

26ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
7º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS



CATEGORIA 3

**INOVAÇÃO E APRIMORAMENTO DA MANUTENÇÃO PREDITIVA DOS TRENS COM
APLICAÇÃO MACHINE LEARNING**

Introdução

O Metrô-SP tem como objetivo permanecer como opção preferencial de transporte na região metropolitana de São Paulo, oferecendo serviços de qualidade e cada vez mais atentos às necessidades do cidadão. Com isso, é necessário um trabalho rigoroso, confiável, seguro e com qualidade pela manutenção dos trens.

A manutenção de trens atual do Metrô-SP é dividida em corretiva e preventiva, ao qual tem seguido por muitos anos, entretanto, com a transformação digital, os avanços da tecnologia influenciam para que realizem serviços que vençam desafios mais eficientes, confiáveis, disponíveis, adaptáveis e seguros, e entre muitas dessas ferramentas, um dos componentes para essa transformação digital é o Machine learning aplicado em manutenção preditiva.

Com a tecnologia já existente nos trens, de obter todos históricos de falhas, integrando com o sistema de banco de dados de históricos de ocorrências da manutenção, pode ser criado uma nova forma de inspecionar uma falha que pode ocasionar na linha ferroviária, obtendo-se melhor desempenho do trabalho na área.

A aplicações de aprendizagem de máquina tem como intuito usar modelos que são aprendidos a partir dos dados, como consequência aumentar o grau de decisão, para prever falhas, cujos benefícios se estendem às autoridades e aos passageiros por meio da oferta de um melhor serviço de transporte, pois essa tecnologia demonstra uma solução consolidada e automatizada do sistema, provê mais segurança, confiabilidade, disponibilidade e flexibilidade, evitando-se falhas na via.

Fundamentos conceituais

- 1) **Ocorrência** – Todo desvio ou falha que causa uma interferência na operação comercial. São classificados nos níveis A, B e C, obedecendo aos seguintes critérios: Segurança do sistema, conforto e requisitos dos usuários e restrições de movimentação e disponibilidade.
 - Nível “A” - O trem não tem condições de movimentação com segurança sem a atuação da manutenção.
 - Nível “B” - O trem possui algum tipo de restrição que gera transtorno na circulação de trens na Operação comercial.
 - Nível “C” – O trem tem condições de movimentação com segurança, com todos os carros prestando serviço, sem restrição à sua velocidade.
- 2) **Manutenção Preventiva** - Manutenção efetuada em intervalos pré-determinados, ou de acordo com critérios prescritos, destinada a reduzir a probabilidade de falha ou a degradação do funcionamento de um item, de acordo a norma ABNT NBR 5462-1994.
- 3) **Manutenção Corretiva** - Manutenção efetuada após a ocorrência de uma pane, destinada a recolocar um item em condições de executar uma função requerida.
- 4) **Manutenção Preditiva** - Manutenção efetuada com acompanhamento de medições e coletas de dados feitos em um intervalo regular de tempo,

atuando com a finalidade de indicar as reais condições de equipamentos e instalações.

5) Confiabilidade do sistema – Para mensurar a confiabilidade do sistema,

são utilizados quatro índices:

5.1) MKBF- Mean Kilometer Between Failure - Média de Quilometragem

entre falhas). O cálculo é realizado da seguinte forma:

$$\Sigma \left[\frac{\Sigma(\text{km rodados}) \times 6}{\Sigma N^{\circ} \text{ de falhas}} \right]$$

5.2) MKBFvB – É uma derivação do MKBF, trata-se de uma média de

quilômetros entre falhas nível B na via) - O cálculo é realizado da

seguinte forma:

$$\Sigma \left[\frac{\Sigma(\text{km rodados}) \times 6}{\Sigma N^{\circ} \text{ de falhas nível B}} \right]$$

5.3) MKBO – Mean Kilometer Between Occurrence - Média de

Quilometragem entre Ocorrências). O cálculo é realizado da seguinte

forma:

$$\Sigma \left[\frac{\Sigma(\text{km rodados}) \times 6}{\Sigma N^{\circ} \text{ de ocorrências}} \right]$$

5.4) MKBO5 – Mean Kilometer Between Occurrence greater than 5

minutes - Média de Quilometragem entre Ocorrências maior que 5 minutos). O cálculo é realizado da seguinte forma:

$$\Sigma \left[\frac{\Sigma (\text{km rodados}) \times 6}{\Sigma \text{N}^\circ \text{de ocorrências que causaram interferências com duração de 5 minutos ou mais}} \right]$$

6) Sistema do Trem – O trem é dividido em várias interfaces, ao quais são:

- PS - Propulsão/Tração
- FR - Freio
- CM - Comunicação
- PT - Portas
- VT - Ventilação/Ar condicionado
- AC - Controle automático do trem (ATC)
- CB Controle automático do trem via wireless (CBTC)
- EN - Engate
- TQ - Truque
- SA - Suprimento de ar comprimido
- SE - Suprimento elétrico
- SI - Sinalização e iluminação
- CX - Caixa

Metodologia

O trabalho foi desenvolvido em 3 (três) etapas:

Etapa 1. Amostragem e estruturação da base de dados:

1.1. Modelos aplicáveis

1.2. Tratamento dos dados

Etapa 2. Estruturação do problema e criação de soluções

2.1. Análise preditiva aplicando aprendizagem de máquina nas ocorrências de falhas

Etapa 3. Desafios

3.1. Aplicação prática

Desenvolvimento

A ciência do aprendizado computacional tem diversas ramificações, sendo cada uma delas objeto de pesquisas variadas. Neste artigo optou-se pelo uso de alguns ramos do aprendizado computacional considerados mais adequados à resolução dos problemas relativos à operacionalidade da manutenção de trens. Sendo assim, este artigo visa a aplicação de modelos de aprendizagem de máquina (Machine learning) com propósito de transformar os problemas em coleta de dados, para entendê-los, limpá-los e formatá-los para dar respostas com intuito de prever saídas, para evitar ocorrências que possam causar transtornos na linha.

A aprendizagem de máquina têm 3 principais aspectos fundamentais que são:

- **Componentes:** Os componentes do elemento de desempenho que devem ser aprendidos, ao qual podem ser como exemplos um mapeamento direto de condições no estado atual de ações, um meio para deduzir propriedades relevantes do mundo a partir da sequência de percepções, informações de utilidade indicando a desejabilidade de ações, entre outros.

- **Realimentação:** A realimentação que estará disponível para aprender esses componentes, ao qual consiste em aprendizagem

- **Supervisionada:** Envolve aprendizagem de uma função a partir de exemplos de suas entradas e saídas.

- **Não supervisionada:** Envolve a aprendizagem de padrões na entrada, quando não são fornecidos valores de saída específicos, com objetivo de descobrir saídas desejadas ou úteis por tentativa e erro ou processos de auto-organização e,

26ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 7º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS



- Por reforço: Em vez de ser informado por um instrutor, uma aprendizagem por reforço consiste a aprender por reforço, isto é, dado um ambiente com todos os possíveis estados onde o agente pode atuar e executar e, também a ação e o estado a cada unidade de tempo, com isso, ele trabalha por recompensa e utilizado com uma estratégia de controle de forma que maximize as recompensas ao longo do tempo, aumentando exponencialmente por forma iterativa no processo.

- **Representação:** A representação que será usada para os componentes.

Será aplicado o modelo de Machine Learning supervisionado. O aprendizado supervisionado tenta aprender uma função através de um software professor. Observa-se o sistema em estudo, tanto as entradas quanto as saídas, e monta um conjunto de observações de treinamento $T = (x_i, y_i), i = 1, \dots, N$. Os valores de entrada observados no sistema x_i também são alimentados em um sistema artificial, conhecido como algoritmo de aprendizado (geralmente um programa de computador), que também produz resultados $f(x_i)$ em resposta às entradas. O algoritmo de aprendizado possui a propriedade de poder modificar sua relação de entrada/saída em uma função f em resposta a diferenças $y_i - f(x_i)$ entre as saídas originais e geradas. Esse processo é conhecido como aprendizado pelo exemplo.

Após a conclusão do processo de aprendizagem, a esperança é que o artificial e as saídas reais estarão próximas o suficiente para serem úteis para todos os conjuntos de entradas que provavelmente serão encontrados na prática.

Existem diversos modelos de aprendizagem de máquina, e será utilizado uma família parametrizada de modelos para descrever a relação de interesse, como presumir diferentes ocorrências que podem ocorrer durante a operação dos trens na via. Alguns

desses modelos aplicáveis serão aprendizagem Bayesiana, aprendizagem em Redes Neurais e Aprendizagem em árvores de decisão.

Etapa 1. Amostragem e estruturação da base de dados:

1.1. Modelos aplicáveis

1.1.1 – Aprendizagem Bayesiana

O modelo de aprendizagem Bayesiana utiliza o teorema de Bayes que pode ser usado para calcular a probabilidade de que um evento venha a ocorrer dado que já conhecemos um fragmento relacionado de informação. Em termos matemáticos, pode-se seguir da seguinte forma:

$$P[A|B] = \frac{P[B|A]P[A]}{P[B]}$$

$P[A|B]$ – Probabilidade do evento A acontecer tendo condicionalmente observado o evento B.

$P[B|A]$ - Probabilidade do evento B acontecer tendo condicionalmente observado o evento A.

$P[A]$ – Probabilidade do evento A ocorrer.

$P[B]$ – Probabilidade do evento B ocorrer.

Nesse sentido, aplicando-se a aprendizagem bayesiana em termos práticos, o mais comum é a verificação automática dos e-mails e determinar a probabilidade do e-mail ser spam se conter uma palavra suspeita, e com isso, de forma iterativa, filtrar e-mails suspeitos na caixa de entrada de e-mail.

1.1.2 – Aprendizagem por árvore de decisão

Esse modelo usa uma estrutura de árvore para representar um número possível de possíveis caminhos de decisão e um resultado para cada caminho. As árvores de decisão possuem muitas recomendações. Elas são muito fáceis de entender e interpretar, e o processo por onde chegam numa previsão é completamente transparente.

Para construir uma árvore de decisão, precisa-se decidir quais perguntas fazer e em qual ordem. Em cada etapa de uma árvore há algumas possibilidades que eliminamos e outras que não. Cada pergunta possível separa as possibilidades restantes de acordo com as respostas. Nesse sentido, é utilizada perguntas cujas respostas informem o que a árvore deve prever.

As árvores de decisão têm grandes qualidades como classificadoras. Além dessa característica, seus modelos são de fácil compreensão para os usuários, as perguntas, ou testes, a que são submetidos os dados acabam por gerar regras inteligíveis, visto que o próprio processo de elicitacão do conhecimento é extremamente simples, na verdade lógico, uma lógica binária.

Um exemplo de árvore de decisão é a escolha de qual a melhor alternativa de investimento, dentre aplicação em títulos públicos, ações ou poupança. O resultado esperado para cada alternativa de investimento depende da ocorrência de um de três cenários possíveis: Crescimento econômico, estagnação ou um ambiente inflacionário, com isso, tendo-se um ponto de decisão, o problema vai escolher o melhor resultado dependendo dos pontos de riscos como opções.

1.1.3 – Aprendizagem por rede neural

Uma rede neural artificial (ou rede neural) é um modelo preditivo motivado pelo forma como o cérebro funciona. Pense no cérebro como uma coleção de neurônios conectados. Cada neurônio olha para a saída de outros neurônios que o alimentam, faz um cálculo e então ele dispara (se o cálculo exceder algum limite) ou não (se não exceder). Redes neurais artificiais consistem de neurônios artificiais, que desenvolvem cálculos similares sobre suas entradas. Redes neurais podem resolver uma variedade de problemas como reconhecimento de caligrafia e detecção facial.

A rede neural mais simples é um perceptron, que aproxima um único neurônio com n entradas binárias. Ela computa a soma ponderada de suas entradas e “dispara” se essa soma for zero ou maior. Entretanto, existem alguns problemas que simplesmente não podem ser resolvidos com apenas um perceptron, com isso, são utilizados conectados entre eles, consistindo por diversas camadas, e formando uma rede neural mais complexa.

1.2. Tratamento dos dados

Para utilização das ferramentas mencionadas anteriormente é fundamental o tratamento de dados, como itens de entradas, para isso os sistemas de trens tem um sistema chamado TCMS (Train control monitoring systems ou Sistema de controle de monitoramento do trem) ao qual é responsável por registrar e monitorar em tempo real eventos que podem potencialmente gerar ocorrências de falhas.

Esse equipamento supervisiona todas variáveis de todas interfaces dos equipamentos, e dependendo do equipamento, o mesmo é isolado eletricamente ou mecanicamente do trem, quando ocorre um evento potencialmente perigoso para a segurança, e apenas é religado com análise técnica ou quando o evento é intermitente.

Entretanto, é relevante utilizar essas ferramentas de aprendizagem em falhas que paralisam o trem na via, ao qual ocorre transtornos para o passageiro e prejuízo para a empresa.

Alguns exemplos dessas ocorrências são as níveis A e B, e que podem ser inspecionadas com a aprendizagem de máquina, algumas delas são abertura das portas do trem automática não funcionar na plataforma das estações, não transmitir portas abertas para o CCO (Centro de controle operacional), trem não realiza a parada programada na estação, aplicação de freio de emergência indevidamente, vazamento forte sob salão de algum carro do trem, abertura da fiação de alguma rede do trem, sequência de chaveamento de potência dos motores de propulsão indevida, entre outras.

Nesse sentido, inicialmente deve ser realizado a mineração de dados, isto é, para cada ocorrência em específico, deve ter-se as entradas, saídas e os algoritmos envolvidos para cada caso, e com isso classificar as probabilidades de a ocorrência reincidir ou não.

2. Estruturação do problema e criação de soluções

2.1. Análise preditiva aplicando aprendizagem de máquina nas ocorrências de falhas

A análise preditiva consiste em aferições imprescindíveis para o bom funcionamento do trem. Nesse sentido, com a mineração de todos os dados e aplicados com algoritmos específicos, serão verificadas possíveis falhas que podem afetar potencialmente em funcionamento normal na via.

Alguns exemplos de inspeções que podem ser verificadas por aprendizagem de máquina são:

- Envio de um sinal de uma porta que não fez seu ciclo devidamente;
- Um sinal que o compressor que não atinge seu rendimento de compressão de ar mínimo;
- Uma antena oscilando no recebimento de um código ou sinal de via, verificando sua impedância em tempo real;
- Um sinal que houve sobrecorrente no conversor de tensão, ou que seu ciclo de funcionamento foi indevido;

- Um alarme que a propulsão dos motores houve sequência de funcionamento indevido, ou que houve sobrecorrente, ou que não houve freio regenerativo;
- Um alarme que a rede ao qual todos equipamentos estão interligados está perdendo estabilidade;
- Um alarme que o sistema de ar condicionado está lendo uma temperatura ambiente indevida;

3. Desafios

3.1. Aplicação prática

Para realizar-se todo esse processo deve ser utilizados softwares que são utilizados em Data Science, para a mineração de dados, e por consequência aprendizagem de máquina. Alguns dos mais conhecidos são o Power BI, ao qual tem boa estruturação para apresentação de Dashboards, ou outros como Tensorflow, Google Cloud ML Engine. Além disso, podem ser utilizados a linguagem de programação Python, ao qual tem uma facilidade no desenvolvimento da mesma e com muitas bibliotecas prontas para utilizar banco de dados.

Além disso, um dos grandes desafios é monitorar todos dados do trem de forma remota, e está em desenvolvimento pontos em estações da via, ao qual podem ser realizados downloads dos registros (log's) de cada trem, por WI-FI, para monitoramento permanente. Nesse sentido, com a aplicação de aprendizagem de máquina, tendo-se a

mineração de dados, serão inspecionados qualquer evento ou alarme que possa evidenciar uma ocorrência, e com isso evitar ao máximo que causem transtornos na via.

Conclusões

Portanto, pode-se inferir que as aplicações dessa ferramentas corroboram para melhorias contínuas em umas das áreas mais importantes do Metrô-SP, pois conforme acontecem as transformações digitais, é necessário que as empresas estejam em constantes adaptações, e com isso, reflita no resultado final, a satisfação total dos passageiros e de uma manutenção mais dinâmica e eficaz em todo o processo.

Por fim, é conceptível que o Machine Learning e todas ferramentas utilizadas no Data Science serão o cotidiano em todas organizações futuramente, e é fundamental o domínio e conhecimento desses sistemas em nossas vidas para desenvolvimento profissional e acadêmico.

26ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
7º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS



REFERÊNCIAS BIBLIOGRÁFICAS

<http://www.eletrica.ufpr.br/ufpr2/professor/36/TE808/5-NaiveBayes-AM.pdf>

<http://professor.luzerna.ifc.edu.br/ricardo-kerschbaumer/wp-content/uploads/sites/43/2018/11/7-Redes-Bayesianas.pdf>

<https://teses.usp.br/teses/disponiveis/3/3143/tde-28032008->

[180226/publico/Alexandre Acacio de Andrade DOUTORADO revisada final.pdf](https://teses.usp.br/teses/disponiveis/3/3143/tde-28032008-180226/publico/Alexandre_Acacio_de_Andrade_DOUTORADO_revisada_final.pdf)