

PREDIÇÃO DE FALHAS EM PROCESSOS LOGÍSTICOS: DESENVOLVIMENTO E VALIDAÇÃO DE UM MODELO PREDITIVO

FAILURE PREDICTION IN LOGISTICS PROCESSES: DEVELOPMENT AND VALIDATION OF A PREDICTIVE MODEL

Rafael Paula dos Santos

Faculdade de Tecnologia “Adib Moisés Dib” de São Bernardo do Campo

rafael.santos357@fatec.sp.gov.br

André Mardegam

Faculdade de Tecnologia “Adib Moisés Dib” de São Bernardo do Campo

andré.mardegam@fatec.sp.gov.br

Prof. Dr. Marcelo Tsuguio Okano

Faculdade de Tecnologia “Adib Moisés Dib” de São Bernardo do Campo

marcelo.okano@fatec.sp.gov.br

Resumo

Na atual configuração de emergência, falhas operacionais na expedição levam a atrasos na entrega de materiais, o que compromete o atendimento ao cliente. Este trabalho explora uma proposta de desenvolvimento de machine learning com abordagem preditiva, destinada a prever falhas em processos logísticos, mais especificamente em expedições emergenciais de material cirúrgico. Utilizou-se a metodologia Design Science Research, o estudo resultou em um artefato preditivo apoiado na técnica de Regressão Linear, aplicado na ferramenta Knime. Para a construção do modelo, foram coletados dados utilizados para treinamento e validação extraídos do sistema de armazém, totalizando 20.368 expedições, das quais 1.697 atenderam a emergências. O modelo desenvolvido foi validado estatisticamente como R^2 de 97%, o que confirma a precisão do modelo em prever falhas antes que ocorram. Conclui-se, portanto, que a aplicação de modelos de predição aplicados em processos logísticos pode aumentar o índice de atendimento a emergência com a diminuir atrasos, além de fornecer aos gestores.

Palavras-chave: Machine Learning, regressão linear, Knime, logística, modelo, desperdícios; expedição.

Abstract

In the current emergency configuration, operational failures in dispatch lead to delays in material delivery, compromising customer service. This work explores a proposal for the development of a machine learning model with a predictive approach, aimed at forecasting failures in logistical processes, specifically in emergency dispatches of surgical materials. The Design Science Research methodology was employed, resulting in a predictive artifact supported by the Linear Regression technique, applied through the Knime tool. For model construction, data used for training and validation were collected from the warehouse system, totaling 20,368 dispatches, of which 1,697 were for emergencies. The developed model was statistically validated with an R^2 of 97%, confirming the model's accuracy in predicting failures before they occur. It is concluded, therefore, that the application of predictive models in logistical processes can increase emergency response rates by reducing delays, in addition to providing valuable insights to managers.

Keywords: Machine Learning, Linear Regression, Knime, Logistics, Model, Waste, Dispatch.

1. Introdução

No cenário contemporâneo, caracterizado por uma economia globalizada e dinâmica, em que a eficiência dos esforços operacionais pode ser convertida em maximização de recursos, a capacidade de melhorar os processos logísticos é um fator crítico para a competitividade (Mendes, 2017). Apesar dos esforços realizados para atingir graus ideais de produtividade e eficiência, há áreas onde ainda permanecem desafios fundamentais, provando a necessidade de abordagens estruturadas, padronização, gestão das rotinas, otimização dos processos (CHAPMAN et al., 2020).

Para conseguir uma otimização bem sucedida dos processos logísticos, é importante ter em conta alguns aspectos fundamentais. São eles: mapeamentos, programas de gestão, simulação, capacidade de implementação de melhorias, sustentabilidade, previsão de falhas em seus processos (Wang; O'brien, 2021). A capacidade de prever falhas pode ser interpretada como um método estruturado que permite atuação antes da realização do desvio do processo, para isso é utilizado modelos estatísticos para inferir o comportamento do processo ao longo do tempo, mantendo o processo sob controle (ASSAGAF, 2023).

Neste artigo, utilizamos um modelo de regressão preditiva para identificar falhas de serviço. O objetivo deste trabalho é desenvolver um modelo de aprendizado de máquina aplicado em uma plataforma para prever falhas de serviços e oportunidades de otimização de processos logísticos.

2. Referencial teórico

No referencial teórico são desenvolvidos as bases para o desenvolvimento do artefato, cobrindo os seguintes temas: desperdícios em processos logísticos, otimização de processos, análise de regressão e machine learning.

2.1 Desperdícios em processos logísticos

Se a empresa tem como meta o crescimento sustentável, aumento da eficiência e produtividade, e a redução de custos, o desperdício de recursos em processos logísticos é uma das etapas a superar. Segundo Shen (2005), o resultado da não correspondência entre um levantamento do espaço e a atividade produtiva do armazém gera desperdício. Explica ainda que estes desperdícios incluem a ociosidade de equipamentos, instalações e pessoas, tempo de espera, transporte e movimentação de materiais, que afeta diretamente no custo operacional, limitam a

capacidade da empresa de responder rapidamente às necessidades emergentes dos clientes. Além disso, Byunghak e Cheol-Han (2003) destacam a questão do controle, ou melhor, da ausência dele.

A literatura acadêmica trata de temas de análise e quantificação de desperdícios em processos logísticos. Chapman et al. (2020) realizaram uma revisão sistemática da literatura sobre desperdícios em cadeias de suprimento e sugeriram métodos de quantificação que podem ajudar a gerir e reduzir esses desperdícios.

O excesso de movimentação de material é um dos maiores desperdícios no seu processo logístico, a mão de obra é sobrecarregada em atividade que não agregam valor para o cliente e negócio. Bhaskar et al. (2014) destacam a importância de eliminar e reduzir quaisquer atividades desnecessárias que não agregam valor ao processo e cliente, indicando a necessidade de analisar sistematicamente os fluxos e processos envolvidos. Para a redução dos desperdícios nos processos logísticos é necessário uma abordagem sistemática, metodológica e integrada.

Para Manzini e Gamberini (2008), a implementação de sistemas de gestão nos processos de suprimentos contribui com a identificação e redução de fontes de desperdício, por meio da otimização do fluxo de materiais, informações entre processos, fornecedores e clientes, e adoção de abordagem como Lean Manufacturing, just-in-time (JIT), Kanban. Essas metodologias e estratégias não apenas reduzem os desperdícios, como também melhoram a eficiência global das operações logísticas.

2.2 Otimização de processos

A pesquisa de Lu et al. (2022), sobre otimização do processo logístico sob a perspectiva da gestão, destaca que esse campo é vital para o desenvolvimento econômico e sustentável. O estudo apresenta e explica os desafios e estratégias para o aprimoramento da logística, dando ênfase na busca pela qualidade do atendimento e serviço que, frequentemente, não acompanha as expectativas dos clientes, que são constantes e crescentes. A otimização dos processos é essencial para elevar a satisfação dos clientes e elevação da qualidade do atendimento. Além disso, a correta movimentação e o fluxo de informações no armazém, em tempo

real, são outros fatores importantes para a eficiência da comunicação, mas muitas empresas ainda enfrentam dificuldades nessa área.

Para otimizar os processos logísticos, Lu et al. (2022) sugerem como estratégias o fortalecimento da gestão, comunicação, controle das variáveis de atendimento, qualificação do time operacional, o uso de tecnologias e a atuação do time multifuncional de melhoria contínua, inferindo que essas medidas melhoram a eficiência operacional e a competitividade das empresas. A cooperação e o acompanhamento da cadeia de valor dos processo logístico, desde fornecedores até clientes, é fundamental para a redução de custos, aumentar a eficiência e promover o desenvolvimento sustentável das empresas.

A otimização de processos logísticos é fundamental para melhorar a eficiência e redução de custos operacionais logísticos. Segundo Manzini e Gamberini (2008), a adoção de modelos analíticos e ferramentas de suporte à decisão permitem uma gestão mais assertiva, o que resulta na melhora da utilização dos recursos e fluxo de materiais mais eficiente. Chan e Chan (2005) enfatizam outra importante abordagem, a simulação e a modelagem dos processos para a identificação de gargalos, e oportunidades, permitindo um melhor ajuste e desempenho global dos processos.

2.3 Análise de Regressão

De acordo com Kuabiak e Benbow (2009), a análise de regressão é uma técnica estatística utilizada para prever a variação em uma variável de resposta contínua (variável dependente) com base em uma ou mais variáveis preditoras contínuas (variáveis independentes). Informam que essa técnica utiliza o método dos mínimos quadrados para determinar os valores dos coeficientes de regressão linear e criar um modelo correspondente que melhor explica a relação entre as variáveis preditoras e a variável resposta.

Suriyan et al. (2022) oferecem como estratégias integrada para melhorar o gerenciamento logístico, entre elas incluem a seleção de variáveis chaves que demonstram o desempenho dos processos, adoção de técnicas de regressão em

aprendizado de máquina. Recomendam a integração dos métodos de seleção por atributos como correlação, análise de componentes principais, LASSO e Elastic-net, seguidos por algoritmos de regressão de aprendizado de máquina, suporte para regressão vetorial (SVR), e regressão linear (Jomthanachai & Wong, 2022).

Shen (2005) destaca que a análise de regressão pode ser utilizada para prever demanda de produtos em diferentes períodos, contribuindo com a gestão de níveis de estoque e evitando tanto a falta quanto o excesso de produtos. Para Chan (2005) a integração de modelo análise de regressão com outras técnicas de otimização pode trazer contribuições importantes a precisão das previsões de demanda e a eficiência dos processos.

2.4 Machine learning (ML)

Segundo Angeluci, Redigolo e Arakaki (2020), o aprendizado de máquina (ML) é um ramo da inteligência artificial que envolve a elaboração de algoritmos e modelos que permitem as máquinas aprenderem a partir dos dados e informações. Esses algoritmos possuem a capacidade de consideração de padrões, específicas ou tomadas decisões baseadas em informações atuais. Indicam que a aplicação do ML pode aumentar a eficácia do setor logístico, contribuindo para a redução dos custos e melhorando os processos. Quando aplicado nos processos logísticos, o aprendizado de máquina (ML) pode facilitar a automação de processos.

De acordo com Lima et al. (2023), a implementação de Machine Learning (ML) com a utilização de modelo de regressão linear é uma abordagem eficiente para a análise dos processos e tomada de ação, porque permite prever o comportamento do processo baseado na variação.

Manzini e Gamberini (2008) discutem que a implementação da ML na logística pode resultar em uma atuação proativa, mais ágil e responsiva, capaz de se adaptar rapidamente a mudanças nas condições do mercado. Outro sim, a integração da ML com outras tecnologias emergentes, como a IoT, proporcionam visibilidade em tempo real e uma análise preditiva precisa, ajudando as empresas na antecipação de falhas e na tomada de decisões aliada a estratégicas.

3. Metodologia

Metodologia é um conjunto estruturado de métodos, técnicas e procedimentos para conduzir uma pesquisa ou projeto com o objetivo de alcançar resultados reproduzíveis.

De acordo com Angeluci, Redigolo, & Arakaki (2020), o DSR (Design Science Research) é um método desenvolvido a partir do conceito de design ou projeto, no qual se fundamenta na ideia de propor alterações em determinado sistema buscando melhorias com o objetivo de desenvolver um produto, artefatos não existentes.

Para Lacerda & Dresch (2016), a relevância da DSR está na identificação do problema para a partir dele, por meio do Design, desenvolver as melhores soluções mitigando ou desenvolvendo uma proposta de solução.

O artigo aplica modelos estatísticos como ferramenta estatística para prever falhas no atendimento em processos logísticos. A Tabela 1 demonstra as etapas conforme descreve o DSR e as ações para o desenvolvimento do projeto.

Tabela 1 - Fases do DSR

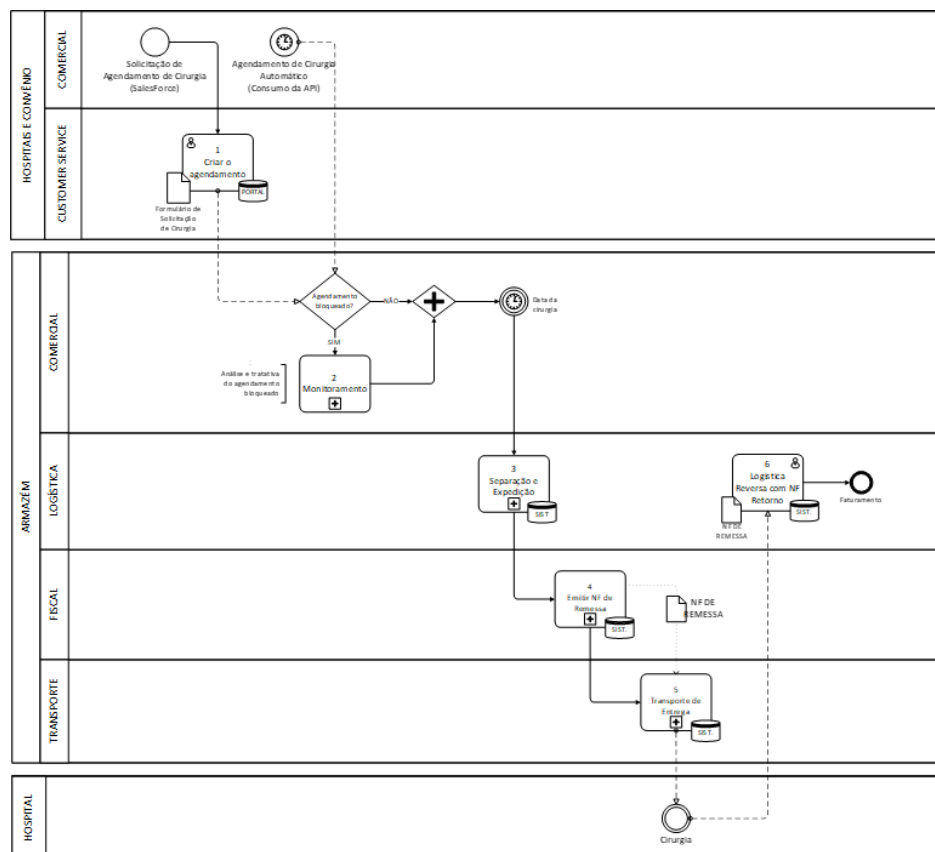
ETAPAS	AÇÃO
1° Explicação do problema	Levramento dos históricos de falhas no atendimento e demonstrar análise de capacidade atual do processo
2° Definição dos requisitos do modelo	Definir as variáveis dependentes e independentes que serão utilizadas no modelo de regressão.
3° Design e desenvolvimento do modelo	Aplicação do modelo de regressão em aprendizado de máquina
4° Demonstração	Inserção da solução dentro do ambiente do armazém
5° Avaliação da eficácia do artefato	Coleta dos resultados a partir dos testes

3.1 Explicação do Problema

A empresa em estudo é responsável pela expedição e transporte de materiais cirúrgicos para atendimento a hospitais e convênios nos estados de São Paulo, Rio de Janeiro, Rio Grande do Sul, Minas Gerais e Distrito Federal. Com atuação em regime especial de tributação, a empresa oferece suporte as cirurgias programadas e emergências para as especialidades de : coluna, neurocirurgia, artroscopia, bucomaxilofacial, hérnia, bariátrica, plástica, geral, joelho, quadril, endovascular, hemodinâmica e cardíaco.

Os hospitais e convênios enviam a solicitação com as informações da cirurgias, procedimento e materiais necessário, o time comercial realizam o agendamento para a expedição dos materiais. Após a inclusão do agendamento, ocorre a integração com o sistema do armazém que na data da cirurgia realiza a Expedição e Transporte dos materiais (Figura 1). Para atendimento de cirurgias programadas, os materiais devem ser expedidos com 10 horas de antecedência, e para emergências, com 20 minutos.

Figura 1 – Processo do Agendamento até Logística Reversa

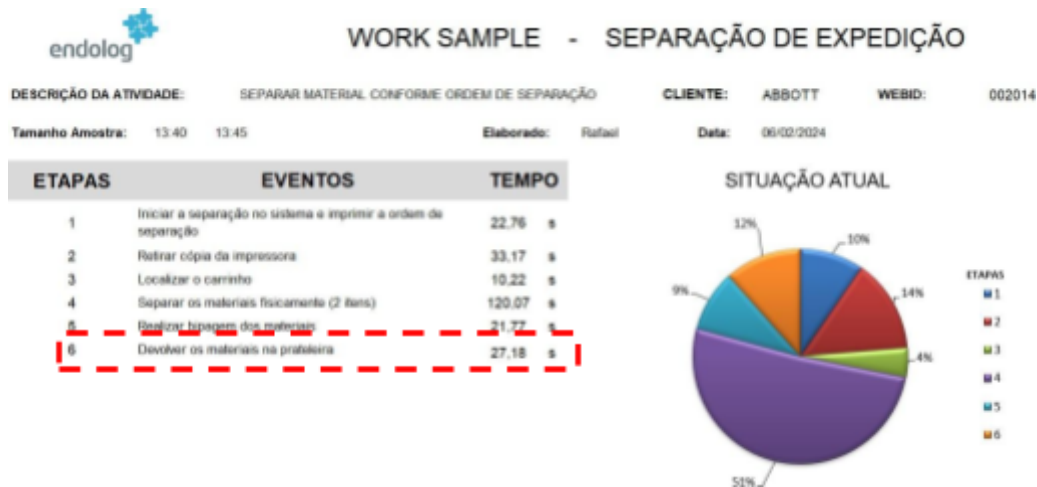


Para identificar problemas no processo de expedição, extraiu-se as informações diretamente da base de dados do sistema do armazém considerando o período de 2023.

Além disso foi realizado diretamente no armazém acompanhamento das atividades relacionadas a expedição de materiais com o objetivo da identificação de desperdícios e limitações do processo que comprometem o desempenho do atendimento, por meio desta ferramenta, Figura 2 - Amostra do trabalho, foi possível identificar os seguinte desperdícios:

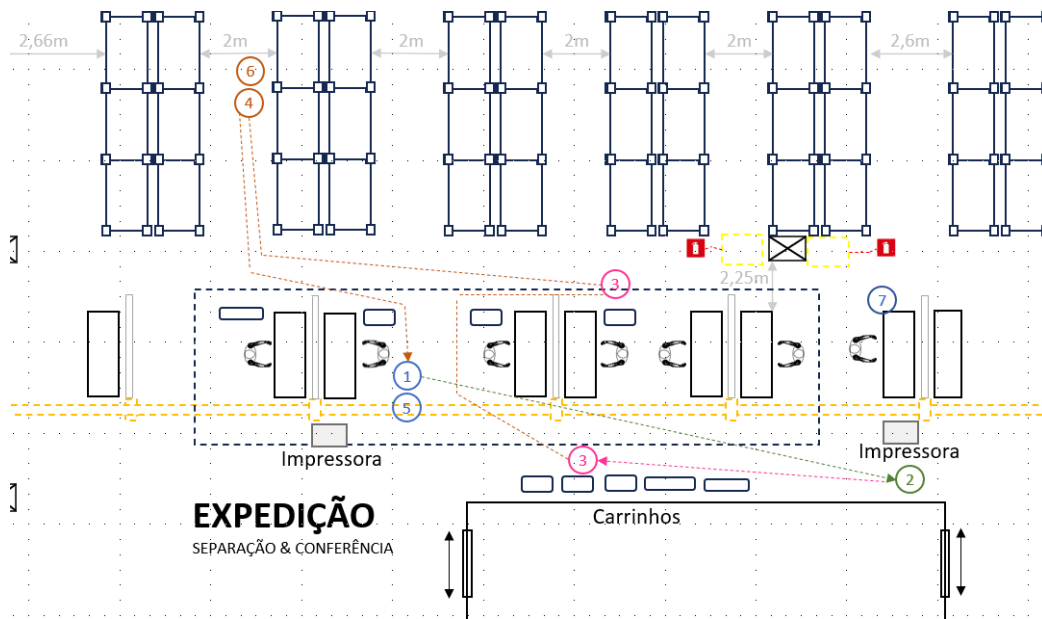
- Localização do carrinho para separação de materiais;
- Coleta da impressão da Ordem de Separação;
- Devolução de materiais separados incorretamente : Representa 12% do tempo de expedição.

Figura 2 – Amostra do Trabalho



Os desperdícios de movimentações podem ser melhor exemplificados por meio da Figura 3 – Ilustração do desperdício. Na qual é possível observar as movimentações necessárias para a Separação dos materiais, e temos o fluxo de movimentação dos trabalhadores.

Figura 3 - Ilustração do desperdício



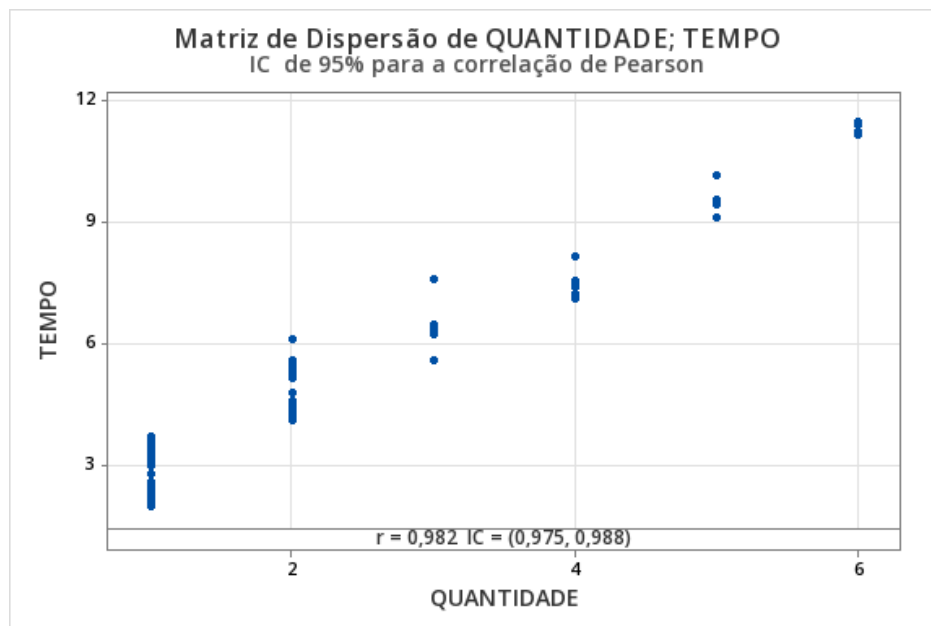
Os desperdícios de movimentação impactam diretamente o tempo de expedição dos materiais, e por consequência o atendimento médico do paciente em atendimento de emergência.

3.2 Definição dos requisitos do modelo

Focamos a análise nas expedições de emergência realizadas no Armazém de São Paulo, foram observadas as seguintes informações: Total de expedições em 2023: 20.368, média mensal de expedições de emergência: 1.697. Após isso segregamos por família, separando as expedições de descartáveis.


Na Figura 4 – Correlação da Família de Descartáveis, observou-se uma correlação positiva e forte com coeficiente de relação de Person de $R = 0,982$.

Figura 4 - Correlação de Tempo e Quantidade



Após análise da correlação, com o objetivo da identificação do nível de atendimento, desenvolveu-se um estudo de capacidade de atendimento da Expedição para o cenário de Emergência. É possível observar um percentual de 25,69% na figura 5 – Análise de Capacidade de Expedição de falha no cumprimento do tempo máximo estabelecido de SLA de 20 minutos. Esta análise foi realizada com base em 580 amostras (subgrupos de 10 amostras por dia).

Figura 5: Análise de Capacidade de Expedição



Após esta análise, desenvolveu-se dentro da plataforma KNIME um modelo de aprendizado de máquina como facilitador para a tomada de decisão por meio da predição de falhas. Dessa forma, os colaboradores poderão atuar de maneira proativa para prevenir ocorrências de atraso na expedição de materiais. Na figura 6 imagem da plataforma KNIME.

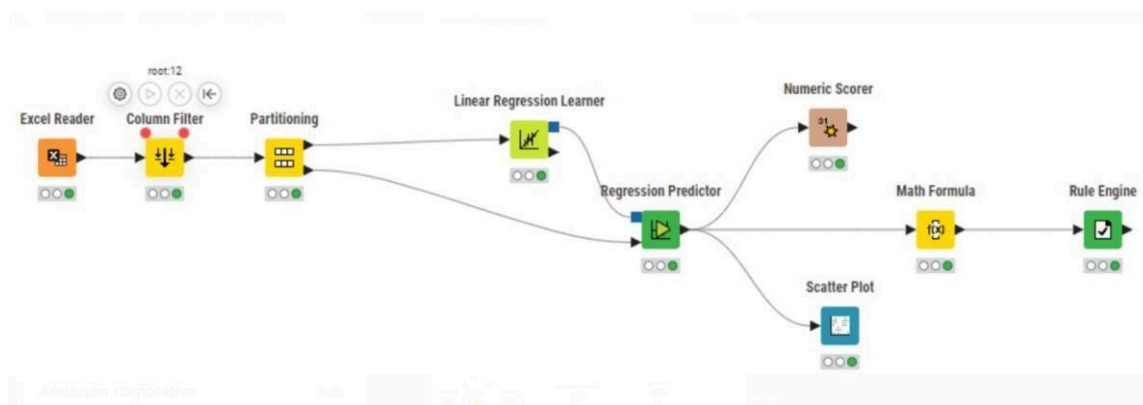
Figura 6 - SOFTWARE KNIME



3.3 Desenvolvimento

Para o desenvolvimento do modelo, realizou-se estudo com base no histórico das expedições realizadas em 2023 para o cenário de expedição de Emergência, em seguida implementou-se o modelo de regressão na plataforma Knime para otimização do processo de expedição de aplicação.

Figura 7 - Imagem do fluxo do Knime



1. **Excel Reader:** O fluxo começa com o nó Excel Reader , onde os dados foram importados de uma planilha Excel. Isso possibilita o uso de dados brutos para alimentar o modelo de regressão.
2. **Column Filter:** Este nó permite que colunas sejam filtradas da tabela de entrada, de modo que apenas as colunas restantes sejam passadas para a tabela de saída. No diálogo, as colunas podem ser movidas entre as listas Incluir e Excluir.
3. **Partitioning:** A tabela de entrada é dividida em duas partições (ou seja, linha por linha), por exemplo, dados de treinamento e teste. Aqui conseguimos fazer o treinamento do modelo.
4. **Linear Regression Learner:** O nó de aprendizado de regressão linear, onde o modelo de Aprendizado de Máquina é treinado. Esse não utiliza uma quantidade de dados para prever o tempo, conforme o modelo de regressão definido.

5. **Regression Predictor:** Após o treinamento, o Regression Predictor usa o modelo para realizar ações específicas sobre novos dados ou dados de teste, gerando resultados que podemos comparar com os valores reais.
6. **Numeric Scorer:** Para avaliar o desempenho do modelo, o nó Numeric Scorer gera avaliações de avaliação, como exemplo o R^2 (0,791), Mean Absolute Error (0,567), Mean Squared Error (0,484), entre outros. Essas medições permitem verificar o ajuste do modelo e a precisão da precisão.
7. **Scatter Plot:** Na configuração do nó, é possível escolher o tamanho de uma amostra que você deseja exibir e habilitar certos controles, que estarão disponíveis na visualização. A configuração também oferece uma pré-visualização da visualização, o que ajuda a ajustar o gráfico de dispersão à forma desejada rapidamente.
8. **Math Formula:** Este nó realiza cálculos matemáticos personalizados para criar novas colunas baseadas em dados existentes. No caso, ele é usado para calcular a diferença entre a previsão gerada pelo modelo de regressão e o SLA (tempo máximo permitido).
9. **Rule Engine:** Este nó é usado para criar regras lógicas que classificam ou categorizam os dados com base em condições predefinidas. No caso, ele analisa a coluna criada pelo Math Formula e classifica os resultados em "Atraso" (quando a diferença é maior que 0) ou "No prazo" (quando a diferença é menor ou igual a 0).

Utilizamos na primeira aplicação do modelo os dados de 2023, e tivemos os seguintes dados na figura 8, uma capacidade preditiva com um R^2 ajustado de 0,77, explicando a variação do processo em função do tempo e quantidade, e após iniciamos o treinamento utilizando o bloco "Partitioning" com 80% de treinamento e 20% de teste.

Figura 8: Predição dados 2023

#	RowID ↓	predição <i>Number (double)</i>
1	R ²	0.776
2	mean absolute error	0.584
3	mean squared error	0.503
4	root mean squared error	0.709
5	mean signed difference	-0.24
6	mean absolute percentage error	0.39
7	adjusted R ²	0.776


Após a finalização do desenvolvimento do artefato na plataforma iniciou-se o treinamento do modelo na fase Teste e Validação.

3.4 Teste e Validação

Na fase de Teste e Validação utilizamos os dados do terceiro trimestre de 2024, com os dados do processo de expedição, para avaliação da capacidade preditiva e precisão. Para essa validação, utilizamos o módulo 'Numeric Scorer' no Knime, que nos permitiu obter métricas como o R² ajustado, o erro médio absoluto (MAE) e o erro médio quadrático (MSE). Essas análises fornecem uma avaliação quantitativa do desempenho do modelo ao comparar as orientações com os valores observados nos dados de teste.

Os estudos iniciais para o desenvolvimento do artefato obtivemos um R² de 0,77, extraímos o gráfico no bloco Scatter Plot a seguir na figura 9.

Figura 9: Gráfico predição dados 2023



A seguir temos os dados e a aplicação no Knime do mês de Julho, Agosto e Setembro de 2024, onde temos a coluna de quantidade de material expedido e o tempo. Para cada mês utilizamos cerca de 200 amostras. Na figura 10, 11 e 12 observa-se a inclusão dos dados na plataforma. Na imagem 10 é possível observar que o resultado da predição indicam que as Expedições estão dentro do prazo, considerando um SLA de 20 minutos.

Figura 10: Dados Julho 2024

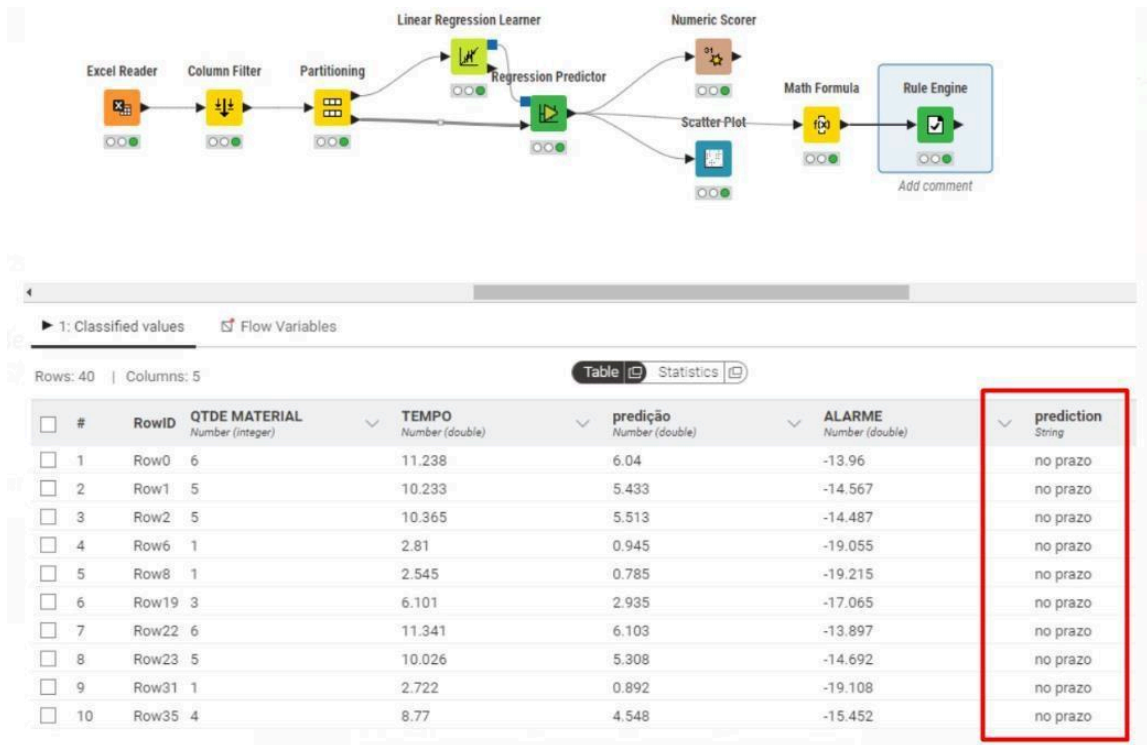


Figura 11: Dados Agosto 2024

#	RowID	Quantidade Number (integer)	Tempo Number (double)	predição Number (double)	ALARME Number (double)	prediction String
1	Row2	1	2.844	1.07	-18.93	no prazo
2	Row14	3	6.071	2.972	-17.028	no prazo
3	Row18	4	8.128	4.184	-15.816	no prazo
4	Row19	3	6.044	2.956	-17.044	no prazo
5	Row23	5	9.555	5.025	-14.975	no prazo
6	Row30	6	11.425	6.127	-13.873	no prazo
7	Row39	1	3.185	1.271	-18.729	no prazo
8	Row46	5	10.057	5.321	-14.679	no prazo
9	Row47	4	8.282	4.275	-15.725	no prazo
10	Row55	6	11.81	6.354	-13.646	no prazo

Figura 12: Dados Setembro 2024

#	RowID	QTDE MATERIAL Number (integer)	TEMPO Number (double)	predição Number (double)	ALARME Number (double)	prediction String
1	Row4	5	10.148	5.272	-14.728	no prazo
2	Row8	3	6.023	2.922	-17.078	no prazo
3	Row14	2	4.537	2.075	-17.925	no prazo
4	Row28	5	9.239	4.754	-15.246	no prazo
5	Row29	2	3.622	1.554	-18.446	no prazo
6	Row31	4	7.549	3.791	-16.209	no prazo
7	Row33	5	9.547	4.929	-15.071	no prazo
8	Row36	5	9.852	5.103	-14.897	no prazo
9	Row38	4	7.716	3.886	-16.114	no prazo
10	Row45	3	5.835	2.815	-17.185	no prazo


Na figura 13 temos os dados das amostras que foram utilizadas na validação do modelo para o mês de Julho de 2024.

Figura 13: Dados predição julho 2024

#	RowID	predição <i>Number (double)</i>
1	R ²	0.971
2	mean absolute error	0.237
3	mean squared error	0.096
4	root mean squared error	0.31
5	mean signed difference	0.032
6	mean absolute percentage error	0.08
7	adjusted R ²	0.971

O valor de R² ajustado indica que o modelo é capaz de explicar a variação nos tempos de expedição com base na quantidade de itens no mês de Julho em 97%, com R² de 0,971. Na imagem 14 é possível observar a validação no software knime com o gráfico pelo bloco Scatter Plot.

Figura 14 - Gráfico predição – Dados julho 2024




Em seguida testamos os dados de agosto de 2024, e obtivemos um R^2 de 0,974 ou 97,4%, a seguir temos os dados retirados do Knime.

Figura 15: Dados predição agosto 2024

#	RowID	predição <i>Number (double)</i>
1	R ²	0.974
2	mean absolute error	0.219
3	mean squared error	0.08
4	root mean squared error	0.283
5	mean signed difference	0.086
6	mean absolute percentage error	0.089
7	adjusted R ²	0.974

Na imagem 16 temos os dados da validação no software knime através do gráfico pelo bloco Scatter Plot.

Figura 16: Gráfico predição – Dados agosto 2024




Com os dados do mês de setembro de 2024, obtivemos um R^2 de 0,947 ou 94,7%.

Figura 17: Dados predição setembro 2024

#	RowID	predição <i>Number (double)</i>
1	R^2	0.947
2	mean absolute error	0.288
3	mean squared error	0.13
4	root mean squared error	0.361
5	mean signed difference	-0.031
6	mean absolute percentage error	0.129
7	adjusted R^2	0.947

A seguir temos a validação do knime através do gráfico.

Figura 18: Gráfico predição – Dados setembro 2024



Ao realizar a etapa de teste e validação, garantimos que o modelo seja aplicável ao contexto prático de expedição, permitindo decisões futuras e otimizações específicas.

4. Resultados e discussão

Os resultados do modelo de previsão foram positivos, o R^2 ajustado foi de 0,958 em 2024 e em julho, 0,974 em agosto e 0,947 em setembro. Isso significa que o modelo é capaz de explicar a variação mais de 90% da variação do processo de expedição. Este valor reflete um ganho significativo de precisão do modelo em relação ao valor inicial de 0,791, obtido com os dados do ano de 2023.

À medida que o valor do R^2 aumenta, podemos compreender os benefícios do modelo para a previsão de falhas e desvios do processo. Assim, a equipe de logística pode acompanhar a expedição de emergência de materiais descartáveis, agindo preventivamente evitando atrasos. Num ambiente hospitalar, onde o tempo é crítico, esta precisão acrescenta uma camada extra de segurança e viabilidade ao atendimento ao paciente.

Em comparação com trabalhos anteriores (Chan e Chan, 2005) onde foi realizada alguma análise histórica ou foi simulado um processo que seria mais do que capaz de fazer previsões, no nosso modelo foi possível adapta-se ao estímulo à mudança do contexto real. Esta diferença está alinhada com práticas emergentes em logística no qual a previsibilidade e a agilidade são essenciais.

Realizou-se um estudo de Regressão para identificar precisão do modelo de machine learning com todos os dados de 2024, na Figura 19 - Análise de Regressão – Expedição de Descartáveis', nota-se que o valor de R^2 (R-Quadrado) indica que o modelo explica 95,80% da variação do tempo em função da quantidade.

Figura 19 - Análise de Regressão - Expedição de Destartáveis 2024



Figura 20: Dados predição 2024

#	RowID	predição <i>Number (double)</i>
1	R ²	0.958
2	mean absolute error	0.273
3	mean squared error	0.118
4	root mean squared error	0.343
5	mean signed difference	-0.016
6	mean absolute percentage error	0.098
7	adjusted R ²	0.958

Em comparação, o modelo proposto oferece um ganho substancial na previsibilidade e controle do processo, com estudos anteriores que possuem abordagens tradicionais que não integram machine learning. Estudos anteriores (Chan e Chan, 2005; Manzini e Gamberini, 2008) mostraram que a análise de dados históricos e a simulação de processos contribuem para a otimização logística. Entretanto, nosso modelo se destaca ao fornecer uma capacidade preditiva com base em machine learning, o que possibilita a tomada de decisão com base em dados em tempo real.

5. Conclusão

O modelo preditivo desenvolvido neste estudo representou um avanço significativo na gestão com a predição de falhas logísticas em expedições. Validado com um R^2 de 0,97, o modelo provou-se eficaz na previsão de desvios no processo logístico permitindo atuação preventiva baseada em dados.

Este trabalho demonstra a viabilidade do uso de machine learning na logística hospitalar, reforçando a confiabilidade do atendimento e reduzindo os riscos de atraso em situações emergenciais. A aplicação da metodologia Design Science Research forneceu uma base prática e adaptável, facilitando o aprimoramento contínuo do modelo.

Perspectivas Futuras: Recomenda-se a expansão do modelo para outras áreas do armazém, tais como o Transporte e Retorno de Cirurgias com a incorporação do modelo estudado para aumentar ainda mais a precisão das previsões.

Referências

- AMBROSINO, D. & SCUTELLÀ. Distribution network design: new problems and related models. *European Journal of Operational Research*, 2005.
- ANGELUCI, A. C., REDIGOLO, G. L., & ARAKAKI, P. J. Design Science Research Como Método para Pesquisas em TDIC, CIET EnPED, 2020.
- BHASKAR, S.M.; SRIVASTAVA, S.K.; SWAIN, B.K. Identification of Waste in Logistics: A Review of Literature. *Procedia Engineering*, 2014.
- BYUNGHAK, L. & CHEOL-HAN, K. A methodology for designing multi-echelon logistics networks using mathematical approach. *International Journal of Industrial Engineering: Theory Applications and Practice*, 2003.
- CHAN, F.T.S & CHAN, H.K. The future trend on system-wide modelling in supply chain studies. *International Journal of Advanced Manufacturing Technology*, 2005.

CHAPMAN, A.J.; MURTHY, D.N.P.; MANI, M. Quantifying waste in logistics: A systematic literature review. *Transportation Research Part E: Logistics and Transportation Review*, 2020.

JINQIANG, F. *Logistics optimization strategy of automobile*, 2022.

JOMTHANACHAI, S., & WONG, W. P. An application of machine learning regression to feature selection, 2022.

KUABIAK, T. M., & W., D. B. *The Certified Six Sigma Black Belt - Hand Book*, pag 188 e 189, 2009.

LACERDA, D. P., & DRESCH, A. *Design Science Research: método de pesquisa para a engenharia de produção*, 2016.

LU, J., & XU, H. *Research on Optimization of Logistics Management*, *Frontiers in Business, Economics and Management*, 2022.

MENDES, A *logística com fator de Competividade para a melhoria do desempenho*, 2017.

WANG, L.; O'BRIEN, R. Waste reduction in logistics and supply chain management. *Journal of Cleaner Production*, 2021.