

CATEGORIA 3

MACHINE LEARNING PARA PREVENÇÃO DE ACIDENTES FERROVIÁRIOS

AUTORES

Dhiego Del Persio Iannarelli

Vitor Miguel Braga

Rafael Silva Pinto

Amer Ackel Orra

Vivian de Souza Gasperino

INTRODUÇÃO

É bastante nítido a evolução de geração de dados e informações que as companhias acabam armazenando - por si só, em função intrínseca de suas atividades e/ou através de pesquisas e levantamentos externos que julguem necessárias para os mais variados fins, e, que seriam impensáveis anos atrás – muito devido à velocidade de avanço da tecnologia, em termos de capacidade de armazenamento e extração de valor destes dados em tempo condizente às suas respectivas necessidades. Não de hoje o crescimento às substituições de material físico para os digitalizados, mais do que isso, à

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



conectividade destes materiais com diversas ferramentas e tecnologias – *IoT*, acabam proporcionando dados enriquecedores dos mais variados à Companhia.

É também condição *sine qua non* ao crescimento das companhias, a necessidade de geração de valor e a parceria inegociável para com a sociedade, de modo a existir um crescimento sustentável conjunto, benéfico e agregador para ambas as partes.

Ao coadunar a riqueza de dados e o crescimento sustentável conjunto de todos *stakeholders* envolvidos - sociedade, colaboradores, investidores, companhias e congêneres, pode-se obter um cenário extremamente frutífero, através do reconhecimento de padrões, entendimento de perfis da sociedade e dos clientes, sensibilidade em função de cenários micro e macroeconômicos, possíveis correlações e tendências, análise de riscos, entre outros. Obtendo-se como *output*, informações valiosas, concisas e direcionadoras – de maneira automatizada, para as tomadas de decisões, que agora, são substancialmente estruturadas, contemplando considerações quantitativas e qualitativas das mais diversas variáveis estudadas, visando o melhor cenário a todos os envolvidos.

Atualmente essas avaliações podem ser executadas manualmente por profissionais. Entretanto, em função do grande volume e possíveis combinações entre dados e variáveis, pode-se obter as devidas respostas em tempos não condizentes com a velocidade de mudança do mundo globalizado que estamos enfrentando e evoluindo dia após dia, e, portanto, impactando diretamente na assertividade das tomadas de decisões.

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



Diante disto, a Rumo Logística, impulsionada pela área de Tecnologia e Inovação, vislumbrou um cenário similar de análise de dados atrelado à resolução e/ou mitigação de algum desafio enfrentado no dia a dia de seus negócios e que poderia proporcionar benefícios dos mais variados a todos os envolvidos - direta e indiretamente.

É de extrema importância ressaltar que a segurança é um valor inegociável para a Rumo, a qual tem investido significativamente em diversas frentes – a exemplo de estudos, projetos e campanhas informativas e educacionais. Portanto, a proposta central aqui descrita foi de utilizar da vasta gama de dados disponíveis em nossos sistemas, e, correlaciona-las em benefício da segurança ferroviária.

Assim como diversas outras empresas, na Rumo usava-se um monitoramento tradicional, avaliando-se apenas variáveis de maneira isolada, enquanto que em casos de acidentes, geralmente, ocorre-se uma soma de fatores, ou seja, existe a possibilidade que as variáveis isoladas possam estar todas dentro dos limites estabelecidos como seguros, mas quando combinadas entre si, possam gerar um desequilíbrio e suceder de fato um acidente. Isto posto, se propôs o desenvolvimento de um sistema de predição, que permita avaliar a condição de um trem e de todas as localidades do traçado ferroviário a serem percorridas pelo mesmo, retornando o risco percentual de um possível acidente, determinando as variáveis relevantes para a tomada de decisão do modelo.

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



A partir do momento que fora definido qual a área específica de análise, segmentou-se diversas etapas que poderiam evoluir, em boa parte do estudo, de maneira paralela, e, conseqüentemente, ter-se-iam validações e testes parciais.

Como primeira etapa, reuniu-se diversos especialistas dos mais variados campos de atuação, com o objetivo de entender a respeito da segurança ferroviária sob diferentes perspectivas, englobando os tipos de acidentes existentes, possíveis variáveis influenciadoras, sistemas que armazenam dados a respeito dessas ocorrências – seja dos acidentes seja das variáveis a serem possivelmente monitoradas, configuração do ambiente de arquitetura para coleta dos dados em detalhamento condizente com as necessidades do estudo, definição de esforços, escopo técnico, o fluxo de processos existentes (restrições, correções, manutenções, planejamento de transporte, revestimento, viagem *etc*), entre outros.

Em seguida, fora definido a localidade a ser estudada, selecionando-a em função da quantidade substancial de dados e das problemáticas enfrentadas – quantidade de acidentes e respectivas gravidades, e, sendo assim, fora escolhido um trecho de cerca de duzentos quilômetros em região próxima ao porto de São Francisco, no estado do Paraná. Nesta análise, foram selecionadas três causas primárias de acidentes a serem estudadas (amortecimento, bitola e nivelamento) em função do impacto positivo que as possíveis resoluções proporcionariam - crescimento sustentável conjunto, e da complexidade em questão de obtenção, análise e aplicabilidade dos dados em relação ao tempo de estudo.

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



Diante das causas primárias de acidentes selecionadas - ainda de maneira conjunta com diversos especialistas dos mais variados campos de atuação, foram elencadas variáveis e testes de hipóteses de acidentes, englobando não somente as variáveis levantadas anteriormente, mas outras intrínsecas às hipóteses apontadas, de modo a verificar possíveis indícios de relevantes preditoras para um acidente ferroviário – exemplo: dormentação inservível, abertura de bitola por fixação, desbalanceamento em curva, empeno, balanço de vagão, entre outros.

Isto posto, foi estruturado um arranjo englobando a origem e captura das informações, a consolidação destes dados (de maneira automatizada, reduzindo tempo de trabalho e possíveis erros/equívocos de manipulação manual dos dados), o tratamento, as análises, as correlações em função de dados em tempo real da operação, e, conseqüentemente, a geração de possíveis alertas de acidentes. A título de exemplificação, apenas em oito sistemas levantados que poderiam ser fontes úteis ao estudo, existiam mais de 200 tabelas – fontes de informações estas que são atualizadas periodicamente, reforçando a necessidade de tratamento através de tecnologias apropriadas para este propósito.

DIAGNÓSTICO

O acidente ferroviário pode trazer impactos à sociedade, financeiro à empresa, danos em ativos, redução na qualidade da prestação de serviço e risco à vida.

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



A ANTT (Agência Nacional de Transportes Terrestres) divulgava anualmente dados referentes à acidentes ferroviários, em ANTT (2014) é apresentado a Figura 1, proporção de tipos de acidentes ferroviários que ocorreram no Brasil entre 2006 e 2013.




Figura 1 – Proporção por tipo de acidente ferroviário no Brasil entre 2006 e 2013

Pelos dados apresentados na Figura 1, verifica-se que mais de 50% dos casos de acidentes estão relacionados a material rodante e via permanente. E ainda, o restante das causas são de difícil atuação direta utilizando-se de análise de dados, como vandalismo, interferência de terceiros e falhas humanas (o que representa outros 25% do gráfico).

Na Rumo a situação parecia ser similar, então um diagnóstico foi realizado através de um *design sprint*, técnica de imersão e prototipação muito utilizada (Banfield et al., 2015). Toda a fase de mapeamento, implementação e análise de resultados foi realizada em conjunto à Keyrus, um dos parceiros da Rumo em projetos de ciência de dados.

Dentro da fase de mapeamento foi gerado uma árvore de causas e variáveis para o histórico de acidentes, criada em conjunto com diversos especialistas da Rumo. Na Figura 2 é apresentado conceitualmente a árvore criada.

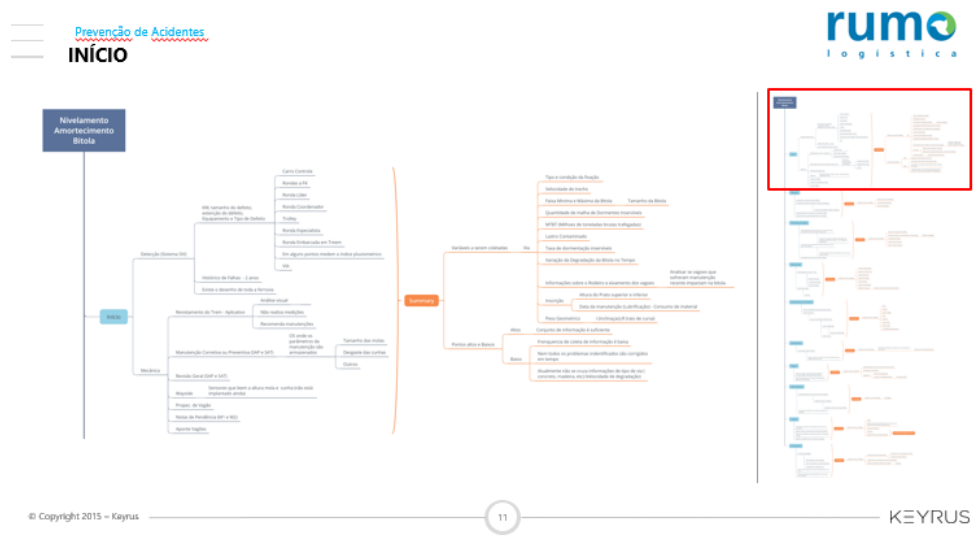


Figura 2 – Exemplo de árvore de causas de acidentes e variáveis

Ao fim da fase de mapeamento, o problema e escopo estavam definidos. O projeto deveria atacar amortecimento, bitola e nivelamento através de diversos dados históricos como manutenção, condução, inspeções, dentro outros, e confrontá-los com o histórico de acidentes. Essas causas (amortecimento, bitola e nivelamento) foram definidas por termos dados gerados diretamente pela empresa, possuírem uma confiança aceitável e que representam significativamente o número de acidentes. Ademais, foi realizada uma matriz considerando o impacto operacional e as dificuldades percebidas em questão de predição. Todavia, qualquer variável pode ser avaliada, sendo relacionada diretamente a essas causas ou não.

TEORIA

De antemão, é de fundamental importância a escolha de um algoritmo de *machine learning* que seja apropriado às grandezas a serem analisadas. Diante disso, foram testados e ponderados os prós e contras de alguns modelos que atendiam ao escopo proposto (entre eles, *XGBoost*, regressão linear, rede neural e *random forest*), e, fora escolhido o *XGBoost* (Chen e Guestrin, 2016) para continuidade do estudo, o qual, por sua vez, costuma ter assertividade elevada e facilidade de implementação, porém, com interpretabilidade mediana, ou seja, dificuldade no entendimento do porquê das decisões do modelo. A escolha pelo *XGBoost* foi pautada pelos resultados iniciais obtidos, o qual apresentou o maior valor em termos de *Precision* entre as quatro opções testadas, assim como, o segundo maior *Recall*.

Como o acidente ferroviário é um evento raro (<1%), a interpretabilidade mediana do algoritmo é aceita, uma vez que sua eficiência é fácil de ser conferida e o impacto de falsos positivos é pequeno na operação ferroviária.

Foram avaliados quatro pilares fundamentais que deveriam ser analisados diante do estudo, sendo: o possível *overfitting* do modelo, existência de classes minoritárias, métricas de resultados e interpretabilidade dos resultados.

Em relação ao *overfitting*, de acordo com a biblioteca *Scikit Learn*, pode-se obter resultados preditivos satisfatórios quando do teste com dados já conhecidos pelo modelo, porém, quando replicado para dados inéditos, pode-se obter resultados

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



insatisfatórios. Para tal, se faz necessário segregarem os dados em duas parcelas, uma para treinamento e uma para teste. Uma metodologia conhecida é o *k-fold*, ou seja, os dados são parcelados em *k* partes, sendo o modelo treinado em *k-1* parcelas e testado na parte restante.

Em relação ao número de parcelas que irão compor a totalidade dos dados (*k*), deve ser ponderado, de modo a tomar em conta os resultados esperados para o modelo e os custos envolvidos para tal.

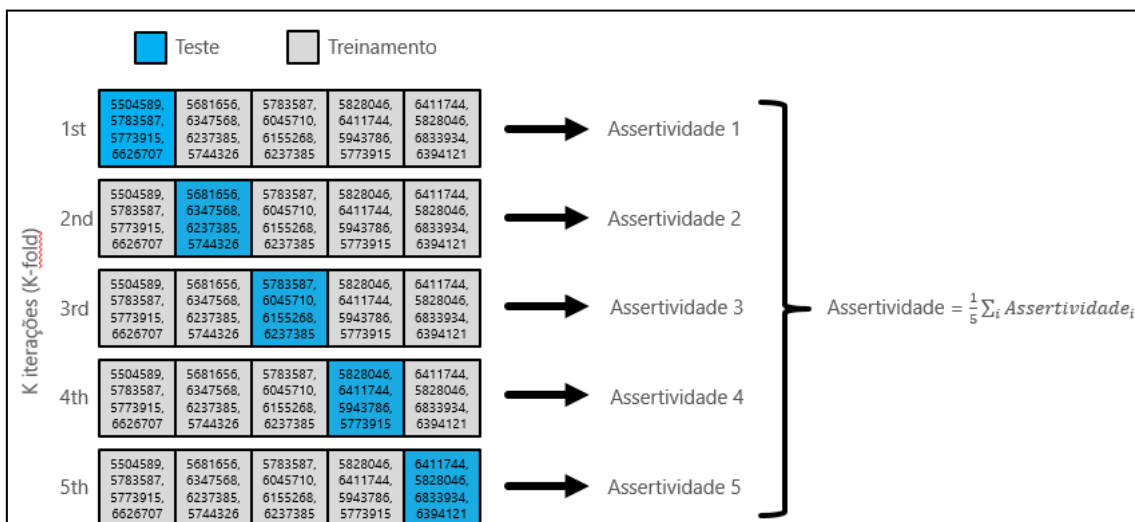


Figura 3 - Validação cruzada K-fold

No que se refere à existência de classes minoritárias, é fundamental atentar-se do cumprimento ou não da condicionante, uma vez que o modelo pode ser enviesado a prever em todas as circunstâncias a favor da classe majoritária, ou seja, em nosso cenário, as predições poderiam ser classificadas como “não acidentes”, e, apesar de fazer a escolha correta em parte substancial das vezes, não estaria contribuindo para o

propósito deste estudo de avaliar/predizer os casos de acidentes - classes minoritárias.

Ou seja, existiria um valor de Revocação elevada, porém, uma Precisão reduzida.

Para tanto, foi adotado a técnica *SMOTE* (*Synthetic Minority Oversampling Technique*), a qual, segundo Chawla, N. V. et al., 2002, tem o objetivo de criar amostras artificiais entre as classes minoritárias, através de uma conexão entre os dados já existentes.

É importante citar, que as amostras artificiais criadas são utilizadas apenas na parte de dados selecionada para treino, ou seja, sem influência direta na parcela destinada a validação. Portanto, as métricas de performance do modelo não são afetadas pela aplicação da técnica em questão.

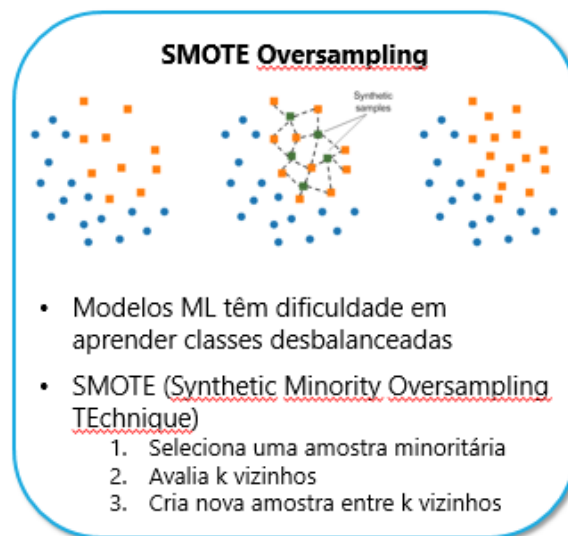


Figura 4 – Exemplificação de técnica SMOTE

Em relação às métricas de resultados do modelo preditivo, utilizou-se de matrizes de confusão, que por sua vez terá como escopo declarar a frequência de cada resultado e sua respectiva classificação na relação entre predição x análise real.

Na prática, o funcionamento ocorre da seguinte maneira:

1. Verdadeiro Positivo: Ocorre quando as predições preveem o acontecimento e de fato ocorre junto ao cenário real estudado;
2. Falso Positivo: Ocorre quando as predições preveem o acontecimento e de fato não ocorre junto ao cenário real estudado;
3. Falso Negativo: Ocorre quando as predições preveem que não ocorrerá o acontecimento, porém, de fato, ocorre junto ao cenário real estudado; e
4. Verdadeiro Negativo: Ocorre quando as predições preveem que não ocorrerá o acontecimento, e, de fato, não ocorre junto ao cenário real estudado.

		Valor Verdadeiro (confirmado pela análise)	
		Positivos	Negativos
Valor Previsto (predito pelo teste)	Positivos	VP Verdadeiro Positivo	FP Falso Positivo
	Negativos	FN Falso Negativo	VN Verdadeiro Negativo

Figura 5 - Matriz de Confusão

Diante disso, é possível calcular duas métricas fundamentais, sendo elas:

$$\textit{Precisão} = \frac{\textit{Verdadeiro Positivo}}{\textit{Verdadeiro Positivo} + \textit{Falso Positivo}}$$

Equação 1 – Fórmula de Precisão

$$\textit{Revocação} = \frac{\textit{Verdadeiro Positivo}}{\textit{Verdadeiro Positivo} + \textit{Falso Negativo}}$$

Equação 2 – Fórmula de Revocação

No tocante à interpretabilidade dos resultados, e, como já mencionado, o modelo *XGBoost* demonstra dificuldade no entendimento da razão das decisões do modelo, o que suscitou a aplicação do modelo *LIME* (*Local Interpretable Model-Agnostic Explanation*). De acordo com Ribeiro, M. T. et al., 2016, trata-se de um algoritmo capaz de proporcionar explicabilidade às variáveis utilizadas no modelo.

Pode-se entender a técnica como responsável pela perturbação das variáveis dispostas como entrada, medindo a variação do resultado do modelo em função da alteração de cada uma dessas variáveis. Dessa maneira, é possível verificar o nível de sensibilidade de cada uma das variáveis no modelo, e, conseqüentemente, qual o impacto/representatividade de cada uma delas, diante do resultado alcançado, ou seja, o entendimento do racional do resultado do modelo preditivo.

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



APLICAÇÃO

Como já disposto, fora realizado um modelo preditivo no trecho próximo ao porto de São Francisco, no estado do Paraná, englobando cerca de duzentos quilômetros de ferrovia.

Neste cenário, foram avaliadas 651 viagens realizadas no ano de 2018, utilizando-se de 104 variáveis extraídas (entre via permanente e material rodante) e proporcionado um *dataset* de dimensão de 651 viagens x 108 variáveis (104 extraídas e 4 integradoras).

As Figuras a seguir apresentam um exemplo do conjunto de variáveis aplicadas ao modelo desenvolvido e as descrições das mesmas. É importante lembrar, que houve uma preocupação em encontrar variáveis além daquelas já existentes – prontas a serem retiradas de sistemas, através da análise das próprias variáveis (valor mínimo, máximo, média *etc*), assim como, de fenômenos e métricas que agrupem mais de uma variável, como é o caso do empeno, da velocidade máxima permitida, do desbalanceamento *etc*.

Nome das Features	Descrição	Descrição
os	Chave	Nº Ordem de Serviço
equipamento	Chave	ID do Equipamento
data	Chave	Data do acidente ou do trem em data aleatória
nd_val_(max,min,median,std)	Via	Nivelamento direito
ne_val_(max,min,median,std)	Via	Nivelamento esquerdo
nt_val_(max,min,median,std)	Via	Nivelamento transversal
nd_val_(max,min,median,std)	Via	Alinhamento direito
ne_val_(max,min,median,std)	Via	Alinhamento esquerdo
bt_val_(max,min,median,std)	Via	Valor Bitola
empeno_(max,min,median,std)	Via	Empeno
velocidade	Via	Velocidade no momento da data (Com ou sem restrição)
acidente	Acidente	Se houve acidente - Variável alvo (0 ou 1)
desbal_diff_vazios	Via/Vagão	Diferença máxima do desbalanceamento de um vagão vazio da composição com o limiar de 15%
acce_diff_vazios	Via/Vagão	Diferença máxima do aceleração transversal de um vagão vazio da composição com o limiar de 0,423m/s ²
desbal_diff_carreg	Via/Vagão	Diferença máxima do desbalanceamento de um vagão carregado da composição com o limiar de 15%
acce_diff_carreg	Via/Vagão	Diferença máxima do aceleração transversal de um vagão carregado da composição com o limiar de 0,423m/s ²
vel_maxima	Via	Velocidade máxima projetada
cv	Via	Flag se é curva (0 ou 1)
raio	Via	Raio do equipamento
rampa	Via	Rampa do equipamento
peso_geometrico	Via	Peso Geométrico do equipamento
superelevacao_diff	Via	Diferença máxima da superelevação real e projetada
restricao_T	Via	Flag restrição temperatura
restricao_V	Via	Flag restrição Via
num_FHD	Vagão	Quantidade de vagões FHD da composição
num_HFD	Vagão	Quantidade de vagões HFD da composição
num_HFE	Vagão	Quantidade de vagões HFE da composição

Figura 6 - Variáveis consideradas em Modelo Preditivo – Parte 1

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



Nome das Features	Descrição	Descrição
num_HFE	Vagão	Quantidade de vagões HFE da composição
num_HPE	Vagão	Quantidade de vagões HPE da composição
num_vazios	Vagão	Quantidade de vagões vazios na composição
num_carreg	Vagão	Quantidade de vagões carregados na composição
mais_cinco_dormentes	Via	Frequência de 5 ou mais dormentes inseríveis
num_locom_frente	Vagão	Número de locomotivas na frente da composição
num_locom_back	Vagão	Número de locomotivas atrás da composição
tamanho_composicao	Vagão	Tamanho da composição
kms_ultima_revisao_geral_(max,min,median,std)	Vagão	Kms desde a última revisão geral
kms_ultima_revisao_regul_(max,min,median,std)	Vagão	Kms desde a última revisão regul.
dias_ultima_revisao_geral_(max,min,median,std)	Vagão	Dias desde a última revisão geral
dias_ultima_revisao_regul_(min,median,std)	Vagão	Dias desde a última revisão regul.
num_vagoes_sem_rg	Vagão	Número de vagões sem revisão geral
num_vagoes_sem_rr	Vagão	Número de vagões sem revisão regul.
num_manutencoes_(max,min,median,std)_acoplament	Vagão	Número de manutenções de acoplamento
num_manutencoes_(max,min,median,std)_freio	Vagão	Número de manutenções de freio
num_manutencoes_(max,min,median,std)_rodeiro	Vagão	Número de manutenções de rodeiro
num_manutencoes_(max,min,median,std)_sist_mecani	Vagão	Número de manutenções de sistema mecânico
num_manutencoes_(max,min,median,std)_truque	Vagão	Número de manutenções de truque
num_avarias_(max,mean)_acidente	Vagão	Número de avarias de acidente registradas
num_avarias_(max,mean)_descarrilado	Vagão	Número de avarias de descarrilamento registradas
num_avarias_(max,mean)_freio	Vagão	Número de avarias de freio registradas
num_avarias_(max,mean)_retencao_incorreta	Vagão	Número de retenções incorreta registradas
num_avarias_(max,mean)_revisao	Vagão	Número de revisões registradas
num_avarias_(max,mean)_rodeiro	Vagão	Número de avarias de rodeiro registradas
num_avarias_(max,mean)_truque	Vagão	Número de avarias de truque registradas
velocidade_max_diff	Via/Vagão	Diferença da velocidade máxima calculada para a velocidade atual da via. Número negativo está acima da velocidade máxima calculada
num_vagoes_acima_vel_max	Via/Vagão	Número de vagões com velocidade acima da velocidade máxima calculada para o vagão

Figura 7 – Variáveis consideradas em Modelo Preditivo – Parte 2

Em relação ao overfitting do modelo, foram separados 80% dos dados para treinamento (520 viagens) e 20% para validação (131 viagens), conforme discutido anteriormente na técnica de *k-fold*.

No que se refere à existência de classes minoritárias, dada a singela quantidade de dados para a análise em questão - 651 viagens de maneira aleatória, onde apenas 18 seriam a variável procurada (acidente), foi realizado um *oversampling* através da técnica *SMOTE* (*Synthetic Minority Oversampling TEchnique*), conforme discutido anteriormente.

Portanto, na figura a seguir é possível verificar que para os dados direcionados para treino, foram criados 492 acidentes sintéticos, figurando com o mesmo número de não acidentes, e, não mais existindo a divergência numérica entre classes minoritárias e majoritárias. É válido lembrar que as métricas de assertividade são baseadas no conjunto de validação, portanto, não sendo influenciados pela criação de acidentes sintéticos.

Descrição:	Dataset:	Divisão de Treino (80%):	Oversampling:	Divisão de Teste (20%):
Não Acidentes:	633	506	506	127
Acidentes:	18	14	506*	4
Total:	651	520	1.012	131

* Sendo 492 sintéticos e 14 dados históricos

Figura 8 - Oversampling

ANÁLISE DOS RESULTADOS

No caso de predição de acidentes ferroviários, a “Precisão” demonstra que quanto maior o seu valor, maior será a eficiência operacional na liberação/saída dos trens para execução de seus trajetos. Isto porque, quanto menor a quantidade de “Falso Positivo” (entenda-se a parada de trens sem a real necessidade, uma vez que o modelo interpretou como risco de acidente, mas no conjunto real, não houve), menor a quantidade de trens que serão interrompidos de maneira errônea.

Por outro lado, em relação à “Revocação”, quanto maior o seu valor, maior será a quantidade correta de predição de acidentes ferroviários. Isso porque, quanto menor a quantidade de “Falso Negativo” (entenda-se menor quantidade de predição de não acidente, mas que de fato ocorreu), menor a quantidade de trens que poderão ser identificados de maneira errônea como sem risco de acidente.

A Figura a seguir apresenta os resultados obtidos em uma das rodadas de testes, avaliando dados históricos de acidentes.




Figura 9 - Resultado do modelo preditivo de acidentes ferroviários

Como demonstrado, observa-se que foram analisadas 651 viagens, dentre os quais, 80% ou 520 viagens, foram utilizadas para treinamento do modelo e 20% ou 131 trens serviram de validação. Dentre os dados de validação, historicamente, é possível afirmar que apenas 4 dentre os 131 trens foram envolvidos em acidentes. Diante do modelo de predição, é possível verificar que houveram 2 “Verdadeiro Positivo” e 1 “Falso Positivo”. Assim sendo, os resultados obtidos pelo modelo preditivo de acidentes ferroviários alcançaram Revocação de 50% e Precisão de 80%.

Através da técnica *LIME*, foi possível entender quais variáveis foram responsáveis em maior ou menor grau na decisão do modelo na classificação entre acidente e não acidente ferroviário. Na Figura a seguir, é possível observar o resultado de uma análise específica utilizando a técnica mencionada para o caso aqui estudado, no qual o modelo classificou corretamente como acidente ferroviário – probabilidade de predição de 27% para não acidente e de 73% para acidente.




Figura 10 - Exemplo adaptado de interpretabilidade do modelo através da técnica LIME

Nota-se que para este exemplo em específico (levando-se em consideração a localidade, o período de análise, os dados históricos estudados, as composições trafegadas, entre outros), as variáveis em cor laranja à direita da Figura acima, são aquelas que impulsionaram o modelo na resposta afirmativa de possibilidade de um acidente ferroviário – 73%, sendo entre elas: máximo de dias desde a última revisão geral, peso geométrico do equipamento e valor máximo de bitola. Por outro lado, as variáveis em cor azul, são aquelas que direcionaram o modelo na resposta negativa de possibilidade de um acidente ferroviário – 27%, sendo: desvio padrão do nivelamento transversal, máximo empeno e máximo valor de alinhamento direito.

CONCLUSÕES

O trabalho realizado apresentou uma metodologia para desenvolvimento de um algoritmo de *Machine Learning* capaz de prever acidentes ferroviários utilizando dados históricos de manutenção de vagão, manutenção de via, inspeção de via, entre outros. Ademais, apresentou os resultados obtidos pela sua aplicação em dados históricos de um pequeno trecho da ferrovia da Rumo Logística.

O modelo preditivo desenvolvido apresentou resultado promissor no que tange seja à predição quanto à explicabilidade de dados. Apresentando assim uma captura (revocação) de 50% dos acidentes estudados e precisão de 80%.

Entretanto, é válido salientar que o melhor cenário que poderíamos observar é o conjunto de informações sendo analisada vagão a vagão, localidade a localidade. Entretanto, por questões sistêmicas dos dados utilizados, não fora possível alcançar este nível de detalhamento, sendo assim, os resultados alcançados referem-se a predição de acidentes com um trem dentro de um intervalo de espaço – neste caso cerca de 200 quilômetros, e tempo – a partir da formação de um trem com origem e destino determinados.

Como próximos passos, o algoritmo está em fase de expansão para todas as localidades da malha ferroviária da Rumo. E ainda está em implementação a precisão de vagão a vagão, no menor intervalo de espaço possível e com diferentes abordagens de modelo

(*random forest*, rede neural, regressão logística, programação genética, entre outros) e técnicas de explicabilidade.

REFERÊNCIAS BIBLIOGRÁFICAS

ANTT. Acidentes Ferroviários Ocorridos no Subsistema Ferroviário Federal no ano de 2013. Disponível em:

<http://www.antt.gov.br/backend/galeria/arquivos/versao_final_relatorio_01201gero_fsufer_1.pdf>. Acesso em: 10/6/2020.

BANFIELD, R.; LOMBARDO, C. T.; WAX, T. **Design Sprint: A Practical Guidebook for Building Great Digital Products**. Sebastopol, CA, Estados Unidos: O'Reilly, 2015.

CHEN, T.; GUESTRIN, C. XGBoost: A Scalable Tree Boosting System. Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. **Anais** . p.785–794, 2016. New York, NY, USA: ACM. Disponível em: <<https://dl.acm.org/doi/10.1145/2939672.2939785>>. .

Chawla, N.V., Bowyer, K. W., Hall, L. O., Kegelmeyer, W.P. **SMOTE: Synthetic Minority Over-sampling Technique**. Journal Of Artificial Intelligence Research, Volume 16, pages 321-357, 2002.

Scikit Learn. **Cross-validation: evaluating estimator performance**. Disponível em: https://scikit-learn.org/stable/modules/cross_validation.html. Acesso em: 22 jun. 2020.

Ribeiro, M.T., Singh, S., Guestrin, C. **Why should I trust you? Explaining the Predictions of Any Classifier**. Disponível em: <https://arxiv.org/abs/1602.04938>. Acesso em: 22 jun.2020.