática, em função dos esforços dinâmicos exercidos pelos trens em movimento, a bitola abre dinamicamente e não figura como risco operacional (dado que não foram identificados defeitos na classe de via 3). Contudo, esse estudo recomenda a análise das práticas de substituição de trilhos e atividades de correção de bitola realizadas pela ferrovia estudada. Intuitivamente é possível inferir que os *cluster* na região de bitola mais fechada representam regiões em que os trilhos e rodas dos veículos ferroviários ficam tensionadas lateralmente, o que acelera a degradação das fixações e aumenta o desgaste dos componentes.

Com as tecnologias atuais, uma recomendação futura é a construção de um dispositivo móvel utilizando hardwares similares ao Arduíno ou Raspberry para processamento do algoritmo SOM para classificação de bitola nos próprios veículos de operação das várias coordenações de manutenção da ferrovia. Com isso, a coleta de informações e identificação de *clusters defeituosos* acontecerá na ponta e com maior frequência. Assim, as alterações bruscas na condição da via serão identificadas em ciclos inferiores aos da inspeção pelo carro controle e com baixo custo. Aumento em muito o tempo de resposta e com potencial redução no custo da intervenção de manutenção propriamente dita (correção de fixações dos dormentes e trilhos é muito mais barata e produtiva do que a própria troca de dormentes e trilhos, por exemplo).

## 6 Referências

ANTF. (3 de Março de 2017). *Releases: ANTF*. Acesso em 19 de Abril de 2018, disponível em Site da ANTF: <http://www.antf.org.br/releases/mais-de-r-52-bi/>

ANTF. (18 de Abril de 2018). *Informações Gerais*. Fonte: Site da ANTF: <http://www.antf.org.br/informacoes-gerais/>

BRINA, H. L. (1979). *Estradas de Ferro*. Rio de Janeiro: Livros Técnicos e Científicos Editora S.A.

COIMBRA, M. V. (2008). Modos de Falha dos Componentes da Via Permanente. *Dissertação de Mestrado*. Rio de Janeiro, RJ, Brasil: Instituto Militar de Engenharia.



- FAWCETT, T., & PROVOST, F. (2013). *Data Science For Business*. Sebastopol, CA: O'Reilly Media, Inc.
- Federal Railroad Administration. (2017). Track and Rail and Infrastructure Integrity Compliance Manual. *Volume II Track Safety Standards, Chapter 1 Track Safety Standards, Classes 1 Through 5*. Estados Unidos da América: U. S. Department of Transportation.
- Holland LP. (10 de 05 de 2018). *Holland Library - TrackSTAR Product Sheet*. Fonte: Site da Holland LP: <https://www.hollandco.com/>
- KNOTHE, K. L., & GRASSIE, S. L. (1993). Modelling Railway Track and Vehicle/Track Interaction at High Frequencies. *International Journal of Vehicle Mechanics and Mobility, Vehicle System Dynamics*. Vol. 22, 209-262.
- Kohonen, T. (1982). Clustering, taxonomy, and topological maps of patterns. *Int. Conf. on Pattern Recognition* (pp. 114-128). Washington, DC: IEEE Computer Soc. Press.
- Kohonen, T. (1995). *Self-Organizing Maps*. Berlin: Springer.
- Kohonen, T., Hynninen, J., Kangas, J., & Laaksonen, J. (1996). *SOM\_PAK: the self-organizing map programming package*. Laboratory of Computer and Information Science. Espoo: Helsinki University of Technology.
- LIN, C. T., & LEE, C. S. (1996). *Neural Fuzzy Systems - A Neuro-Fuzzy Synergism to Intelligent Systems*. Upper Saddle River, NJ: Prentice Hall P T R.
- McCULLOCH, W. S., & PITTS, W. H. (1943). A logical calculus of ideas immanent in nervous activity. *Bulletin of mathematical biophysics*, vol. 5, 115-133.
- MRS Logística. (26 de Março de 2018). *Relações com Investidores: MRS Logística*. Acesso em 19 de Abril de 2018, disponível em Site da MRS Logística: [http://ri.mrs.com.br/conteudo\\_pt.asp?idioma=0&conta=28&tipo=53958](http://ri.mrs.com.br/conteudo_pt.asp?idioma=0&conta=28&tipo=53958)
- PORTO, T. G. (2004). PTR 2501 - Ferrovias. São Paulo, Brasil: Escola Politécnica da Universidade de São Paulo - Departamento de Engenharia de Transportes.
- RIVES, F. O., L., P. A., & PUENTE, M. J. (1977). *Tratado de Ferrocarriles I*. Madri: Editora Ruerda.
- The MathWorks, Inc. (07 de 05 de 2018). *Documentation*. Fonte: Site da MathWorks: <https://www.mathworks.com/help/nnet/ref/selforgmap.html>
- The Mathworks, Inc. (10 de 05 de 2018). *Matlab*. Fonte: Learn to use - Documentation: <https://www.mathworks.com/help/matlab/index.html>
- The Mathworks, Inc.1. (10 de 05 de 2018). *Cluster with Self-Organizing Map Neural Network*. Fonte: Matlab Documentation - SOM: [https://www.mathworks.com/help/nnet/ug/cluster-with-self-organizing-map-neural-network.html?searchHighlight=neural%20network%20som&s\\_tid=doc\\_srchtile](https://www.mathworks.com/help/nnet/ug/cluster-with-self-organizing-map-neural-network.html?searchHighlight=neural%20network%20som&s_tid=doc_srchtile)
- ZAREMBSKI, A. M., & Palese, J. W. (2005). Characterization of Broken Rail Risk for Freight and Passenger. *AREMA - Conference Proceedings*.