



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA **11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS**

CATEGORIA 3

Implantação de ferramenta preditiva por inteligência artificial para aumento de produtividade dos maquinistas.

INTRODUÇÃO

O avanço tecnológico nas operações ferroviárias ampliou de sobremaneira o volume de informações geradas e coletadas pelas ferrovias. Este acúmulo de dados nos permite ter suficiência para o uso do aprendizado de máquina (IA) para identificar padrões em eventos passados e fazer previsões sobre eventos futuros, sobretudo pelo log de dados dos sistemas operativos. Deste modo, surge a possibilidade de aumentar a eficiência operacional através de um modelo preditivo, garantindo a qualidade de condução do trem pelos maquinistas.

"O aprendizado de máquina é fundamental para a análise de dados em larga escala e para a tomada de decisões automatizadas. Modelos preditivos baseados em aprendizado de máquina permitem que sistemas detectem padrões e tendências ocultas nos dados, proporcionando



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

insights valiosos que podem ser utilizados em diversos setores” (Alpaydin, E. Aprendizado de Máquina, 2016)

Diante da necessidade de se aumentar a eficiência operacional pelos condutores dos trens, foi desenvolvido por técnicos da SuperVia uma solução interna de IA chamada **SIPAM** – Sistema de Inteligência Preditiva para Avaliação dos Maquinistas, capaz de antecipar quando o maquinista entrará em um ciclo de improdutividade.

Para tal, devido a multiplicidade de distintas fontes de dados a serem analisados, foi elaborada uma arquitetura que consistiu na criação de um banco de dados do tipo Data Warehouse (DW) em ambiente SQL Server, que passou a atuar com nó estruturante de todos os dados disponíveis.

Em busca de mais dados para compor o modelo, além de dados operacionais e pessoais dos maquinistas, foi coletado pelas câmeras alocadas nas cabines dos trens, através de visão computacional, dados de movimentos dos maquinistas durante condução, detectando padrões de movimento para execução de procedimentos de segurança. Também foi criada uma ferramenta complementar através do Power Apps, com o intuito de realizar periodicamente com os maquinistas testes psicotécnicos e comportamentais.

Para manipulação dos dados e desenvolvimento da ferramenta preditiva, foi utilizada a linguagem de programação Python.



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

DIAGNÓSTICO

A operação eficiente dos trens é fundamental para a segurança, pontualidade e satisfação dos passageiros. Com base nessa premissa o estudo traz como base a introdução da ferramenta **SIPAM** – Sistema de Inteligência Preditiva para **A**valiação dos **M**aquinistas, com o intuito de garantir eficiência operacional, proporcionando insights valiosos para a tomada de decisões e a melhoria contínua das operações. Este diagnóstico explora como a implementação desta ferramenta preditiva pode beneficiar uma empresa de trem, focando na otimização da eficiência dos maquinistas.

Identificação das causas de ineficiência operacional dos maquinistas

Os maquinistas da SuperVia enfrentam diversos desafios que podem impactar em sua eficiência operacional, causando um maior número de ocorrências e incidentes:

- Alocação inadequada de turnos que pode levar a fadiga, aumentando os riscos operacionais
- Problemas psicológicos que podem levar ao estresse físico/mental, comprometendo seu desempenho.
- Falta de orientação e treinamentos contínuos de reciclagem.
- Pressão por cumprimento de metas e procedimentos inadequados.



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

Proposta da ferramenta SIPAM

A ferramenta SIPAM utiliza algoritmos de aprendizado de máquina para analisar dados históricos e em tempo real, fornecendo previsões e recomendações para otimizar a eficiência operacional dos maquinistas. As principais funcionalidades são:

Treinamento Personalizado: Com base no desempenho individual dos maquinistas, utilização de dados históricos e outros modos de avaliação a ferramenta retorna um farol de alerta para cada maquinista, recomendando programas de treinamento personalizados para abordar áreas de melhoria específicas, antes que o desempenho dos maquinistas diminua.

Análise de fadiga: Utilizando dados históricos de turnos, a ferramenta pode prever períodos de alta fadiga entre os maquinistas através do mesmo farol de alerta e recomendar ajustes na programação para minimizar riscos.

Metodologia de Implementação

A implementação da ferramenta preditiva segue um processo estruturado para garantir a eficácia e integração suave com os sistemas existentes. Atualmente o SIPAM se encontra em fase de homologação, sendo testada com um grupo seletivo de maquinista.

Abaixo todos os processos aplicados:

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

1. Coleta de dados: Integração de fontes de dados existentes, incluindo registros de turnos, tempo de viagem, tempo de condução, inspeção de execução de procedimentos na condução por maquinista, acidente e incidentes por maquinista, quantidade de equipagens.

2. Criação de um banco de dados: Para facilitar a integração de fontes para o modelo, criou-se uma arquitetura que consistiu na criação de um banco de dados do tipo Data Warehouse (DW) em ambiente SQL Server, centralizando todas as informações e variáveis a serem utilizadas no modelo:

The screenshot shows a SQL query window with the following SQL code:

```
SELECT TOP (1000) [data]
, [tipo_prefixo]
, [prefixo]
, [nome_ramal]
, [composicao]
, [serie]
, [extra]
, [partida_real]
, [hora_real]
, [periodo_real]
, [chegada_real]
, [partida_programada]
, [hora_programada]
, [periodo_prog]
, [chegada_programada]
, [maquinista]
, [servico]
```

The results are displayed in a table with the following columns: `ida`, `periodo_prog`, `chegada_programada`, `maquinista`, `servico`, `tipo_viagem`, `descricao_sentido`, `siof_viagem_jd`, and `fluxo_realizado`.

ida	periodo_prog	chegada_programada	maquinista	servico	tipo_viagem	descricao_sentido	siof_viagem_jd	fluxo_realizado	
1	PM	07:15:00	FAD	Parador	Viagem Comercial	Ímpar	3366131	não	
2	PM	07:10:00	FAB	JO	Parador	Viagem Comercial	Par	3366132	sim
3	PM	08:39:00	FAB	JO	Parador	Viagem Comercial	Ímpar	3366133	não
4	PM	08:50:00	FAD	Parador	Viagem Comercial	Par	3366134	sim	
5	VD	10:09:00	REN	ITOS	Parador	Viagem Comercial	Ímpar	3366135	não
6	VD	10:20:00	FAB	JO	Parador	Viagem Comercial	Par	3366136	não
7	VD	11:39:00	FAB	JO	Parador	Viagem Comercial	Ímpar	3366137	não
8	VD	11:40:00	REN	ITOS	Parador	Viagem Comercial	Par	3366138	não
9	VD	13:15:00	REN	ITOS	Parador	Viagem Comercial	Ímpar	3366139	não
10	VD	13:10:00	FAB	JO	Parador	Viagem Comercial	Par	3366140	não

The status bar at the bottom indicates: "Consulta executada com êxito. CCOSRVDB10 (11.0 SP1) gerencial (81) GERENCIAL 00:00:06 1.000 linhas".

Figura 1 – Tabela estruturada do banco de dados gerencial para o modelo preditivo



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

3. Desenvolvimento do Modelo: no desenvolvimento modelo utilizamos com entrada 4 indicadores dos dados citados para caso de envolvimento com acidente ou incidentes com uma entrada de 30 dias antes da ocorrência, da mesma forma e feita com maquinistas não envolvidos com alguma ocorrência, mas selecionando os maquinistas e dias de referência de forma aleatória. Isto retorna um total de 120 variáveis, inicialmente.

Com a entrada de novos indicadores e refinamento do modelo (fator que reduz número total de entradas necessárias para um resultado preditivo, o número inicial tende a reduzir ao final do desenvolvimento.

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

4. Modelo: Esses dados são trabalhados com o modelo *Random Forest* para treinamento e refinamento da estimativa de risco do envolvimento do maquinista com uma nova ocorrência.

```
import pandas as pd
from sklearn.model_selection import train_test_split
from sklearn.ensemble import RandomForestClassifier
from sklearn.metrics import mean_squared_error, r2_score

df = pd.read_excel('BaseTreino.xlsx')
df.fillna(0, inplace=True)
colunas = df.columns

X = df[colunas[0: len(colunas)-1]]
y = df[colunas[-1]]

# Dividindo os dados em conjuntos de treino e teste
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42)

# Inicializando e treinando o modelo de regressão linear
modelo = RandomForestClassifier(n_estimators=100, random_state=42)
modelo.fit(X_train, y_train)

# Fazendo previsões nos dados de teste
y_pred = modelo.predict(X_test)
print(X_test)
# Avaliando o modelo
mse = mean_squared_error(y_test, y_pred)
r2 = r2_score(y_test, y_pred)

print("Erro médio quadrático (MSE):", mse)
print("Coeficiente de determinação (R^2):", r2)
```

Figura 2 - Modelo Preditivo "Random Forest" em Python

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

5. Teste e validação: Teste da ferramenta em um ambiente controlado para validar suas previsões e ajustes necessários para melhorar a precisão.

6. Desenvolvimento de visão computacional para complementar o modelo: Detectar padrões de movimento para execução de procedimentos de segurança. Abaixo é um frame de um vídeo resgatado de uma câmera localizada na cabine de um trem da série 3000, na parte superior direita.



Figura 3 - Gravação realizada dentro da cabine de condução

Na sequência, um script em Python é executado, ele separa o vídeo em seus frames e para cada frame aplica um modelo de inteligência artificial e visão computacional do



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

tipo estimador de pose. Este modelo é treinado para reconhecer pessoas e detectar 17 pontos específicos do corpo humano, conforme a Figura 6:

- Nariz, Olho esquerdo, Olho direito, Orelha, Orelha direita, Ombro esquerdo, Ombro direito, Cotovelo esquerdo, Cotovelo direito, Punho esquerdo, Punho direito, Quadril esquerdo, Quadril direito, Joelho esquerdo, Joelho direito, tornozelo esquerdo e tornozelo direito.

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS




Figura 4 - Modelo de Estimador de Pose



Figura 5 - Cabine do maquinista com script em Python



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

Desenvolvimento de um aplicativo psicotécnico para complementar o modelo: Um dos modelos escolhidos para avaliar o comportamento dos maquinistas e ser utilizado como uma das medidas para o modelo preditivo foi a utilização de testes psicotécnicos. Foi desenvolvido um aplicativo na ferramenta Power Apps, da Microsoft.

Esta aplicação é composta por um teste dividido em duas etapas. A primeira etapa consiste em avaliar a coordenação motora do maquinista, com círculos que aparecem na tela e mudam de posição constantemente. O avaliado terá que clicar nos alvos antes que mudem de posição novamente. A cada clique correto, soma-se pontos. Nesta etapa, há quatro níveis, e a cada nível, o intervalo de tempo em que os pontos mudam de posição diminui, dificultando o processo.

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS



Figura 6 - Aplicativo de aplicação de teste psicotécnico e coordenação.

Na segunda etapa, o maquinista faz um teste com 10 perguntas envolvendo lógica, baseadas principalmente em análise de padrões e progressões aritméticas.

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

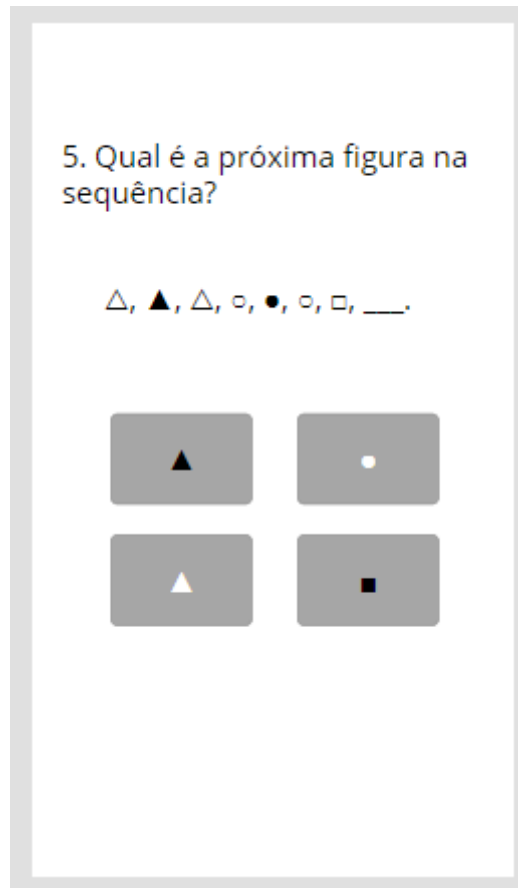


Figura 7 - Segunda etapa do aplicativo psicotécnico

As duas etapas do teste têm como objetivo avaliar aspectos como atenção, concentração e tempo de reação, características essenciais para um bom desempenho.

O modelo preditivo avaliará o resultado do teste como um todo e associará com os outros parâmetros de análise, buscando prever quais são as condições favorecem uma possível perda de rendimento futuro.



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA **11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS**

Tanto a visão computacional quanto o aplicativo psicotécnico estão atualmente em fase de homologação. Esses sistemas estão sendo testados periodicamente com um grupo seletivo de maquinistas para garantir sua eficácia e precisão.

Apesar do progresso, ambos os sistemas ainda não foram incorporados ao modelo operacional principal. Isso se deve ao fato de que nossa base de teste ainda é relativamente pequena, o que limita a robustez das conclusões que podemos tirar neste estágio. Além disso, a máquina está em um estágio crucial de aprendizagem das informações, necessitando de mais dados e ajustes para alcançar um nível de precisão e confiabilidade aceitável.

7. Implementação Gradual: Lançamento gradual da ferramenta, começando com um grupo piloto de maquinistas e expandindo para toda a operação após validação bem-sucedida.
8. Monitoramento e Ajuste Contínuos: Monitoramento contínuo da eficácia da ferramenta e ajustes baseados no feedback dos usuários e nos dados de desempenho.
9. Ferramenta em Power BI com o farol de alerta por maquinista: relatório em Power BI com sistema de cores (verde, amarelo, vermelho) indicando a situação geral dos maquinistas de acordo com a resposta do modelo testado. Verde para normal,



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

amarelo para atenção e vermelho para ação imediata. Este sistema de acompanhamento tem como objetivo identificar e monitorar os maquinistas antes que eles entrem em uma curva de improdutividade, permitindo intervenções proativas.

10. Implementação de treinamento para os maquinistas com farol em atenção:

Sugestão de treinamentos adicionais baseadas no “farol de maquinistas” e aplicados antes que qualquer tendência de improdutividade se consolide. Este enfoque holístico não só melhorará a segurança e a eficiência operacional, mas também promoverá o bem-estar e o desenvolvimento contínuo dos maquinistas.

- Treinamento de Condução Preventiva
- Workshops de Saúde Mental e Bem-Estar
- Sessões de Feedback Personalizado
- Simulações de Cenários de Emergência

ANÁLISE DOS RESULTADOS

A ferramenta preditiva “SIMPAM” começou a ser desenvolvida em mar/24 e está atualmente em fase de homologação. Embora ainda não tenhamos todos os resultados



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

completos, os dados preliminares são promissores e indicam um potencial significativo para otimizar nossas operações, no sentido de antecipar problemas e oportunidades nas operações, permitindo ações proativas que aumentem a eficiência e a segurança dos maquinistas.

Durante a fase de homologação, a ferramenta está sendo testada com um grupo de maquinistas em um ambiente controlado. Os testes são realizados periodicamente para coletar dados abrangentes que alimentarão o algoritmo de aprendizagem da máquina. Esta abordagem nos permite ajustar os parâmetros da ferramenta e melhorar a precisão das previsões.

Os dados preliminares já nos permitem ter as primeiras indicações, representadas no painel de farol dos maquinistas.

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA
11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

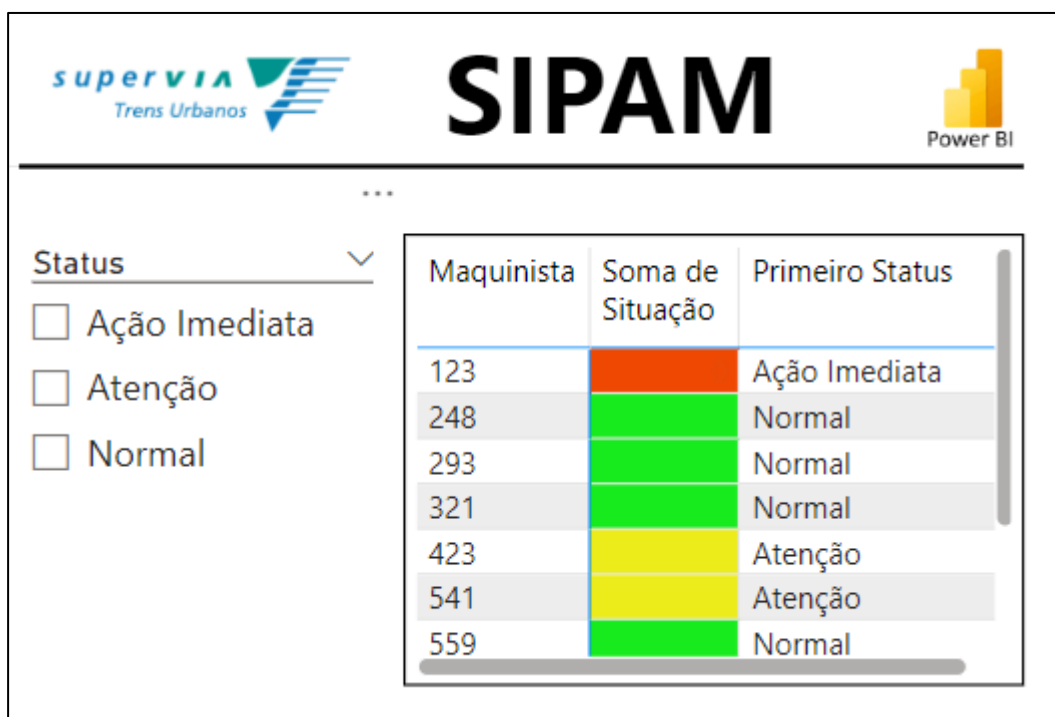


Figura 8 – Painel Power BI

Os primeiros resultados têm sido encorajadores e indicam dentro do cronograma estabelecido uma expectativa muito otimista quanto a eficácia da ferramenta.

Próximos passos

Para concluir a fase de homologação e avançar para a implementação completa, planejamos as seguintes ações:



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA

11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

1. Aprendizagem Contínua: Concluir a fase de aprendizagem das informações dentro do cronograma estabelecido, até o refino eficaz do algoritmo.
2. Aprimoramento dos Algoritmos: Continuar a refinar os algoritmos de aprendizagem da máquina com base nos novos dados coletados (Visão Computacional e Aplicativo Psicotécnico), melhorando a precisão e a confiabilidade das previsões.
3. Treinamento dos maquinistas: Avaliar o grupo amostral de maquinista e realizar treinamento preventivo com os maquinistas que já apresenta farol de atenção.
4. Avaliação de aumento da eficiência operacional: Analisar se houve uma melhoria na eficiência operacional das equipes que utilizaram as previsões fornecidas pela ferramenta, resultando em aumento da produtividade e queda nos acidentes e incidente.
5. Expansão da Base de Teste: Aumentar o número de maquinistas envolvidos nos testes para obter uma amostra mais diversificada e representativa.

30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

6. Aplicação da ferramenta: Incluir a ferramenta no processo da tração e aplicar a mesma efetivamente.

	jan/24	fev/24	mar/24	abr/24	mai/24	jun/24	jul/24	ago/24	set/24	out/24	nov/24	dez/24	jan/25
Reuniões de Alinhamento													
Coleta de dados													
Criação do banco													
Desenvolvimento do Modelo													
Criação do Aplicativo Psicotécnico													
Desenvolvimento da Visão Computacional													
Começo de teste com um grupo de Maquinista													
Ferramenta em Power BI (Farol)													
Aprendizagem do Modelo													
Aprimoramento do Modelo													
Treinamento com os primeiros maquinistas													
Avaliação dos Resultados													
Expansão da Base de Teste													
Aplicação final da ferramenta													

Figura 9 – Cronograma

CONCLUSÕES

A fase de homologação da ferramenta preditiva SIPAM (Sistema de Inteligência Preditiva para Avaliação dos Maquinistas) tem revelado resultados preliminares promissores, indicando um potencial significativo para transformar as operações ferroviárias. A análise preditiva oferecida pela SIPAM, fundamentada em algoritmos de aprendizado de máquina e IA, mostra-se capaz de antecipar problemas operacionais e identificar



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

oportunidades de melhoria, permitindo uma gestão mais proativa e eficiente dos maquinistas.

O compromisso com a implementação gradual e monitoramento contínuo garante que a ferramenta seja ajustada conforme necessário, atendendo às demandas operacionais e promovendo a melhoria contínua. O farol de alerta personalizado, aliado a programas de treinamento específicos, proporciona uma abordagem holística para manter a produtividade e o desempenho dos maquinistas em níveis elevados.

O plano de expansão e refinamento contínuo dos algoritmos é um passo crucial para assegurar a robustez e a confiabilidade da ferramenta. A ampliação da base de dados, a inclusão de novas fontes de informação, e o treinamento contínuo dos maquinistas contribuirão para o desenvolvimento de um modelo preditivo ainda mais preciso e eficaz.

Em suma, a SIPAM representa uma inovação significativa no setor ferroviário, com o potencial de redefinir padrões de eficiência e segurança. A continuidade dos testes, a coleta de dados adicionais e o feedback constante dos usuários serão fundamentais para a consolidação desta ferramenta como um recurso indispensável para a SuperVia. O



30ª SEMANA DE TECNOLOGIA METROFERROVIÁRIA 11º PRÊMIO TECNOLOGIA E DESENVOLVIMENTO METROFERROVIÁRIOS

futuro da operação ferroviária, com o auxílio da SIPAM, vislumbra um cenário de maior previsibilidade, segurança e produtividade, beneficiando tanto os maquinistas quanto os passageiros.

REFERÊNCIAS BIBLIOGRÁFICAS

Alpaydin, E. (2016). *Aprendizado de Máquina*. Tradução de Marcelo El Khouri Bouson. Porto Alegre: Bookman

Araújo, A. de, & Falcão, A. X. (2008). "Processamento Digital de Imagens." Thomson Learning.

Visão geral da criação de aplicativos no Power Apps. 2024

Consultado em

<https://learn.microsoft.com/pt-br/power-apps/maker/>