



Detecção de fratura em trilho com uso de inteligência artificial

Rafael Eugenio Barbosa Orsoni*, Rodrigo de Souza, Rafael Silva Pinto,
Vitor Miguel Braga, Vivian de Souza Gasperino

Diretoria de Tecnologia, Rua Emílio Bertolini nº 100, 82920-030, Curitiba/PR

rafael.orsoni@rumolog.com, rodrigo.souza@rumolog.com,
rafael.pinto@rumolog.com, vitor.braga@rumolog.com e
vivian.gasperino@rumolog.com

Resumo A iniciativa de detecção de fratura em trilho com uso de inteligência artificial tem o objetivo de aumentar a segurança operacional a partir de uma maior detecção desses fenômenos com uso de algoritmos de Inteligência Artificial (IA) para processar em tempo real as leituras realizadas pelos equipamentos Detectores de Trilho Quebrado (DTQ) instalados em toda a malha da Rumo. Para isso foram utilizados os dados históricos dos equipamentos instalados em toda a Operação Norte (Malha Norte e Paulista) e a base de fraturas em trilho na companhia para realizar o treinamento de uma rede neural capaz de identificar os fenômenos de fratura em trilho. O objetivo era detectar fraturas em condições específicas onde o DTQ apresenta uma sensibilidade menor, e detectar anomalias no sinal do equipamento que permitissem uma avaliação preventiva do trilho no local, assim diminuindo o risco de um acidente por causa de um trilho fraturado.

Palavras-Chaves: Inteligência Artificial, Redes Neurais, Fratura em Trilho, Segurança Operacional.

1. INTRODUÇÃO

O risco de acidentes causa trilho quebrado são constantes em todas as ferrovias, implicando em prejuízo financeiro, riscos ambientais e possibilidade de perdas de vidas humanas. Por esse motivo e fabricantes e ferrovias discutem esse assunto em vários fóruns. Inegavelmente a Rumo tem investindo em minimizar de maneira significativa os riscos relacionados à exposição dos trens a trilhos quebrados (com fratura).

Nesse sentido, podemos avaliar a situação que a Rumo enfrentava no ano de 2016, quando após uma forte redução do número de acidentes em relação aos anos anteriores, ainda permanecia em um cenário com alto número de acidentes por causa Trilho Quebrado, sendo essa a segunda principal bandeira dentro da companhia. Considerando o impacto na operação que os acidentes por

bandeira trilho geram, o custo de manutenção dos ativos envolvidos nos acidentes e da recuperação do local do acidente, impacto financeiro da perda de produtividade, aumento do Transit Time, e risco de perdas humanas, o tratamento desses casos era imprescindível.

A solução padrão para esse problema seria a utilização de circuitos de via, solução considerada financeiramente inviável na época por utilizar um equipamento desenvolvido para outro fim (detectar a presença de trem na seção de bloqueio) e por ter como requisito falha segura. Dessa constatação, surgiu a proposta de desenvolver um equipamento voltado especificamente para detecção de fraturas nos trilhos, e dessa iniciativa surgiu o Detector de Trilho Quebrado (DTQ).

2. DETECTOR DE TRILHO QUEBRADO

Produto de um projeto de desenvolvimento executado em 2017, o Detector de Trilho Quebrado (DTQ) é um equipamento de campo instalado na via permanente que realiza a leitura da resistência elétrica dos trilhos compreendidos na sua região de cobertura.

A escolha do princípio de funcionamento por trás do equipamento ser a resistência elétrica dos trilhos se deu após uma avaliação de outros princípios que acabaram desempenhando pior nas condições de uso determinadas pela malha, além da resistividade elétrica dos trilhos ter apresentado melhor reprodutibilidade entre diferentes amostras do que outras propriedades testadas.



Fig. 1 Equipamento Detector de Trilho Quebrado

A medição da resistência elétrica do trecho é possível através da passagem de corrente elétrica pelos trilhos e a medição da diferença de potencial entre os mesmos, realizando o cálculo inverso da Lei de Ohm:

$$U = R.I \quad (1)$$

Dessa maneira, o equipamento é capaz de monitorar a resistência do trecho e perceber aumentos súbitos de resistência, como acontece nos casos de Fratura, e gerar um alarme de trilho quebrado.



Fig. 2 Exemplo de trilho quebrado e efeito na resistência medida pelo equipamento. [3]

Utilizando-se desses estudos iniciais, um protótipo foi desenvolvido testado e validado, sucedendo-se a instalação de grande quantidade desses equipamentos por toda a malha.



Fig. 3 Ilustração de vários DTQs instalados em sequência na malha.

Com o uso massivo dos equipamentos por toda a malha, pudemos observar uma grande redução de acidentes por bandeira trilho nos anos que se sucederam.



Fig. 4 Histórico de redução de acidentes por causa Trilho Quebrado. [1]

Além disso, o equipamento permitiu uma atuação mais rápida das equipes de manutenção, uma vez que não era mais necessário a passagem de um trem, auto de linha ou rondante no local para identificar o problema. E também, permitiu a remediação do risco de acidente com a aplicação de restrições de velocidade nos trechos onde o DTQ dispara, reduzindo a Velocidade Máxima Autorizada (VMA) enquanto a equipe de manutenção não chega ao local.

3. IDENTIFICANDO A OPORTUNIDADE

No cenário atual, temos centenas de DTQs instalados na nossa malha, com os equipamentos apresentando uma alta capacidade de detecção de fraturas em trilho (95%) e tendo até o momento detectado mais

de 1000 trilhos quebrados desde o início do projeto. Por que então investir no desenvolvimento de uma Inteligência Artificial (IA) para auxiliar o equipamento a realizar sua função, sendo que ele é tão bem sucedido nela?

O patamar de 95% de captura de trilhos quebrados indica que temos 1 a cada 20 fraturas que não são detectadas, o que permite a ocorrência de alguns acidentes por essa causa. Esse limite na assertividade do equipamento acaba criando um desafio mais bem delimitado quando foi possível perceber que ele é o resultado da dificuldade do equipamento detectar fraturas em algumas condições específicas, como quando a fratura ocorre sobre a placa de apoio do trilho, o que permite a condução da corrente elétrica através do contato da placa com o trilho.



Fig. 5 Exemplo de fratura sobre placa de apoio.

Foi considerando casos desse tipo, chamados de fratura sem alarme (FSA), nos quais o equipamento não dispara o alarme, que a ideia de utilização de IA para tratar esses casos surgiu.




Fig. 6 Proporção de eventos DTQ em 2020. [2]

4. PROPOSIÇÃO DE USO DA IA

Com o intuito de gerar alertas via um modelo de Inteligência Artificial (IA) capaz de fazer a identificação dos trilhos quebrados, foi proposta uma visão do funcionamento dessa ferramenta como se segue.




Fig. 7 Ilustração do fluxo de processamento da Inteligência Artificial na nuvem. [3]

Baseando-se na utilização de dados enviados pelos equipamentos e armazenados na nuvem, seria feito o processamento desses dados e a execução do modelo de IA para detecção de fenômenos em tempo real. Esse processamento seria feito de forma centralizada, avaliando as leituras de todos os equipamentos com comunicação de rede e produzindo alertas de detecção de fraturas e anomalias.

Nesse caso, diferenciamos fraturas e anomalias como diferentes classes de fenômenos que podemos diferenciar da seguinte maneira: casos nos quais podemos observar uma separação física das partes do trilho, no caso das fraturas; e casos onde há fissuras, trincas e até mesmo a fratura do trilho, mas o contato elétrico entre as partes permanece, caracterizando o que conhecemos como “trilho topado” e gerando anomalias nas leituras do equipamento.

5. DESENVOLVIMENTO E VALIDAÇÃO DO MODELO

Para o desenvolvimento do modelo foram utilizadas 2 principais fontes de dados: os dados enviados pelos DTQs em campo e armazenados na nuvem, e a Base de Alarmes DTQ, que é mantida pela equipe de engenharia e registra todos os fenômenos relevantes relacionados aos DTQs, principalmente alarmes de trilho quebrado e fenômenos de fratura sem alarme.



Com esses dados em mãos, e utilizando o ambiente da AWS para processamento dos dados, foi possível tratar as leituras dos equipamentos e agregar aos fenômenos registrados.



Fig. 8 Ilustração do processo de desenvolvimento do modelo de IA utilizado pela ferramenta. [3]

Passamos então para a etapa de extração de características e modelagem, na qual foi possível testar diferentes abordagens e modelos, priorizando a capacidade de detecção de fraturas e anomalias.

Desta etapa, pudemos selecionar uma Rede Neural Artificial (RNA) Convolucional como melhor modelo. Dentre as arquiteturas testadas, uma com 6 camadas e mais de 5 milhões de parâmetros foi a que desempenhou melhor.

Para realizar a validação desse modelo, um conjunto de dados que não havia sido utilizado no treinamento foi avaliado. Os dados para as fraturas sem alarme do ano foram coletados e foram utilizados como teste final para aprovação do modelo para implementação piloto.

Nesse teste, 5 fraturas sem alarme não utilizadas no treinamento foram submetidas ao processamento da IA e o modelo foi capaz de detectar 3 fenômenos dentre esses 5, o que representa uma detecção de 60% de fraturas sem alarme. Isso traz um grande aumento de sensibilidade de detecção, permitindo esperar uma redução da proporção de fraturas sem alarme de 1 a cada 20, para 1 a cada 50 trilhos quebrados.

6. IMPLEMENTAÇÃO PILOTO E PRIMEIROS RESULTADOS

Uma vez validado o modelo, foi iniciada a fase de implementação do piloto. Para este fim,

tivemos apoio do time de TI responsável pelo Supervisório no desenho de uma arquitetura capaz de realizar a execução desse modelo em tempo real. Além disso, foi desenvolvida também uma interface para os alertas gerados pela IA, de maneira que os usuários da operação pudessem tirar o máximo de proveito possível da ferramenta.



Fig. 9 Interface da ferramenta entregue aos usuários da operação. [3]

Essa interface tem a função não só de exibir os alertas, mas também agregar informações do ativo (localização, número serial, etc.), exibir o histórico recente de leituras do equipamento que gerou o alerta na forma de gráficos e permitir o feedback dos usuários, de forma que eles possam contribuir para a evolução da mesma, respondendo o formulário de avaliação dos alertas.

Uma vez implementado o modelo e integrada a interface, teve início a validação da ferramenta pelas áreas da operação. Nas primeiras semanas desse período, a IA detectou o mesmo número de fraturas que o DTQ, tendo portanto o mesmo número de alarmes verdadeiros.

Tabela 1 Visão dos alertas gerados pelo DTQ e pela IA nas primeiras semanas da fase de validação. [3]

Alertas	IA	DTQ
Verdadeiros	33	33
Anomalias	23	0
Falsos	9	0
Fraturas sem alarme	0	0

Total de Alertas	65	33
------------------	----	----

O que a IA trouxe de ganho nesse período foi a detecção de 23 anomalias que não dispararam o DTQ. Dentre elas, 2 fenômenos em particular ilustram bem o a eficácia da ferramenta:

- No primeiro caso, apesar do aspecto de fratura, a resistência dos trilhos não aumentou o suficiente para disparar os DTQ instalado no local, e a IA foi capaz de detectar o evento.



Fig. 10 Exemplo de fenômeno detectado pela IA com aspecto de trilho quebrado. [3]

- No segundo caso, uma oscilação de alta frequência no sinal foi detectada horas antes da resistência do trecho subir em decorrência da descontinuidade do circuito do DTQ naquele trecho, indicando que um mal contato já existia entre as partes antes da detecção do equipamento.



Fig. 11 Exemplo de fenômeno detectado pela IA com aspecto de anomalia. [3]

7. VALIDAÇÃO DO PILOTO

O período de avaliação se estendeu por um total de 10 semanas, nas quais os alertas foram avaliados caso a caso e o volume de cada tipo de alerta foi avaliado de uma forma mais ampla.




Fig. 12 Visão semanal dos alertas da IA discriminados entre verdadeiros, anomalias e falsos durante fase de validação. [3]

Nesse período, pudemos observar o crescimento da assertividade do modelo semana a semana, e o consequente decréscimo de alertas falsos (sem nenhum fenômeno constatado), alcançando o patamar de 98% de assertividade.




Fig. 13 Performance da IA durante fase de validação. [3]

Essa evolução foi possível graças ao feedback da operação e do esforço de desenvolvimento que foi despendido nesse período.

8. PRÓXIMOS PASSOS

Como principais iniciativas para a melhoria dessa ferramenta, temos 3 frentes de trabalho relativamente independentes:

- IA Embarcada: iniciativa de adaptação do modelo de Inteligência Artificial na Cloud para execução no hardware em campo, permitindo trazer os benefícios observados também para os equipamentos sem comunicação. Para isso será necessário passar por um

processo de miniaturização do modelo similar ao descrito a seguir:

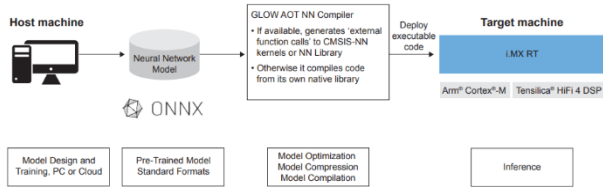


Fig. 14 Processo de miniaturização de modelos proposto pela NXP. [4]

- Melhoria semiautônoma do modelo: iniciativa de automatizar parte do processo de retreinamento do modelo de IA a partir do feedback dos usuários, permitindo maior agilidade na execução da tarefa e a continuidade da melhoria do mesmo.

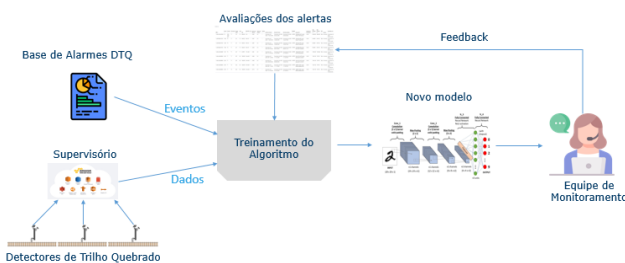


Fig. 15 Processo de retreinamento do modelo baseado no feedback dos usuários. [3]

- Melhorar assertividade e estudar anomalias: investigar anomalias frequentes em campo para podermos constatar os fenômenos na via que causam essas variações no sinal. A partir desses achados, utilizar esse feedback das equipes de campo no treinamento do modelo, com o objetivo

de melhorar a detecção e seletividade das anomalias detectadas pela IA.

9. CONCLUSÕES

A Inteligência Artificial desenvolvida durante o projeto se mostrou capaz de realizar a detecção dos fenômenos de interesse para os quais ela foi projetada, cumprindo a missão de Detecção de fratura em trilho com uso de inteligência artificial, conforme proposto inicialmente.

Os resultados obtidos no projeto representam um ganho importante na capacidade de detecção do equipamento, diminuindo o risco de acidentes e trazendo maior segurança para a operação.

O uso de serviços em nuvem permitiu uma fluidez maior da etapa de desenvolvimento, uma vez que a integração com os dados armazenados nesse ambiente foi facilitada.

O projeto englobou a implementação de um novo sistema piloto e a entrega de uma interface para a operação. Para isso sessões de treinamento para uso da interface foram ministradas e orientação de como responder o formulário de orientações foram passadas. Esse alinhamento se mostrou crucial na fase de validação, uma vez que o feedback dos usuários permitiu a melhoria do modelo.

10. REFERÊNCIAS

- [1] Rumo. Base Acidentes SRO. Consultado em: Fevereiro 2021.
- [2] Rumo. Base Controle DTQ. Versão 4. Consultado em: Julho 2021.



-
- [3] Rumo. Relatório Interno de Evidências do Projeto DTQ Fase 2. Versão 2. Fevereiro 2021.
- [4] eIQ™ Inference with Glow NN. Ilustração retirada de:
<https://www.nxp.com/design/software/development-software/eiq-ml-development-environment/eiq-inference-with-glow-nn:eiQ-Glow>. Acessado em: Julho 2021.