

Uso de Sensores Virtuais para Estimativa do Fluxo de Minério de Ferro em Correias Transportadoras

Thiago Machado Martins

Programa de Pós-Graduação em
Instrumentação, Controle e
Automação de Processos de Mineração
(PROFICAM)
Escola de Minas, Universidade Federal
de Ouro Preto (UFOP), em Associação
com o Instituto Tecnológico Vale (ITV)
MG, Brasil
thiago.machado@vale.com

Aginaldo José da Rocha Reis
Departamento de Engenharia de
Controle e Automação
Escola de Minas, Universidade Federal
de Ouro Preto
MG, Brasil
reis@ufop.edu.br

Rosa Elvira Correa Pábon
Instituto Tecnológico Vale, Mineração
Ouro Preto, MG, Brasil
rosa.correa@itv.org

Resumo — Apresenta-se neste trabalho o desenvolvimento de um sensor virtual integrado a um equipamento do tipo Correia Transportadora (CT), com o objetivo de estimar o fluxo de material transportado. O sensor utiliza como variáveis de entrada a corrente elétrica (A) e a velocidade dos motores (RPM) de um Virador de Vagões, configurando-se como alternativa às balanças integradoras tradicionais. A base de dados empregada foi composta por medições reais de uma planta industrial da empresa Vale S.A., localizada no setor portuário de minério de ferro. Foram aplicadas técnicas de Aprendizado de Máquina, como Regressão Linear, Árvores de Decisão, *Random Forest*, *Gradient Boosting* e Perceptrons de Múltiplas Camadas, no desenvolvimento dos sensores virtuais. O sensor proposto possui potencial para ser incorporado ao processo produtivo, representando uma contribuição significativa para o monitoramento do fluxo em ambientes industriais onde esse tipo de sensor ainda não é utilizado.

Palavras-chaves — *Sensor Virtual; Correia Transportadora; Aprendizado de Máquina; Estimador de fluxo; Minério de Ferro; Virador de vagões.*

I. INTRODUÇÃO

Em 2022, a produção mineral brasileira atingiu US\$48 bilhões, representando 12% das exportações do país e contribuindo com 40% do saldo comercial nacional [1].

A Vale SA é uma das maiores empresas de mineração do mundo, presente em 20 países, com sede no Brasil, possuindo operações na América do Sul, América do Norte, Europa, África, Oriente e Ásia. Além da mineração, a empresa também atua na logística, possuindo ferrovias, portos, terminais e infraestrutura.

A quantificação do material transportado e, consequentemente, a medição da vazão em correias transportadoras são fundamentais para o controle operacional e a otimização dos processos industriais. No entanto, em muitas instalações, sensores diretos como balanças integradoras não estão presentes, devido ao alto custo de aquisição e à complexidade associada à sua manutenção.

No Porto de Tubarão, terminal de minério de ferro, localizado em Vitória - ES, o monitoramento do fluxo de material transportado (Fig. 1) é essencial para garantir a eficiência operacional e evitar problemas como entupimentos, desalinhamento e desgaste prematuro das Correias Transportadoras (CTs). O material transportado é pesado em movimento nas balanças integradoras instaladas nas CTs. A balança mede a massa do material na CT (kg/m) por meio de

células de carga, sendo que a velocidade da CT (m/s) é obtida via sensor específico de velocidade. A unidade kg/m refere-se à massa por unidade de comprimento da correia que está sobre o conjunto de células de carga. No caso deste estudo, a balança utilizada possui um comprimento de 4 metros, o qual corresponde ao trecho da correia considerado para a medição da massa. A vazão instantânea (t/h) é então calculada multiplicando-se a saída da balança pela velocidade da CT, sendo que o total processado num dado período de interesse também é calculado [2] (Fig. 2).

Diante desse contexto, em específico, propõe-se neste artigo o desenvolvimento de um Sensor Virtual (SV) do tipo estimador de fluxo de material, que tem como entradas as grandezas: corrente elétrica e velocidade dos motores dos alimentadores do Virador de Vagões 01 (VV01), que é uma estrutura robusta capaz de girar até 180° um par de vagões simultaneamente, realizando o descarregamento de minério em silos. O VV01 foi escolhido como piloto devido à ausência de medição confiável de vazão em seus alimentadores. A balança integradora mais próxima pode estar a minutos de distância, conforme a rota utilizada. De posse das estimativas obtidas, apresenta-se no artigo um comparativo de desempenho entre os SVs propostos e a balança integradora instalada na CT a montante do VV01. Para tanto, as técnicas de Regressão Linear, *Random Forest*, Perceptrons de Múltiplas Camadas, Árvores de Decisão e *Gradient Boosting* foram empregadas nos sensores virtuais aqui desenvolvidos, com o objetivo de se identificar a abordagem mais adequada para implementação em campo. Os pormenores dessa implementação serão apresentados nas próximas seções. A propósito, este artigo está organizado como se segue. Na Seção II, os trabalhos correlatos ao aqui apresentado são analisados. Os materiais e métodos empregados no texto são assunto da Seção III. Já na Seção IV, os resultados obtidos são descritos e analisados. As principais conclusões e sugestões de trabalhos futuros são apresentadas na Seção V. Finaliza-se o artigo com os agradecimentos e uma lista com as referências consultadas.

II. TRABALHOS CORRELATOS

Estudos anteriores sobre correias transportadoras destacam estimativas de fluxo baseadas em consumo de energia elétrica e técnicas de Aprendizado de Máquina, com foco predominante em transportadores ascendentes e equipamentos com balanças integradoras. Propõe-se neste trabalho uma abordagem inovadora ao utilizar dados de um virador de vagões como entradas para sensores virtuais,

realizando estimativas em tempo real com frequência de 1 segundo — configuração não identificada na literatura consultada.




Fig. 1: Fluxo de minério de ferro no Terminal de Tubarão.




Fig. 2: Arranjo típico de uma balança integradora.

Väyrynen [3] realizou testes em planta de britagem utilizando dados reais de energia elétrica em correias inclinadas, comparando-os com medições de balanças integradoras. A abordagem demonstrou alta acurácia, com erro médio de 1,12% e máximo de 2,33% em um dia de operação, validada em dois casos de controle de processo industrial. Esses resultados são comparáveis aos erros típicos de calibração de balanças, que variam de 0,5 a 1% sob carga nominal (70 a 90%) e podem atingir até 3% em faixas mais amplas de carga (20 a 100%).

Lopes [4] analisou dados operacionais de corrente elétrica dos motores de uma Recuperadora de Caçambas em ambiente industrial, correlacionando-os com medições de vazão obtidas por balança integradora instalada na correia transportadora. A relação identificada foi utilizada para estimar o fluxo de recuperação de minério, com resultados que indicam a corrente como um indicador confiável para inferência de vazão nesse tipo de equipamento.

Moreira, Euzébio e Miola [5] desenvolveram um sensor virtual de baixo custo para medir a vazão mássica em correias transportadoras, baseado no modelo de [3]. O método, que relaciona o consumo de energia elétrica à elevação do material, mostrou-se eficaz em transportadores ascendentes, com erro médio de $\pm 4\%$. Essa abordagem permitiu medições em fluxos intermediários, aprimorando o controle da taxa horária e potencializando a produtividade.

Sobreira et al. [6] desenvolveram cinco sensores virtuais para estimar o fluxo de minério em correias transportadoras, utilizando dados reais coletados em planta industrial da Vale S.A., no complexo de S11D. As abordagens empregaram Redes Neurais Artificiais (RNA) e algoritmos de aprendizado de máquina baseados em árvore de decisão (M5P, REPTree e *Random Forest*), com variáveis de entrada como corrente, torque e velocidade do motor do Hopper — compartimento de alimentação responsável por armazenar e liberar o minério de

forma controlada para a correia. Os modelos apresentaram alto desempenho, com coeficientes de determinação (R^2) superiores a 0,94 e erros percentuais entre 0,70% e 1,61%. Dois sensores foram implementados em CLPs no complexo S11D, demonstrando a viabilidade dos sensores virtuais como alternativa para monitoramento em correias sem balança.

Com relação aos critérios de desempenho dos modelos aqui desenvolvidos, os índices MAE, RMSE e coeficiente R^2 foram empregados. Chai e Draxler [7] destacam que o MAE é uma métrica robusta e amplamente utilizada para avaliar a precisão de modelos preditivos em diversas áreas de estudo, incluindo meteorologia, economia e engenharia. Trata-se de um índice capaz de fornecer uma estimativa direta do erro médio. Por outro lado, Jolliffe e Stephenson [8] destacam que o RMSE é útil para avaliar modelos quando se deseja penalizar erros maiores. Por fim, segundo Enders [9], o coeficiente de determinação R^2 é uma medida que avalia a capacidade de um modelo prever ou explicar um resultado no contexto da Regressão Linear (RL). Em suma, R^2 indica a proporção da variância na variável dependente (Y) que é explicada pela RL e a variável independente (X). Tal coeficiente varia entre 0 e 1.

III. MATERIAIS E MÉTODOS

O presente estudo foi conduzido por meio do emprego de dados reais obtidos do Virador de Vagão 01 (VV01) e da Correia Transportadora A01 (CT-A01) do Terminal de Minério de Ferro, localizado no Porto de Tubarão, Vitória/ES, pertencente à empresa Vale SA. A escolha do VV01 deve-se à sua importância no processo de descarregamento de minério, etapa crítica e primordial da logística do terminal. Além disso, não foram identificados estudos que utilizem dados de viradores de vagões no desenvolvimento de estimadores de fluxo de minério com sensores virtuais. No estágio atual, os dados relativos à corrente e à velocidade dos motores dos dois alimentadores do VV01 foram utilizados para estimar o fluxo de material. A escolha dessas entradas foi feita principalmente com base nos trabalhos de [4] e [6], e no cálculo da matriz de correlação, que segundo Miot [10], é uma tabela bidimensional onde cada célula contém o coeficiente de correlação entre dois pares de colunas. Os valores dentro da matriz variam de -1 a 1, onde -1 representa uma correlação negativa forte, 0 representa nenhuma correlação e 1 representa uma correlação positiva forte. No caso em estudo, os coeficientes de correlação com a vazão da balança foram: Corrente Motor Alimentador Sul: 0,78; Corrente Motor Alimentador Norte: 0,77; Velocidade Motor Alimentador Sul: 0,47; Velocidade Motor Alimentador Norte: 0,45. Tais índices foram computados com a função `df.corr` da biblioteca *Pandas* para Python [11] e indicam correlação forte entre vazão e corrente, e correlação moderada entre vazão e velocidade, se alinhando, de certa forma, aos achados das referências [4] e [6]. Os sensores virtuais desenvolvidos neste estudo realizam estimativas de fluxo a cada 1s.

As estimativas obtidas por cinco estratégias distintas foram comparadas às medidas obtidas com a balança integradora presente no processo (ver Fig. 3) e são analisadas em detalhes na Seção IV.

A. Coleta de Dados

Todos os dados operacionais do processo cadastrado são coletados e armazenados no sistema PIMS (*Process Information Management Systems*), permanecendo disponíveis para análises posteriores. Esses sistemas são

conhecidos como historiadores, pois têm como função principal armazenar dados de plantas industriais por muitos anos.




Fig. 3: Sensores Virtuais desenvolvidos.

Foram utilizadas 2.824.596 amostras coletadas entre 01/01 e 31/12/2023, com intervalo de 1 segundo. A corrente elétrica dos motores variou entre 0,1 A e 70,0 A, com média de 55,83 A. A velocidade dos motores variou entre 0 RPM e 1.800 RPM, com média de 902,88 RPM. A vazão medida pela balança apresentou valores entre 4,13 t/h e 6.000 t/h, com média de 3.776,31 t/h. A análise exploratória apontou uma distribuição estável das variáveis, com baixa incidência de outliers, o que reforça a confiabilidade da base para análises de correlação e modelagem estatística. Apresenta-se na Tabela I um recorte de parte dos dados utilizados com os parâmetros de interesse, tais como: data, horário, vazão (t/h), corrente elétrica (A) dos motores dos alimentadores sul e norte (ALS e ALN) e velocidade dos motores em rotações por minuto (RPM). Já a Fig. 4 apresenta os dados normalizados e sincronizados de corrente e velocidade dos alimentadores ALN e ALS, bem como da vazão registrada pela balança da CT-A01, ao longo de um intervalo de 2 minutos. A sincronização, realizada com atraso de 35 s entre os sinais — correspondente ao tempo de deslocamento do material até a balança — permite evidenciar a correlação entre as variáveis envolvidas.

B. Preparação do Conjunto de Dados

Após a coleta, os dados foram analisados para verificar a necessidade de pré-processamento, etapa fundamental no desenvolvimento de modelos no contexto de Aprendizado de Máquina (AM). Esse processo envolveu técnicas para transformar os dados brutos em um formato que garantisse qualidade, consistência e relevância [12]. Neste trabalho, o pré-processamento aplicado aos dados coletados envolveu as seguintes etapas:

- Valores ausentes (ou *missing data*) nas colunas numéricas foram preenchidos com a média de cada coluna, evitando lacunas na base de dados;
- Valores extremos (ou outliers) foram removidos com base no z-score (± 3 desvios padrão), e os valores ausentes resultantes foram preenchidos com a média de cada coluna, evitando lacunas na base de dados.
- As variáveis independentes foram padronizadas de modo a apresentar média zero e desvio padrão unitário;
- Valores negativos do fluxo de minério, observados com transportador vazio, foram substituídos por zero, a fim de manter a coerência dos dados;
- Para estabelecer a relação entre as variáveis independentes (corrente e velocidade) e a variável dependente (vazão da balança), foi necessário realizar a sincronização desses dados por meio da introdução de um atraso que representa o intervalo entre as medições. Isso se deve ao fato de que, ao sair dos alimentadores (moega), o minério percorre toda a

extensão de uma correia transportadora e ainda uma certa distância adicional até alcançar a balança instalada na Correia Transportadora A01 (CT-A01). Esse atraso foi identificado por meio de análise de gráficos sequenciais e do cálculo do coeficiente de correlação para diferentes defasagens temporais, utilizando a função `df.corr()` da biblioteca Pandas para Python [11], sendo que o valor encontrado foi de 35s (ver Fig. 5).




Fig. 4: Dados normalizados e sincronizados de corrente e velocidade dos motores dos alimentadores ALN e ALS, e da vazão medida pela balança A01, ao longo de um intervalo de 2 minutos. A sincronização considerou um atraso de 35 s entre os sinais, permitindo visualizar a correlação entre as variáveis.

TABELA I. DADOS DE CORRENTE E VELOCIDADE DOS MOTORES DOS ALIMENTADORES DO VV01 E VAZÃO NA BALANÇA DA CT-A01

Data Hora	Corr. M1 ALN (A)	Corr. M1 ALS (A)	Veloc. M1 ALN (RPM)	Veloc. M1 ALS (RPM)	Vazão BAL_CT (t/h)
01-jan-23 12:09:00	61,03	61,03	6427,00	6427,00	4410,50
01-jan-23 12:09:01	61,00	61,00	6427,00	6427,00	4435,70
01-jan-23 12:09:02	61,03	61,00	6427,00	6427,00	4456,38
01-jan-23 12:09:03	61,00	61,00	6427,00	6427,00	4444,82
01-jan-23 12:09:04	61,00	61,00	6427,00	6427,00	4420,20
01-jan-23 12:09:05	61,00	61,00	6427,00	6427,00	4400,05
01-jan-23 12:09:06	60,62	60,62	6427,00	6427,00	4391,43
01-jan-23 12:09:07	60,22	60,22	6427,00	6427,00	4377,82
01-jan-23 12:09:08	59,82	59,82	6427,00	6427,00	4392,58
01-jan-23 12:09:09	59,42	59,42	6427,00	6427,00	4412,39
01-jan-23 12:09:10	59,02	59,02	6427,00	6427,00	4428,90




Fig. 5: Correlação cruzada e deslocamento entre corrente e velocidade dos motores dos alimentadores e vazão da balança da correia transportadora.

C. Análise Comparativa de Diferentes Conjuntos de Dados para Treinamento e Teste dos Sensores Virtuais

Vários experimentos foram conduzidos no desenvolvimento dos sensores virtuais, tendo sido testadas diferentes configurações de treinamento, validação e teste, além de três janelas de dados distintas: 7×7 dias, 30×30 dias e 60×30 dias. Especificamente, a janela 7×7 corresponde à coleta de 7 dias de dados para treinamento e 7 dias para teste; a janela 30×30 compreende 30 dias para treinamento e 30 dias para teste; e a janela 60×30 utiliza 60 dias de dados para treinamento e 30 dias para teste. Dentro de cada janela de treinamento, os dados foram divididos em 80% para treino e 20% para validação, enquanto os dados da janela de teste foram utilizados integralmente para avaliação final dos modelos. A escolha das janelas de dados foi realizada de forma experimental, buscando avaliar o impacto do tamanho do conjunto de treino e teste no desempenho dos modelos. Esses intervalos foram selecionados para abranger diferentes escalas temporais e permitir a análise de tendências de curto e médio prazo na estimativa de fluxo da CT. Ainda que a escolha específica dessas janelas não tenha sido baseada em um critério fixo pré-estabelecido, ela seguiu a lógica de avaliar diferentes escalas temporais de aprendizado, permitindo uma análise mais ampla do comportamento dos algoritmos em distintos cenários práticos e que foram avaliados segundo os índices MAE, RMSE e coeficiente R².

D. Modelos de Regressão

D.1 Modelo Regressão Linear

A Regressão Linear, um dos métodos mais simples de AM, foi implementada neste trabalho utilizando a classe `LinearRegression()` do `scikit-learn` [13]. O modelo foi treinado e testado para avaliar tanto seu ajuste aos dados quanto sua capacidade de generalização. É considerado como um *benchmark* neste trabalho.

D.2 Modelo Árvore de Decisão

O modelo de regressão com Árvore de Decisão adotado neste estudo foi implementado por meio da classe `DecisionTreeRegressor` da biblioteca `scikit-learn` [14], com o objetivo de modelar a relação entre as variáveis independentes e a variável dependente. Inicialmente, o modelo foi configurado com profundidade máxima igual a 10 (`max_depth=10`), visando mitigar o risco de sobreajuste (*overfitting*), e com semente aleatória fixa (`random_state=42`), a fim de garantir a reprodutibilidade dos resultados. Essas escolhas foram baseadas em experimentações e em referências técnicas.

Para a avaliação do desempenho do modelo, utilizou-se a técnica de Validação Cruzada K-Fold com 15 subdivisões ($K=15$), por meio da função `GridSearchCV` [15], que também permitiu a otimização dos hiperparâmetros. Essa abordagem possibilitou uma estimativa mais robusta da capacidade de generalização do modelo, ao dividir iterativamente os dados de treinamento em subconjuntos distintos para treino e validação. A escolha por 15 divisões foi baseada em critérios empíricos, com o objetivo de equilibrar robustez estatística e custo computacional. A busca em grade — `GridSearchCV` (Python, `Scikit-learn`) — permitiu identificar as combinações de hiperparâmetros mais adequadas ao conjunto de dados, contribuindo para a melhoria do desempenho preditivo. Os principais hiperparâmetros ajustados são apresentados na Tabela II.

TABELA II. HIPERPARÂMETROS AJUSTADOS DO MODELO ÁRVORE DE DECISÃO

Parâmetro	Descrição	Faixa de Valores
<code>max_depth</code>	Profundidade máxima da árvore. Controla a complexidade e evita o <i>overfitting</i> .	[4, 6, 8, 10]
<code>min_samples_split</code>	Número mínimo de amostras para dividir um nó interno.	[5, 10]
<code>min_samples_leaf</code>	Número mínimo de amostras de cada folha. Suaviza o modelo e reduz a variância.	[3, 5]
<code>ccp_alpha</code>	Parâmetro de poda por complexidade. Remove ramos com pouca relevância.	[0.001, 0.01]

E. Modelo Random Forest

O modelo *Random Forest* foi implementado neste estudo utilizando a classe `RandomForestRegressor` do módulo *ensemble* da biblioteca `scikit-learn` [16]. Inicialmente instanciado com configuração padrão, o modelo passou por ajuste de hiperparâmetros por meio de validação cruzada com `GridSearchCV`, explorando um conjunto predefinido de combinações. Na configuração inicial, foram utilizados os seguintes parâmetros: `n_estimators=200` (número de árvores), para ampliar a capacidade preditiva do ensemble; `max_depth=10`, limitando a profundidade das árvores a fim de controlar a complexidade e evitar sobreajuste; e `random_state=42`, garantindo reprodutibilidade dos resultados. Além disso, foi utilizada paralelização (`n_jobs=-1`) para otimizar o tempo de treinamento. A validação foi conduzida com K-Fold Cross Validation, configurada com $k=15$, equilibrando custo computacional e robustez estatística. Essas escolhas foram baseadas em experimentação e em referências técnicas. Durante o processo de ajuste, o critério de avaliação adotado também foi o erro absoluto médio negativo. A Tabela III resume os principais hiperparâmetros ajustados e suas funções.

TABELA III. HIPERPARÂMETROS AJUSTADOS DO MODELO RANDOM FOREST

Parâmetro	Descrição	Faixa de Valores
<code>n_estimators</code>	Número de árvores no conjunto. Aumenta a capacidade preditiva do modelo.	[50, 75, 100]
<code>max_depth</code>	Profundidade máxima de cada árvore. Controla a complexidade e evita <i>overfitting</i> .	[5, 10, 15, 20]
<code>min_samples_split</code>	Número mínimo de amostras para dividir um nó interno. Reduz divisões irrelevantes.	[50, 100, 150]
<code>min_samples_leaf</code>	Número mínimo de amostras por folha. Suaviza o modelo e reduz variância.	[20, 50, 100]
<code>max_features</code>	Proporção de variáveis avaliadas por divisão. Introduce diversidade entre as árvores.	[0.5, 0.7, 0.9]

F. Modelo Gradient Boosting

O modelo *Gradient Boosting*, implementado com a biblioteca `XGBoost` [17], foi desenvolvido com foco em equilíbrio entre desempenho preditivo e complexidade computacional. Utilizou-se a classe `XGBRegressor`, inicialmente configurada com 200 estimadores, profundidade máxima de 6 níveis, taxa de aprendizado de 0,1 e `random_state=42`. O treinamento foi acelerado por meio da paralelização automática dos processos (`n_jobs=-1`),

permitindo o uso simultâneo de todos os núcleos disponíveis do processador. Enfim, essa configuração inicial buscou garantir estabilidade no treinamento, favorecendo uma convergência controlada e mitigando o risco de sobreajuste. Essas escolhas foram baseadas em experimentação e em referências técnicas.

A etapa de otimização foi realizada por meio de GridSearchCV, com validação cruzada utilizando 15 divisões (K-Fold Cross Validation). Esse procedimento forneceu uma avaliação abrangente da capacidade de generalização do modelo, explorando múltiplas partições do conjunto de dados. O critério de avaliação adotado também foi o erro absoluto médio negativo (neg_mean_absolute_error). A Tabela IV apresenta os hiperparâmetros ajustados para o modelo XGBoost.

TABELA IV. HIPERPARÂMETROS AJUSTADOS DO MODELO GRADIENT BOOSTING

Parâmetro	Descrição	Faixa de Valores
n_estimators	Número de árvores no conjunto. Aumenta a capacidade preditiva do modelo.	[100, 200]
max_depth	Profundidade máxima de cada árvore. Controla a complexidade e evita overfitting.	[3, 4, 5]
learning_rate	Taxa de aprendizado. Controla o impacto de cada árvore na correção dos erros anteriores.	[0.01, 0.05, 0.1]
reg_lambda	Termo de regularização L2. Penaliza grandes coeficientes, reduzindo a variância do modelo.	[10, 20, 50]
reg_alpha	Termo de regularização L1. Promove sparsidade, contribuindo para modelos mais simples e robustos.	[5, 10, 15]
subsample	Proporção de amostras utilizadas para o treinamento de cada árvore. Introduce diversidade e reduz sobreajuste.	[0.6, 0.7, 0.8]
colsample_bytree	Proporção de variáveis consideradas em cada árvore. Melhora a generalização e reduz correlação entre árvores.	[0.5, 0.6, 0.7]

G. Modelo Perceptrons de Múltiplas Camadas (PMC)

O modelo MLPRegressor, da biblioteca scikit-learn [14], foi implementado com o objetivo de capturar relações não lineares nos dados por meio de uma rede neural artificial. A configuração do modelo incluiu até 2000 iterações para o ajuste dos pesos e random_state = 42 para garantir a reprodutibilidade dos resultados.

A otimização dos hiperparâmetros foi conduzida com o auxílio da classe GridSearchCV, utilizando validação cruzada do tipo K-Fold com 15 divisões, assegurando uma avaliação consistente da capacidade de generalização do modelo. Esse método divide o conjunto de dados de treinamento em múltiplos subconjuntos, permitindo que cada partição seja utilizada alternadamente para treinamento e validação ao longo das iterações. A execução foi otimizada por meio da configuração n_jobs=-1, que permitiu a distribuição paralela das tarefas de ajuste entre todos os núcleos lógicos disponíveis, reduzindo significativamente o tempo de treinamento. O critério de avaliação adotado no processo também foi o erro absoluto médio negativo (neg_mean_absolute_error).

A Tabela V apresenta os principais hiperparâmetros ajustados do modelo Perceptron de Múltiplas Camadas

(PMC). A definição dos valores foi guiada por experimentação sucessiva, com base em práticas consolidadas na literatura. O objetivo foi maximizar a capacidade de aprendizado do modelo, promovendo estabilidade durante o treinamento e reduzindo o risco de sobreajuste.

TABELA V. HIPERPARÂMETROS AJUSTADOS DO MODELO PERCEPTRONS DE MÚLTIPLAS CAMADAS

Parâmetro	Descrição	Faixa de Valores
hidden_layer_sizes	Define a arquitetura da rede: número de camadas ocultas e neurônios em cada uma. Controla a capacidade de aprendizado.	[(5,), (6,), (7,), (8,), (9,), (10,)]
learning_rate_init	Taxa de aprendizado inicial. Determina o tamanho das atualizações dos pesos a cada iteração.	[0.001, 0.01]
activation	Função de ativação não linear. Foram testadas: relu, eficiente em redes profundas, e tanh, que favorece convergência suave.	[relu, tanh]
solver	Algoritmo de otimização. Utilizou-se adam, baseado em gradiente estocástico adaptativo.	[adam]
alpha	Termo de regularização L2. Penaliza grandes valores de peso para mitigar o sobreajuste.	[0.0001, 0.001]

H. Implementação dos Algoritmos

Para implementar os algoritmos de AM, foi utilizado a linguagem Python 3.6 (via Spyder 3.12), instalada no SO Windows 10 64 bits. O ambiente de execução foi uma máquina equipada com um processador Intel Core i5-8365U, 8 GB de memória RAM e uma placa de vídeo Intel UHD Graphics 620.

IV. RESULTADOS E DISCUSSÕES

Para fins de comparação, todos os modelos foram treinados com a mesma base de dados, visando identificar o melhor desempenho e promover um ranqueamento entre eles. Eles foram avaliados quanto à sua capacidade de estimar o fluxo de minério de ferro, utilizando os mesmos dados de entrada e critérios de avaliação, a fim de possibilitar uma comparação justa entre as abordagens. As métricas utilizadas incluíram o MAE, RMSE e o Coeficiente R². As Tabelas VI e VII sintetizam os resultados obtidos, apresentando as configurações de treinamento e teste, assim como as métricas de desempenho para as três janelas de dados distintas analisadas: 7x7 dias, 30x30 dias e 60x30 dias.

A. Análise dos Resultados – Janela 7x7

A Regressão Linear, embora simples, apresentou desempenho competitivo, com um R² de 0,95, erro percentual de 5,49% em relação à balança, MAE de 329,60 t/h e RMSE de 522,61 t/h. Contudo, a limitação quanto à modelagem de relações não lineares contribuiu para erros médios mais elevados em comparação aos modelos mais sofisticados. Já a Árvore de Decisão superou a Regressão Linear em termos de MAE (242,66 t/h), com melhora no erro percentual (4,04%) se comparado a balança e R² (0,96), demonstrando maior capacidade de captar variações nos dados. No entanto, o RMSE manteve-se elevado (467,81 t/h), indicando sensibilidade a erros pontuais mais altos. Entre os modelos testados, o *Random Forest* destacou-se com o melhor desempenho geral, apresentando o menor MAE (206,25 t/h), o menor RMSE (430,95 t/h) e o maior R² (0,97), além de um

menor erro percentual (3,43%) se comparado à balança. Essa superioridade se deve, em parte, à sua robustez frente ao overfitting e à diversidade gerada pelo ensemble de árvores. Já o *Gradient Boosting* apresentou resultados consistentes com MAE de 213,50 t/h, R^2 de 0,96, erro percentual de 3,55% se comparado à balança e RMSE de 473,80 t/h beneficiando-se da capacidade do modelo em corrigir erros residuais de maneira sequencial. Seu desempenho próximo ao melhor modelo reforça sua adequação em tarefas de regressão com dados complexos. Por fim, o modelo PMC, obteve desempenho satisfatório ($R^2 = 0,96$), mas com MAE de 215,08 t/h (erro de 3,58% se comparado à balança) — superior aos demais modelos baseados em árvores e RMSE de 479,35 t/h.

B. Análise dos Resultados – Janela 30x30

Na configuração de janela 30x30, observou-se leve variação nos desempenhos dos modelos. A Regressão Linear manteve um bom desempenho, com R^2 de 0,94, MAE de 315,80 t/h e RMSE de 562,70 t/h. Apesar de continuar competitiva, a limitação na captura de não linearidades ainda impõe restrições à sua eficácia preditiva em cenários com maior volume de dados. A Árvore de Decisão apresentou leve piora em relação à janela 7x7, com aumento no MAE (283,63 t/h) e RMSE (645,63 t/h), além de uma pequena redução no R^2 (0,93). Isso sugere que, embora ela tenha elevada capacidade de generalização, sua performance pode ser afetada pelo aumento da janela temporal. Já o *Random Forest* apresentou R^2 de 0,95, com MAE de 226,65 t/h e RMSE de 497,35 t/h, consolidando sua eficácia mesmo com maior quantidade de dados históricos. O *Gradient Boosting*, por sua vez, teve desempenho semelhante, com MAE de 221,00 t/h, RMSE de 496,50 t/h e R^2 de 0,95, reforçando sua capacidade de modelar padrões complexos por meio da correção sequencial de erros. Por fim, o PMC apresentou desempenho inferior aos modelos baseados em árvores, com MAE de 292,30 t/h, RMSE de 608,75 t/h e R^2 de 0,93.

C. Análise dos Resultados – Janela 60x30

Com a janela de 60x30, alguns modelos apresentaram estabilidade, enquanto outros mostraram maior sensibilidade à ampliação da base de dados. A Regressão Linear manteve desempenho semelhante ao observado nas demais janelas, com R^2 de 0,94, MAE de 285,92 t/h e RMSE de 544,10 t/h, demonstrando consistência, mas novamente limitada por sua natureza linear. A Árvore de Decisão obteve seu melhor desempenho nesta configuração, com MAE de 210,86 t/h, RMSE de 513,50 t/h e R^2 de 0,96. Esse resultado indica que o modelo conseguiu aproveitar a maior amplitude dos dados para capturar variações de maneira mais eficaz, ainda que com sensibilidade a picos de erro. Já o *Random Forest* apresentou uma pequena queda no desempenho comparado à janela 30x30, com aumento no MAE (248,50 t/h) e RMSE (551,70 t/h), além de redução no R^2 (0,94). O *Gradient Boosting*, por sua vez, apresentou resultados ligeiramente inferiores aos da Árvore de Decisão, com MAE de 214,95 t/h, RMSE de 513,75 t/h e R^2 de 0,95. Mesmo diante da ampliação da janela, o modelo mostrou-se estável, mantendo bom equilíbrio entre erro e poder explicativo. Por fim, o PMC teve desempenho intermediário, com MAE de 246,35 t/h, RMSE de 555,75 t/h e R^2 de 0,94. Embora com desempenho inferior aos modelos baseados em *boosting* e árvores de decisão, com o aumento de dados, a rede neural apresentou resultados comparáveis aos do *Random Forest*.

D. Análise dos Resultados – Escolha da Janela 7x7

A análise comparativa das três janelas temporais (7x7, 30x30 e 60x30) evidencia o impacto do volume de dados históricos no desempenho dos modelos de regressão. A Regressão Linear demonstrou desempenho consistente nas três janelas, com melhora gradual nos erros absolutos (MAE e RMSE) à medida que mais dados foram considerados. Já a Árvore de Decisão apresentou flutuações, com desempenho inferior na janela 30x30, mas melhora significativa na 60x30, sugerindo que sua capacidade de modelar regras pode se beneficiar de maiores intervalos temporais quando há padrões bem definidos. Por outro lado, o *Random Forest*, que inicialmente se destacou com a menor taxa de erro na janela 7x7, perdeu desempenho nas janelas maiores, especialmente na 60x30. Já o *Gradient Boosting* parece ser o modelo que menos se mostrou sensível às variações das janelas de dados. Por fim, o PMC apresentou desempenho intermediário, sendo superado pelos modelos baseados em árvores nesta abordagem e nas condições consideradas. Todos esses resultados estão compilados nas Tabelas VI e VII.

Em suma, a janela de 7x7 favoreceu os modelos mais sofisticados, especialmente o *Random Forest*, enquanto a 60x30 beneficiou a Árvore de Decisão. Já o *Gradient Boosting* mostrou-se mais equilibrado entre as janelas, sugerindo ser uma opção robusta em diferentes contextos de previsão de vazão. Dessa forma, optou-se pela janela 7x7 como principal abordagem neste trabalho por conciliar elevado desempenho preditivo e menor custo computacional, sendo mais adequada para aplicações práticas que exigem resposta ágil e uso eficiente de recursos.

TABELA VI. ANÁLISE DE RESULTADOS DOS MODELOS (REGRESSÃO LINEAR, ÁRVORE DE DECISÃO E *RANDOM FOREST*)

Dataset Quant. (Dias)		Predição Balança (Regressão Linear)			Predição Balança (Árvore de Decisão)			Predição Balança (<i>Random Forest</i>)		
Treino	Teste	MAE (t/h)	MAE (t/h)	R^2	MAE (t/h)	MAE (t/h)	R^2	MAE (t/h)	MAE (t/h)	R^2
7	7	329,60	522,61	0,95	242,66	467,81	0,96	206,25	430,95	0,97
30	30	315,80	562,70	0,94	283,92	645,63	0,93	226,65	497,35	0,95
60	30	285,92	544,10	0,94	210,86	513,50	0,95	248,50	551,70	0,94

TABELA VII. ANÁLISE DE RESULTADOS DOS MODELOS (*GRADIENT BOOSTING* E PMC)

Dataset Quant. (Dias)		Predição Balança (<i>Gradient Boosting</i>)			Predição Balança (PMC)		
Treino	Teste	MAE (t/h)	MAE (t/h)	R^2	MAE (t/h)	RMSE (t/h)	R^2
7	7	213,50	473,80	0,96	215,08	479,35	0,96
30	30	221,00	496,50	0,95	292,30	608,75	0,93
60	30	214,95	513,75	0,95	246,35	555,75	0,94

A título de exemplo, a Fig.6 permite uma comparação entre medições da balança integradora e as estimativas feitas com o sensor virtual baseado em *Random Forest* num intervalo de cerca de 16,67min (1000s).




Fig. 6: Medições da balança integradora e estimativas realizadas pelo Sensor Virtual *Random Forest*.

V. CONCLUSÕES

O modelo *Random Forest* apresentou o melhor desempenho na estimativa do fluxo de minério de ferro em correias transportadoras, com coeficiente de determinação R^2 de 0,97 e erro médio absoluto (MAE) de 206 t/h. Apesar de esse erro representar cerca de 3,4%, valor ligeiramente superior ao erro típico de calibração das balanças integradoras (2 a 3% para faixas de carga entre 20 e 100%), o modelo se mostra como uma alternativa viável para correias transportadoras sem balanças, que normalmente utilizam medições indiretas com taxas de erro superiores às observadas neste trabalho.

O desenvolvimento de um sensor virtual integrado a um equipamento do tipo Correia Transportadora foi o foco deste estudo. O sensor virtual proposto utilizou como entradas as grandezas corrente elétrica (A) e velocidade dos motores (RPM) de um virador de vagões, visando estimar o fluxo de material (t/h) transportado por uma CT. Os dados utilizados foram reais, coletados em uma planta industrial da empresa Vale S.A., e cinco técnicas de Aprendizado de Máquina foram empregadas no desenvolvimento dos sensores virtuais candidatos, avaliados com base nos índices MAE, RMSE e R^2 .

Os sensores virtuais desenvolvidos foram inicialmente concebidos como uma simulação para avaliar a viabilidade de estimar o fluxo de minério sem a necessidade de balanças integradoras, cuja instalação e manutenção envolvem altos custos e complexidade. Os resultados obtidos demonstram que é possível realizar essa estimativa com base em variáveis operacionais, como corrente elétrica e velocidade dos motores, por meio de algoritmos de aprendizado de máquina.

Além da viabilidade técnica e econômica, destaca-se que tanto a iniciativa de se considerar corrente elétrica e velocidade dos motores de um virador de vagões como entradas do sensor virtual quanto a estimativa de fluxo de material realizada a cada 1 segundo não foram encontradas na pesquisa bibliográfica realizada, o que confere características inovadoras ao presente trabalho. Os resultados reforçam o potencial do modelo em oferecer previsões confiáveis para fluxos de material em condições industriais reais, além de abrir caminho para futuras melhorias no monitoramento dos processos industriais.

Como trabalhos futuros, propõe-se a implementação do sensor virtual desenvolvido em um Controlador Lógico Programável (CLP) existente na planta do Terminal de Minério de Ferro, permitindo sua integração automatizada ao sistema industrial. Além disso, com o sensor virtual proposto neste artigo, busca-se estimar, em tempo real, o fluxo de material a partir de variáveis facilmente acessíveis, como a corrente do motor e sua velocidade — configurando um típico

problema de regressão. A propósito, optou-se por esta abordagem, por se tratar de um trabalho preliminar e inédito no contexto do setor da empresa onde será implantado. Abordagens mais avançadas, especialmente aquelas relacionadas à modelagem de séries temporais para a previsão de múltiplos passos à frente, por exemplo, são reconhecidas como potenciais aprimoramentos e ficam também indicadas como trabalhos futuros.

AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001, do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPQ), do Instituto Tecnológico Vale (ITV) e da Universidade Federal de Ouro Preto (UFOP).

REFERÊNCIAS

- [1] AGÊNCIA NACIONAL DE MINERAÇÃO. Disponível em: <https://ibram.org.br/noticia/ibram-apresenta-panorama-do-setor-mineral-brasileiro-no-enic-2023>. Acesso em: 24 jan. 2025.
- [2] BRXSISTEMAS. Balança Integradora de Correia. Disponível em: <http://brxsistemas.com.br/produtos.php?id=13>. Acesso em: 24 jan. 2025.
- [3] HULTHÉN, Erik. Real-time optimization of cone crushers. 2010. 168 f. Dissertação (Ph.D.) - Chalmers University of Technology, 2010.
- [4] LOPES, Bruno Eduardo. Bulk material reclaim control system. [S.l.]: Google Patents, 2015. US Patent 9,073,701.
- [5] MOREIRA, V. D. S.; EUZÉBIO, Thiago Antônio Melo; MIOLA, Wilson. Aplicação de soft sensor de baixo custo para medição de vazão mássica de minério em transportador de correia. *Anais do XIII Simpósio Brasileiro de Automação Inteligente-SBAI*, p. 1905-1910, 2017.
- [6] SOBREIRA, Sandro G. A. et al. A data-driven soft sensor for mass flow estimation. *IEEE Transactions on Instrumentation and Measurement*, v. 72, p. 1-9, 2023.
- [7] CHAI, Tianfeng; DRAXLER, Roland R. Root mean square error (RMSE) or mean absolute error (MAE)? - Arguments against avoiding RMSE in the literature *Geoscientific Model Development*, v. 7, n. 3, p. 1247-1250, 2014.
- [8] JOLLIFFE, Ian T.; STEPHENSON, David B. (Ed.). *Forecast verification: a practitioner's guide in atmospheric science*. Chichester: John Wiley & Sons, 2012.
- [9] ENDERS, F. B. Coefficient of Determination | Interpretation & Equation | Britannica, 4 out. 2022. (Nota técnica).
- [10] MIOT, Hélio Amante. Correlation analysis in clinical and experimental studies. *Jornal vascular brasileiro*, v. 17, p. 275-279, 2018.
- [11] pandas.DataFrame.corr — pandas 2.2.2 documentation. Disponível em: <https://pandas.pydata.org/docs/reference/api/pandas.DataFrame.corr.html>. Acesso em: 4 jun. 2025.
- [12] KOTSIANTIS, Sotiris B. et al. Supervised machine learning: A review of classification techniques. *Emerging Artificial Intelligence Applications in Computer Engineering*, v. 160, n. 1, p. 3-24, 2007.
- [13] SCIKIT-LEARN DEVELOPERS. *scikit-learn: Machine learning in Python*. 2019. Disponível em: <https://scikit-learn.org/stable/>. Acesso em: 15 mar. 2025.
- [14] sklearn.tree.DecisionTreeRegressor — scikit-learn 0.23.1 documentation. Disponível em: <https://scikit-learn.org/stable/modules/generated/sklearn.tree.DecisionTreeRegressor.html#sklearn.tree.DecisionTreeRegressor>. Acesso em: 15 mar. 2025.
- [15] sklearn.model_selection.GridSearchCV — scikit-learn 1.4.2 documentation. Disponível em: https://scikit-learn.org/stable/modules/generated/sklearn.model_selection.GridSearchCV.html. Acesso em: 4 jun. 2025.
- [16] SCIKIT-LEARN. 3.2.4.3.2. sklearn.ensemble.RandomForestRegressor — scikit-learn 0.20.3 documentation. Disponível em: <https://scikit-learn.org/stable/modules/generated/sklearn.ensemble.RandomForestRegressor.html>. Acesso em: 15 mar. 2025.

- [17] Gradient Boosting regression. Disponível em: <https://scikit-learn.org/stable/auto_examples/ensemble/plot_gradient_boosting_regression.html>. Acesso em: 15 mar. 2025.
- [18] sklearn.neural_network.MLPRegressor — scikit-learn 0.21.3 documentation. Disponível em: <https://scikit-learn.org/stable/modules/generated/sklearn.neural_network.MLPRegressor.html>. Acesso em: 15 mar. 2025.