



GERENCIAMENTO DE RISCO DE ATRASO DE ENTREGA EM LOGÍSTICA EMPRESARIAL POR MÉTODO DE VALOR ESPERADO


MANAGING RISK OF DELAY IN LOGISTICS DELIVERIES USING EXPECTED VALUE METHOD

Versão do autor aceita publicada online: 18 dez. 2019

Publicado online: 12 maio 2021

Como citar esse artigo - American Psychological Association (APA):

Rodrigues, G. de A., & Vieira, J. G. V. (2021, abr./jun.). Gerenciamento de risco de atraso em entregas logísticas por método de valor esperado. *Exacta*, 19(2), 324-350.
<https://doi.org/10.5585/exactaep.2021.8636>.

Submeta seu artigo para este periódico 



Dados Crossmark



GERENCIAMENTO DE RISCO DE ATRASO EM ENTREGAS LOGÍSTICAS POR MÉTODO DE VALOR ESPERADO

MANAGING RISK OF DELAY IN LOGISTICS DELIVERIES USING EXPECTED VALUE METHOD

 Gustavo de Abreu Rodrigues¹

 Jose Geraldo Vidal Vieira²

¹ Mestrando em Engenharia de Produção
 Universidade de São Paulo – USP
ga.rodriques@usp.com

² Professor Colaborador - Escola
 Politécnica/Universidade de São Paulo –
 Poli/USP
jgvidal@gmail.com

Recebido em: 20 abr. 2018

Aprovado em: 18 dez. 2019

Resumo: Neste artigo foi desenvolvido um mecanismo de auxílio à tomada de decisão para o gerenciamento de risco de atrasos em entregas em logística empresarial, baseado em valor esperado (VE) e aprendizado estatístico (AE). Este mecanismo permite ao tomador de decisão discernir quais entregas priorizar, simultaneamente, tanto pela sua importância em quantidade, quanto pela sua probabilidade de atraso. Neste modelo, priorizar as entregas de maior valor esperado implica minimizar o risco de impacto no indicador de desempenho logístico de entrega no prazo (On-Time Delivery [OTD]). A técnica de AE escolhida para auferir as probabilidades de atraso foi a Regressão Logística (RL). Os coeficientes das variáveis foram utilizados para comparar as variáveis que mais influenciam a chance de atraso. Foi feita uma simulação testando a aplicabilidade deste modelo com os dados de operação de uma multinacional de produtos eletrônicos. A qualidade das predições foi testada utilizando metodologias sugeridas na literatura para validação de qualidade de modelos de aprendizado estatístico. Por fim, a sugestão de priorização por VE foi testada criando-se cinco grupos de risco e confrontando as taxas previstas de atraso contra as taxas reais em cada um destes grupos. Como resultado, obteve-se que as probabilidades auferidas foram confiáveis e o cálculo de VE permitiu encontrar o grupo de maior risco.

Palavras-chave: Valor Esperado. Regressão logística. Indicador de entrega no prazo.

Abstract: This paper develops a decision-making assistant tool for managing the risk of delay in commercial outbound deliveries based on expected value (EV) and Statistical Learning (EL). This tool allows decision takers to prioritize deliveries based both on their quantities and probability of delaying. In this model prioritizing deliveries based on their EV results in minimizing impact on On-Time Delivery (OTD) KPI. The probabilities used on this model stem from a logistic regression model. The coefficients were used to evaluate which variables most impact on the chance of delaying. A simulation was executed on the historical data of multinational electronics company to test the applicability of this model. The quality of the predictions was tested using standard methodology for testing statistical learning models of the literature. Lastly the prioritization based on VE was tested confronting the predicted delay against real delay in each of five risk groups. The results show that the calculated probabilities were a reliable input and that the EV prioritization model allowed to find the high-risk group.

Keywords: Recycling. Wind blades. Wind power. Life cycle.

1 Introdução

Esta pesquisa aborda o tema “gerenciamento de risco de atrasos das entregas” de produtos eletrônicos, dentro da área de logística de uma empresa multinacional. Auferir a probabilidade da ocorrência de atraso em entregas geralmente é uma tarefa trabalhosa dentro da área de logística empresarial, pois exige que uma dada empresa tenha processos bem estruturados para coletar e armazenar dados ao longo do tempo.

Especificamente, para o setor de planejamento e monitoramento de transporte da empresa em estudo, manter um alto índice no seu indicador “Entregas no Prazo” (ou *On-Time Delivery* [OTD]) é uma meta. Este indicador é medido pela relação de peças entregues no prazo pelo total de peças entregues. Os dados históricos do sistema de transporte desta empresa serviram de base para esta pesquisa.

Observou-se, como oportunidade, a crescente difusão na literatura de métodos de Aprendizado Estatístico (AE) utilizados para gerar previsões a partir de dados reais (James, Witten, Hastie, & Tibshirani, 2017). No entanto, foi observado que existe uma lacuna na literatura em artigos que utilizam técnicas para a previsão de atraso na área de logística rodoviária. Foram encontrados apenas trabalhos publicados no âmbito de atraso em malha aérea (Mukherjee, Grabbe, & Sridhar, 2014; Ni, Wang, & Li, 2017; Wang, Liang, & Delahaye, 2018) e malha ferroviária (Lessan, Fu, & Wen, 2018; Yaghini, Khoshraftar, & Seyedabadi, 2013). Além disto, estes artigos exploram mais profundamente o uso de técnicas de AE em si do que as implicações para a área de logística, ou a criação de ferramentas úteis para estes profissionais. Em especial, nenhum artigo foi encontrado sobre o tema de previsão de atraso para entregas em malha rodoviária comercial.

Desta forma, a questão que norteou esta pesquisa foi:

É possível utilizar alguma técnica de AE para ajudar os profissionais de logística empresarial a identificar e priorizar as entregas de sua carteira que possuam um maior risco de impacto no OTD?

Baseado nesta questão, o objetivo delineado para esta pesquisa foi:

A partir de uma técnica de AE, criar um mecanismo de auxílio à tomada de decisão, que permita identificar e priorizar as entregas com maior risco de impacto no OTD.

Para ser caracterizada como entrega com alto risco de impacto no OTD uma entrega precisa tanto possuir uma alta probabilidade de atraso quanto uma alta quantidade de peças. Portanto, para combinar estas duas variáveis no mesmo objetivo, foi utilizado um modelo de classificação de risco a partir do Valor Esperado (VE), utilizando-se o produto da quantidade de cada entrega pela probabilidade de ela atrasar.

Já para auferir as probabilidades de atraso, a técnica de Regressão Logística (RL) foi escolhida baseando-se em alguns critérios: (i) Sua modelagem permite lidar com variáveis tanto de natureza quantitativa quanto categórica (Hosmer, Lemeshow, & Sturdivant, 2013); (ii) os valores obtidos com sua

parametrização são de alto valor interpretativo (James et al., 2017). Isto quer dizer que um tomador de decisão pode compreender facilmente a saída do modelo, pois pode-se verificar quais valores de coeficientes foram parametrizados na equação do preditor. Desta forma o decisor pode utilizar seu conhecimento de especialista para criticar ou aceitar os resultados das predições; Por fim (iii) é possível criar modelos com inúmeras variáveis independentes, como entrada, e obter uma probabilidade de realização, como saída, (Tibshirani, 1996).

Para testar o modelo foi utilizado o histórico de entregas presentes no sistema logístico da empresa estudada. O histórico foi dividido entre uma base de aprendizado e uma de teste. Os coeficientes da RL foram parametrizados sobre a base de aprendizado e utilizados para calcular as probabilidades de atraso das entregas da base de teste.

Em sequência, as probabilidades previstas e as quantidades de cada entrega foram utilizadas para calcular seus VE e, subsequentemente, foi utilizado este valor para gerar a classificação das entregas em grupos de risco de impacto no OTD.

Para medir a qualidade deste modelo foram feitos os testes padrões da literatura de aprendizado de máquina para validar as qualidades das predições. Adicionalmente, também foram feitos testes confrontando as predições com atrasos reais nos grupos classificados com maior risco baseado em VE.

Como resultado, observou-se que as probabilidades obtidas com o modelo se tornam confiáveis quando seu valor é alto. A segmentação de entregas por grupos de VE acabou misturando entregas de probabilidades de graus de confiança distintos e, conseqüentemente, gerando mais imprecisão nas predições de atraso. Porém ainda foi possível obter uma boa predição para o grupo de VE alto, mostrando que o método é eficaz quando se almeja discriminar apenas entregas de maior chance de impacto no OTD.

Na seção 2 foi desenvolvida uma breve revisão teórica, na seção 3 foi discutido o método de estudo, uma contextualização do objeto de estudo e o design experimental. Finalmente, na seção 4 foi feita uma contextualização dos dados, análise dos resultados, e foram apresentadas as conclusões, limitações e oportunidade de estudos futuros.

2 Revisão da literatura

Os dois principais pilares teóricos deste trabalho são Regressão Logística (RL) e Indicadores de Desempenho Logístico (IDL), e para cada um destes foi criado um subtópico. No primeiro, é apresentada a relevância do método de RL como uma ferramenta de AE e predição, principalmente no contexto onde as variáveis de entrada são de valores não numéricos, ou categóricos. O modelo de regressão escolhido visa prever o valor de uma variável dicotômica de saída. Neste estudo a variável de saída é a

categorização de uma entrega em um de dois grupos, com atraso e sem atraso. Por isto, em sequência, a importância da previsão de atraso em logística empresarial é então mais claramente explicitada. No segundo tópico é dedicado uma atenção especial à importância de utilização de indicadores de desempenho como ferramenta de controle em malhas logísticas, em especial o uso do indicador OTD.

2.1 Regressão logística

No final do último século Long (1997) preconizava como técnicas de regressão haviam se multiplicado em número e ganhado importância nos 20 anos precedentes. Principalmente, técnicas que se assemelham a regressões, mas que lidam com variáveis de entrada de natureza categórica, haviam ganhado grande popularidade em ciências sociais e biomédicas. Nestas áreas, previsões passaram a ser possíveis, vinculando por exemplo, a chance de viver de um indivíduo a um grupo de variáveis numéricas, como idade, peso, mas também categóricas como sim, ou não, em resposta a questionários de hábitos de risco. A técnica principal apresentada pelo autor quando a variável de saída tem o valor binário foi a RL.

Recentemente, o ganho de abrangência no uso de técnicas de AE, incluindo RL, também se deu em diversas outras áreas. Autores como Patah e Vargas Neto (2016), Berssaneti e Carvalho (2015) e Takagi, Mizuno, & Kikuno (2005) utilizaram questionários e RL para prever atrasos em projetos. Já em um contexto mais próximo a operações logísticas, Mukherjee et al. (2014) aplicou RL para prever atrasos de operações de solo em aeroportos dado condições meteorológicas diferentes. Kuhn & Jamadagni(2017) compararam três técnicas diferentes de aprendizado de máquina para prever atrasos em malhas aéreas, Redes Neurais, Árvores de Decisão e RL e, chegaram a resultados muito similares em termos de acurácia para os três modelos. Outros estudos fazem previsões similares, em contextos logísticos importantes, porém aplicando técnicas distintas. Yaghini et al. (2013) previram atrasos em malhas ferroviárias utilizando Redes Neurais Artificiais. Lessan et al. (2018) também previram atrasos em operações de trens utilizando Redes Bayesianas. Apesar das diversas técnicas disponíveis para realizar o mesmo trabalho de classificação, é importante o resultado explicitado pela comparação de Kuhn & Jamadagni(2017), de que estes modelos tem acurácia similar e são muitas vezes intercambiáveis em tarefas de classificação. Nesses trabalhos é possível observar o interesse em prever atraso em contextos diferentes e também em comparar técnicas diferentes.

Neste mesmo sentido, Long, Griffith, Spelker e D'Agostino (1993) fizeram uma comparação detalhada de dois dos métodos mais populares de classificação, Árvores de Decisão e RL, com resultados muito mais favoráveis para o segundo. Além disso, os autores comprovaram dois pontos que são de interesse para esta pesquisa. (i) A confirmação de que a probabilidade obtida com o método de RL é uma fonte confiável e eficaz para a previsão de variáveis dependentes dicotômicas; (ii) a de que esta técnica é robusta o suficiente e computacionalmente mais barata para chegar ao resultado desejado.

Utilizamos a mesma notação de Raschka & Mirjalili (2019):

$i \in [1, n]$: Índice de observações;

$j \in [1, p]$: Índice de dimensões;

\mathbf{X} : Matriz de observações. Sendo $\mathbf{x}^{(i)}$ ou \mathbf{x} os valores de uma observação e $x_j^{(i)}$ o valor associado à observação i da dimensão j ;

$\mathbf{y} \in \{0, 1\}$: Vetor dos resultados observados, sendo 0 e 1 não atraso e atraso.

O modelo de RL prevê um atraso quando $p(y = 1 | \mathbf{x}) > 0.5$. Ou seja, quando a probabilidade associada ao atraso, dado a escolha das variáveis subjacente, for maior que 50% (James et al., 2017). Utilizamos também a simplificação de notação $p(y = 1 | \mathbf{x}) = \pi(\mathbf{x})$ e $p(y = 0 | \mathbf{x}) = 1 - \pi(\mathbf{x})$ para as probabilidades condicionais nos casos de atraso e não atraso. A probabilidade de atraso para uma entrega é, então, encontrada pela transformação da relação linear das variáveis subjacentes ao modelo em uma curva sigmoide, dada pela equação (1).

$$\pi(\mathbf{x}) = \frac{1}{1 + e^{-(\beta_0 + \beta_1 x_1 + \dots + \beta_p x_p)}} = \frac{1}{1 + e^{-\boldsymbol{\beta}^T \mathbf{x}}} \quad (1)$$

Que também pode ser escrita como:

$$\text{Logit}(\pi(\mathbf{x})) = \log\left(\frac{\pi(\mathbf{x})}{1 - \pi(\mathbf{x})}\right) = \beta_0 + \beta_1 x_1 + \dots + \beta_p x_p \quad (2)$$

A equação (1) advém da manipulação da equação (2). A equação (2) relaciona o Logit, ou seja, o log da razão de chances, a divisão de $\pi(\mathbf{x})$ por $1 - \pi(\mathbf{x})$, que traduz quantas vezes a chance de o evento acontecer é maior do que a chance de não acontecer, com as variáveis subjacentes do modelo. Segundo Raschka & Mirjalili (2019), algumas propriedades destas relações são de interesse; a saber:

- (i) trabalhar com o Logit é mais interessante computacionalmente do que trabalhar diretamente com probabilidades condicionais, pois probabilidades condicionais se tornam números muito pequenos em contextos de muitas variáveis e observações;
- (ii) a função sigmoide mapeia números reais ao intervalo de zero a um, $n \in \mathbb{R} \rightarrow [0,1]$, atendendo com isso o axioma de definição de conjunto da função probabilidade;
- (iii) Com o ajuste adequado dos parâmetros β_j , pode-se fazer a curva sigmoide se aproximar muito do formato da curva de densidade de probabilidade acumulada de uma distribuição gaussiana. O que explica a possibilidade de interpretação da interpolação desta curva aos dados, como análogo ao problema de auferir probabilidades.

Para prover soluções para esta pesquisa, utilizam-se as observações de uma base de aprendizado em dados reais. Esta base deve conter pares de observações e seus resultados associados (\mathbf{x}, y_i) .

No entanto, para encontrar os coeficientes $\boldsymbol{\beta}$ deve-se fazer a parametrização tal que as probabilidades observadas se ajustem aos valores observados de \mathbf{y} . Ou seja, tal que $p(\mathbf{y}|\mathbf{X}; \boldsymbol{\beta}) \approx \mathbf{y}$. Para isto basta maximizar a função de verossimilhança, equação (3) (Hosmer et al., 2013).

$$L(\boldsymbol{\beta}) = \prod_{i=1}^n P(y^{(i)}|\mathbf{x}^{(i)}; \boldsymbol{\beta}) = \prod_{i=1}^n \pi(\mathbf{x}^{(i)})^{y^{(i)}} (1 - \pi(\mathbf{x}^{(i)}))^{1-y^{(i)}} \quad (3)$$

Nesta equação, observações $\mathbf{x}^{(i)}$ que obtiveram atraso, ou seja, com $y^{(i)} = 1$, contribuem com $\pi(\mathbf{x}^{(i)})$ para a computação do valor da máxima verossimilhança, enquanto observações que não obtiveram atraso contribuem com $1 - \pi(\mathbf{x}^{(i)})$. Esta função é convenientemente escrita desta forma, utilizando o artifício de que o observado só pode assumir valores 0 ou 1 e, o produto destas probabilidades advém do modelo de probabilidade condicional de Bayes.

No entanto, as multiplicações de probabilidades na equação (3) podem gerar números muito pequenos que podem se perder em aproximações de precisão numérica. Por isto, uma forma computacionalmente mais eficiente é trabalhar com a transformação em logaritmo da função de verossimilhança. Costuma-se também transformar este problema em um problema de minimização invertendo o sinal e atribuindo este valor à equação de custo $J(\boldsymbol{\beta})$. Isto resulta na equação (4) (Raschka & Mirjalili, 2019).

$$J(\boldsymbol{\beta}) = - \sum_{i=1}^n [y^{(i)} \log(\pi(\mathbf{x}^{(i)})) + (1 - y^{(i)}) \log(1 - \pi(\mathbf{x}^{(i)}))] \quad (4)$$

Uma abordagem possível para se encontrar os valores $\boldsymbol{\beta}$ é utilizar um modelo de otimização para descer iterativamente em direção contrária ao gradiente da função de custo, $\nabla J(\boldsymbol{\beta})$.

$$\nabla J(\boldsymbol{\beta}) = \frac{\partial J(\boldsymbol{\beta})}{\partial \beta_j} = \sum_{i=1}^n (y^{(i)} - \pi(\mathbf{x}^{(i)})) x_j^{(i)} \quad (5)$$

No entanto, vale ressaltar que um dos erros mais comuns passíveis de serem cometidos ao aplicar um modelo de aprendizagem a um conjunto de dados é o erro de super-ajuste (*overfitting*). Isto acontece principalmente, quando se leva em consideração variáveis que têm uma baixa significância estatística no modelo (Hastie, Tibshirani, & Friedman, 2009; Hosmer et al., 2013; James et al., 2017).

Para contornar este problema, foram desenvolvidas na literatura de AE várias técnicas. De maneira simplificada, estas técnicas abordam uma tentativa de: (i) coletar um volume maior de dados de aprendizagem; (ii) penalizar complexidade; (iii) eliminar variáveis (Hosmer et al., 2013). Para cobrir os pontos (ii) e (iii), um dos métodos mais populares e de maior prestígio desenvolvidos dentro da estatística, para resolver este problema de regularização e seleção de variáveis, é o *Least Absolute Shrinkage and Selection Operator (LASSO)* Tibshirani (1996). A regularização LASSO, descrita na equação (6), também chamada de regularização L1, modifica a equação de custo intrudindo um teto para os valores individuais possíveis de β_j . Desta forma, esta abordagem introduz um mecanismo que suaviza e seleciona coeficientes baseados no seu valor absoluto.

$$\begin{aligned} \min J(\boldsymbol{\beta}) &= \min_{\boldsymbol{\beta}} \sum_{i=1}^n -\log p(y^{(i)} | \mathbf{x}^{(i)}; \boldsymbol{\beta}) \\ \text{sujeito a: } &\sum_{j=1}^p |\beta_j| \leq C \end{aligned} \quad |(6)$$

Além disso, a regularização LASSO elimina a necessidade de utilização dos métodos preliminares de avaliação e seleção de dimensões. Isto porque tem-se em vista que as restrições, que são impostas ao modelo matemático automaticamente força os coeficientes das variáveis de menor importância para zero, e suaviza os valores dos demais (Raschka & Mirjalili, 2019).

Esta pesquisa não trata apenas de previsão de atraso, mas também da utilização de VE para classificar entregas futuras em grupos de risco de atraso. Essa abordagem tem valor para empresas com processos envolvendo escolhas que repetem em grande número, como é o caso, do gerenciamento de transporte no canal de distribuição de produtos eletrônicos. Apesar da alta complexidade envolvida, gerada pelo alto número de agentes e variáveis logísticas (fornecedores, prestadores de serviço, modais, veículos, plantas, clientes, etc.), a escolha destes fatores se repete periodicamente. Um mecanismo preditor, aliado à técnica de VE, pode ser utilizado para a escolha de planos de contingência, replanejamento, estudos de casos, atualização de contratos, ou ainda como base para mecanismos de auxílio à priorização.

2.2 Indicadores de desempenho logístico

Neely, Gregory, e Platts (1995) definiram medida de desempenho como a métrica que permite quantificar a eficiência e a eficácia de uma ação. Desta forma, indicadores de desempenho traduzem o resultado de cada tarefa executada em uma medição de sucesso, facilmente auferível, associada a diversas variáveis de contexto, de menor ou maior complexidade e disponibilidade.

Segundo Cai, Liu, Xiao, e Liu (2009) indicadores de desempenho logístico são vastamente utilizados para medir a eficiência de empresas fornecedoras e fabricantes, com malhas logísticas de alta

complexidade ou de parceiros em cadeias de suprimentos. Por meio do gerenciamento desses indicadores, meras opiniões são traduzidas em dados quantificáveis (Beamon, 1999).

Neste sentido, Vieira, Yoshizak, e Ho (2015) classificaram e avaliaram um conjunto de indicadores de desempenho logístico a partir de uma *survey* com 125 representantes de fornecedores de produtos para grandes redes varejistas. Os indicadores avaliados foram: entregas no prazo, tempo de atendimento de pedido, entregas sem erro, atendimento das entregas programadas, frequência de entrega, entregas urgentes etc.

No entanto, identificar o melhor conjunto de indicadores e executar o monitoramento contínuo do desempenho é crucial para melhorar a eficácia e eficiência de uma cadeia de suprimentos (Shepherd & Günter, 2006).

Em especial, esta pesquisa se apoia na visão de Beamon (1999), de que dentre os diversos indicadores de desempenho utilizados para o gerenciamento de cadeia de suprimentos [GCS] (Neely, Gregory & Platts, 1995; Shepherd & Günter, 2006), o mais imprescindível é obter um controle estatístico de processos, conseguir gerar visibilidade de transporte, previsibilidade de entrega, possibilidade de simulação, suporte às atividades de planejamento e execução de processos de vendas, compras, e produção. O indicador de desempenho Entregas no Prazo (*On-Time Delivery* [OTD]) (Equação 9) é um dos mais abrangentes e que permite obter visibilidade da operação de distribuição de mercadorias a partir de um centro de distribuição ou da fábrica.

$$OTD = \frac{\sum \text{peças entregues em tempo}}{\sum \text{peças entregues}} \quad (7)$$

Além disso, OTD é um indicador que permite gerar gráficos de controle a serem utilizados em processos de produção controlados por metodologias como *Just in Time* (JIT) ou Seis-Sigma. A quantidade percentual de pedidos entregues a tempo deve circundar uma média, com desvio padrão baixo, para que o processo logístico seja considerado sob controle. Neste cenário trabalha-se com a confiança que os *lead times* sejam obedecidos e que planejamentos baseados nestes dados, como planos de distribuição, são confiáveis.

Nestas condições pode-se fazer não só planejamentos futuros, mas simulações confiáveis, estressando variáveis e explorando novos cenários. Desta forma, o método de priorização de entregas baseado em VE proposto, visa proporcionar um mecanismo que vai ao encontro do objetivo de maximizar o indicador OTD e, com isso, propiciar às vantagens às operações de transporte.

3 Método de pesquisa

Este trabalho teve seu desenvolvimento firmado nos passos propostos por Bertrand e Fransoo (2002) para a elaboração de metodologias para estudos quantitativos. Foi escolhido para este estudo um método quantitativo axiomático baseado em simulação. Essa escolha embasa o propósito desta pesquisa com grande aderência, pois este não objetiva desenvolver novo algoritmo ou conceito matemático, mas sim adaptar um modelo existente em um contexto de complexidade.

Desta forma, os passos de Bertrand e Fransoo (2002) foram adaptados a seguir, sendo que os dois primeiros passos já foram discutidos na revisão de literatura:

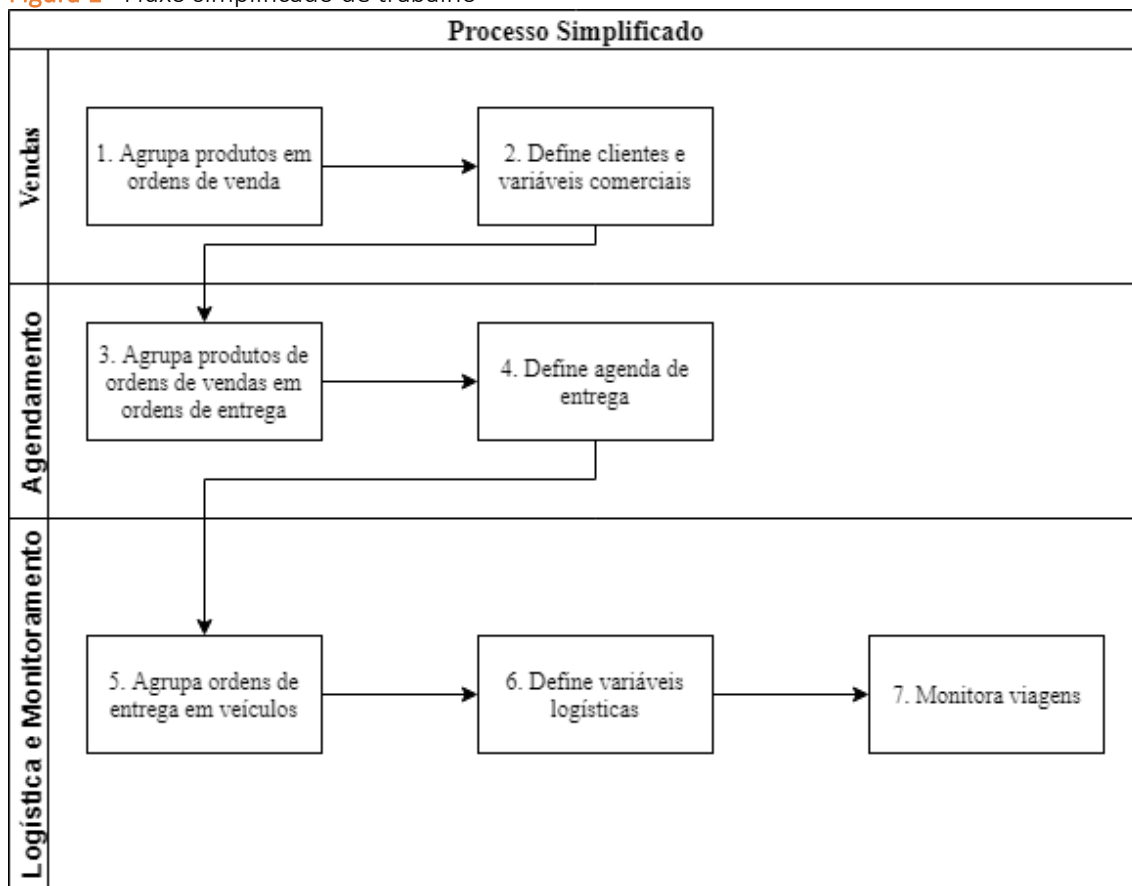
- Contextualização teórica e modelo científico
- Discussão e justificativa do método
- Contextualização do objeto de estudo
- Projeto experimental
- Discussão dos resultados

3.1 Contextualização do objeto de estudo

A empresa estudada é uma multinacional de produtos eletrônicos de alto valor agregado. Dentro desta empresa é focada a análise na subsidiária de vendas localizada em São Paulo no Brasil. Em especial, esta pesquisa abrange as variáveis de decisão disponíveis ao grupo de profissionais das áreas funcionais de vendas, agendamento e logística. Cada equipe, durante o fluxo de vendas, escolhe variáveis concernentes à venda e às entregas, como o cliente, os produtos, transportadora etc.

Na Figura 1 é apresentada uma simplificação deste fluxo, focando nos documentos que são gerados pelo trabalho de áreas funcionais e as variáveis que estão no universo de escolha de cada área funcional.

Figura 1 - Fluxo simplificado de trabalho



Fonte: Autores.

Os documentos gerados por estas áreas, principalmente as ordens de venda (OV), e as ordens de entrega (OE), têm seus nomes advindos de terminologias utilizadas pelo sistema de gerenciamento de pedidos (SGP) e sistema de gerenciamento de transporte (SGT) da empresa. A função destes documentos é criar agrupamentos de produtos a serem utilizados pelos profissionais das diferentes áreas funcionais.

Assim, de acordo com o fluxo da Figura 1, o pedido se inicia na área de vendas. Os profissionais desta área negociam com os clientes as quantidades de pedido, e inserem condições comerciais como preço e desconto. O documento que agrega estas informações é a ordem de venda (OV). A área de agendamento se encarrega de criar os agrupamentos de entrega. Esta área aloca os produtos a partir das localizações de estoque da malha e cria as ordens de entrega (OE), agrupando parte dos produtos das OV em OE.

A área de agendamento também é responsável por contatar os clientes e acordar uma data de agendamento de entrega para cada OE. Subsequentemente, para cada trecho de movimentação de produtos, os profissionais de logística agrupam as OE em agrupamentos de transporte como veículos e contêineres, escolhem as variáveis logísticas como transportadora, tipo de veículo, modal e Incoterm.

Por fim, as datas de execução de transporte como saída e chegada em cada nó da malha logística são atualizadas para cada OE durante a fase de monitoramento.

Neste trabalho são consideradas apenas as entregas contendo uma origem e um cliente de destino. Foram abrangidos nesta análise os modais de transporte terrestre e cabotagem. Em ambos modais foram considerados modelos de embarque carregamento completo do veículo (ou *Full Truck Load* [FTL]) e carregamento fracionado do veículo (ou *Less than Truck Load* [LTL]), assim como carregamento completo do container (ou *Full Container Load* [FCL]) e carregamento fracionado do container (ou *Less than Container Load* [LCL]) para os modais terrestre e de cabotagem. Ainda, são consideradas viagens de até duas transportadoras diferentes, possuindo modelos de transporte que contêm complexidades como consolidação e desconsolidação em HUBs de transporte, transmodalidade, *cross-docking*, e armazenamentos intermediários.

3.2 Projeto experimental

Para a execução desta simulação, foi utilizada a base de dados do sistema de SGT da empresa estudada. Desta base, foram escolhidas arbitrariamente apenas oito variáveis independentes e uma variável binária dependente. Esta escolha visou encontrar um universo mínimo de variáveis cuja responsabilidade de criação abrange todas as áreas funcionais do fluxo de venda. Nesta minimização visou-se também reduzir a chance de se incorrer em colinearidade eliminando variáveis que sempre ocorrem simultâneas. As variáveis categóricas foram tratadas pré-tratadas pelo método *one-hot-encoding*, que consiste em criar novas colunas na base de dados para cada realização possível desta variável, atribuindo valor 1 na coluna em que ela aparece e 0 nas demais. As variáveis escolhidas caracterizam de maneira simplificada um evento de transporte (vide Tabela 1).

Tabela 1 - Variáveis do modelo

Variável	Responsável criador	Natureza/Tipo
Cliente	Vendas	
Transportadora	Logística	
Estado	Vendas	
Tipo de agendamento	Agendamento	I/C
Tipo de embarque	Logística	
Origem	Agendamento	
Categoria de Produto	Vendas	
Quartil do mês	Agendamento	
Atraso	x	D/B

Nota: Natureza: I = Independente; D = Dependente. Tipo: C = Categórica; B = Binária.

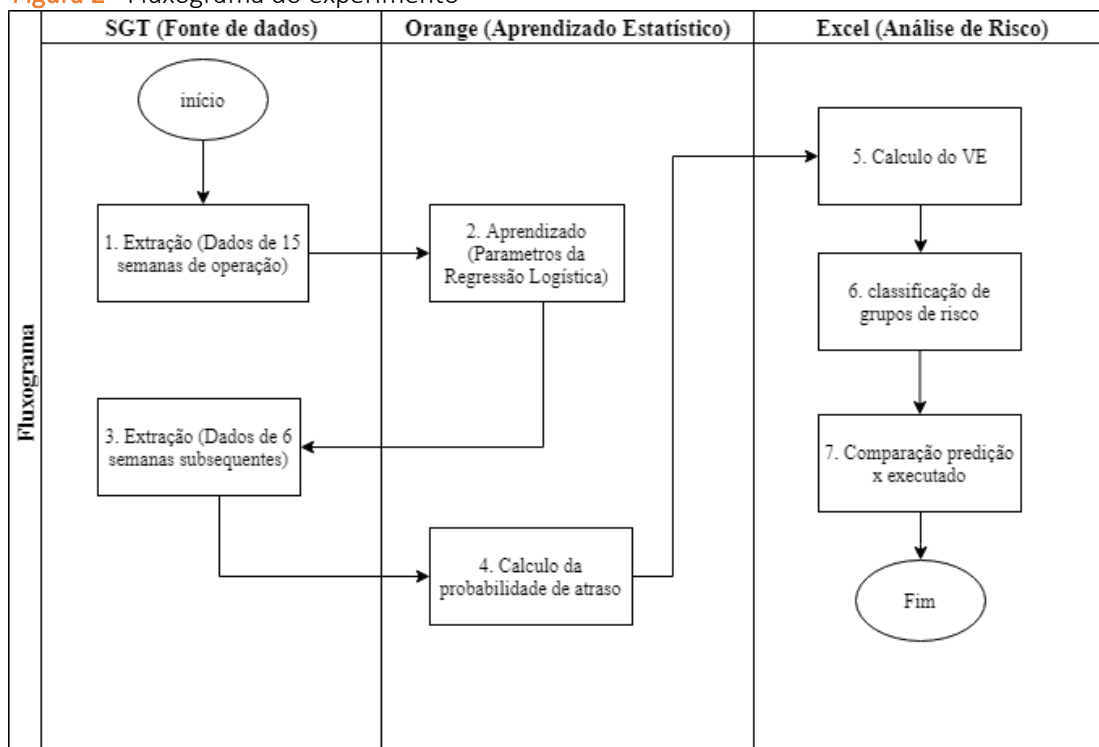
Fonte: Autores.

A seguir as variáveis da Tabela 1 são justificadas, como foram configuradas para poderem se ajustar ao modelo de RL.

- Cliente: Código do grupo de vendas do cliente. Em caso de baixa representatividade, estes foram agrupados em dois grupos nomeados *Destination Rest* (DR) e *Destination High* (DH). Ambos agrupam clientes com carteira inferior a 10 pedidos anuais, sendo o primeiro com pedidos de baixo valor e o segundo com pedidos de alto valor;
- Transportadora: Código da empresa de transporte contratada. No caso de transmodalidade, foi considerada apenas a última transportadora atuante como a responsável pelo transporte e por eventual atraso. Esta escolha se justifica tendo em vista que os *leadtimes* de transporte estabelecidos por arco levam em consideração uma folga de tempo suficiente para cobrir variações da primeira perna;
- Estado: Unidade Federal onde reside o cliente;
- Tipo de Agendamento: O tipo de agendamento identifica em que posição da malha logística as ordens de entrega devem ser agendadas com o cliente. A diferenciação de o contato com o cliente ocorrer quando o transporte se encontra mais próximo à origem ou mais próximo ao cliente gera diferentes categorias;
- Tipo de embarque: Para lidar com viagens que possuem vários trechos, e modais diferentes, foram agrupados os modelos de embarque e modal de cada segmento do arco de transporte em uma nova variável, que corresponde a um modelo de operação por arco;
- Origem: Identifica o ponto de origem dos transportes. Pode tanto ser um centro de distribuição, como uma planta de produção;
- Categoria de Produto: Identifica a categoria de produto transportado. Como as OE são geradas ao nível de granularidade de unidade de produto não há ambiguidade gerada por esta variável;
- Quartil do mês: identifica para qual quartil do mês foi agendada a entrega. Esta variável objetiva identificar se as concentrações de entrega em algum período do mês influenciam na chance destas entregas atrasarem;
- Marcação de atraso: O conceito de atraso parte do confronto da data de primeira agenda de entrega e a data de entrega. Uma OE é considerada atrasada quando a data de entrega é maior que data de agenda.

A Figura 2 mostra o fluxograma do experimento.

Figura 2 - Fluxograma do experimento



Fonte: Autores.

Seguindo o fluxograma da Figura 2, tem-se:

1. Extraiu-se uma base de 15 semanas sequenciais de operação logística do SGT da empresa, contendo as mesmas variáveis da Tabela 1. Esta fonte foi utilizada como base de aprendizado.
2. Foi utilizado o software Orange versão 3.11.0, para encontrar os coeficientes θ do modelo de RL, utilizando regularização do tipo LASSO.
3. Foi extraída uma base de seis semanas subsequentes de operação. Esta extração foi utilizada como base de teste.
4. Foi utilizada a equação de RL, parametrizada com os valores θ aprendidos na base de teste, para marcar as probabilidades de atraso em cada OE da base de teste.
5. Calculou-se o VE para cada OE da base de teste, multiplicando a probabilidade auferida com a RL pela quantidade de produtos da entrega.
6. As OE foram classificadas em cinco grupos de risco de acordo com o seu VE.
7. Por fim, validou-se o modelo em duas fases, validando primeiro a qualidade das probabilidades e em seguida a usabilidade do VE.

Para executar o passo 7 foram utilizadas diversas ferramentas presentes na literatura de AE, que auxiliam na mensuração da qualidade de um modelo preditor (Hastie et al., 2009).

Assim, primeiramente foi conduzido um teste de validação cruzada, gerando 10 grupos de dados aleatórios a partir da base de aprendizado. Cada grupo foi mantido como base de teste para um modelo de RL gerado a partir dos demais dados. A proporção mantida foi de 66% dos dados para o tamanho da base de aprendizado e 34% para a base de teste. A média das 10 iterações foi utilizada para construir uma Curva Característica do Receptor (CCR) e uma curva de calibração, correlacionando as médias observadas com as probabilidades calculadas. Segundo os mesmos autores, um modelo é considerado um bom preditor quando a área embaixo da curva (AEC) de CCR é superior a 75% e quando a curva de calibração é próxima a bissetriz. Para validar o modelo buscou-se, portanto, medir se a AEC obtida foi superior a 75% e se a curva de calibração se aproxima da bissetriz.

Outro mecanismo utilizado foi a comparação das previsões com as verdadeiras taxas de atraso nas entregas da base de teste. Utilizou-se de uma matriz de confusão e comparou-se a taxa de atraso em cada um de cinco grupos, de faixas de probabilidade diferentes. Esta categorização visou permitir identificar se a taxa real de atraso realmente é maior onde as probabilidades de atrasar são previstas com valores altos.

Por fim, mediu-se, de maneira similar ao último passo, a aplicabilidade do VE como técnica de priorização de risco. Para isto, compararam-se as taxas de atraso real, de entregas classificadas em grupos de risco distintos, baseados em seu valor de VE. A quebra das taxas de atraso real em grupos de risco objetiva identificar se, em grupos de risco alto, dois outros fatores também são encontrados. Espera-se que, se a proporção de atraso for alta e concomitantemente o tamanho do grupo de risco for pequeno, encontra-se uma oportunidade. Isso significa que, redirecionando os esforços de monitoramento e gerenciamento, para um grupo mínimo de entregas é possível obter as melhores chances de reduzir atrasos, assim obtém-se um eficiente mecanismo de priorização das entregas.

4 Discussão dos resultados

Neste tópico são apresentados de forma comparativa os coeficientes de cada variável do modelo de RL, e são discutidas as implicações destes valores. Em seguida é testada a qualidade do modelo de RL e do modelo de priorização baseado em VE.


4.1 Contextualização dos resultados

O resultado obtido com o modelo de RL aplicado à base de aprendizado foi sumarizado no Nomograma da Figura 3. Cada coeficiente β_j do modelo é representado em uma escala de pontos dada pela distância de seu menor valor. Ou seja, o menor β_j é representado como zero, e os demais como a

diferença entre seu valor original e o de menor valor. Quanto maior a amplitude entre as instâncias de uma mesma variável, maior é a variação que ela causa na probabilidade final. As instâncias mais à direita são as que contribuem mais positivamente para a probabilidade de atrasar. A combinação destes coeficientes é, então, traduzida em probabilidade pela equação (1), e representada na última barra inferior. Com isso, é possível visualizar a probabilidade de atraso de uma combinação de variáveis logísticas gera e compará-las entre si.

No exemplo ilustrado pela Figura 3, o resultado obtido com este modelo foi de que escolhas geográficas como o cliente, e o Estado da entrega, em conjunto com variáveis concernentes à operação, como a transportadora, o tipo de embarque ou o tipo de agendamento, são muito mais influentes na probabilidade de uma entrega falhar o cumprimento de sua agenda do que a escolha do produto, da origem ou do período do mês em que a entrega foi efetuada. A combinação de variáveis marcadas com bolas azuis se traduz em 67% de chance de atraso.

Figura 3 - Nomograma dos valores dos coeficientes β_j como distância do menor β_j da mesma variável



Nota: Obtido a partir de simulação com software Orange Data Mining.

Fonte: Autores.

É interessante notar, pela Figura 3, que o resultado do quartil do mês de entrega influi pouco na probabilidade de atraso como observado pela concentração à esquerda das instâncias desta variável, e, ainda, as entregas agendadas para o último quartil são as de menor chance de atrasar. Embora isto seja contraintuitivo, talvez se deva à expectativa de que as concentrações de entregas em final de mês gerassem dificuldades operacionais que causassem atrasos.

Existem diversos fatores para que concentrações desta natureza ocorram. Sterman (1989) identificou esta alternância entre concentração e escassez como efeitos advindos de ingerência dos tomadores de decisão sobre seu inventário. Já Lee, Padmanabhan, e Whang (1997) identificaram estas flutuações como algo comum à toda cadeia de suprimentos e citaram, dentre vários, que fatores corriqueiros como falta de visibilidade sobre a demanda real, políticas de desconto e consolidações de transporte geram o comportamento alternante que eles denominaram efeito chicote. Pode-se interpretar que para a empresa estudada, apesar das concentrações de entrega em fim de mês, as pressões internas para atingir os objetivos de vendas, podem ser também superiores neste quartil. Esta pressão reforça a comunicação entre o time de logística, os transportadores e os clientes. Este reforço pode influir positivamente para que os transportadores cumpram o cronograma de entrega, e que os clientes recebam as mercadorias na data agendada. Este resultado, no entanto, não é generalizável e poderia ser razoavelmente mais significativo em outra malha logística.

Um tomador de decisão imbuído desses dados conseguiria atuar de maneira proativa na minimização do risco de atraso de duas maneiras, (i) realimentando o planejamento com a chance de entregas futuras atrasarem, ou (ii) tomando medidas corretivas direcionadas. Nos próximos tópicos são validados a qualidade do modelo matemático e a aplicabilidade do mecanismo de priorização baseado em VE.

4.2 Validação do modelo de regressão logística

A partir dos testes de validação cruzada executados na base de teste, foi obtida a curva de CCR da Figura 4. A área abaixo desta curva é uma das maneiras de se medir a qualidade de um preditor. Quanto melhor for as predições, mais a curva CCR se afasta da bissetriz. A bissetriz representa neste gráfico quais valores seriam obtidos caso as predições fossem geradas a partir de um modelo perfeitamente aleatório (James et al., 2017). A Tabela 2 apresenta os demais valores dos testes de qualidade da classificação obtidos com a validação cruzada.

Tabela 2 - Avaliação de resultados da regressão logística

Testes	AEC	AC	F1	Precisão	Recall
Valores	0.754	0.854	0.811	0.834	0.854

Nota: Extraído de simulação com software Orange Data Mining.


Fonte: Autores.

As nomenclaturas e respectivas definições utilizadas na Tabela 2 são:

- AEC: Área embaixo da curva de CCR
- AC: Acurácia da classificação. Mede a proporção de eventos corretamente classificados
- F1: Média harmônica entre Precisão e Recall
- Precisão: Proporção de verdadeiros positivos entre todas as instâncias classificadas como positivos. No modelo é proporção de entregas que foram preditas que atrasariam e que realmente atrasaram, por todas que foram preditas que atrasariam.
- Recall: Proporção de verdadeiros positivos entre todas as instâncias positivas da base de dados. No modelo é proporção de entregas que foram preditas que atrasariam e que realmente atrasaram, por todas as entregas que atrasaram.

A AEC obtida na Tabela 2 mostra que o modelo de RL alcançou resultado próximo a 75%. Isto mostra que as probabilidades aferidas pelo modelo de regressão têm eficácia 25% superior ao resultado do lançamento de uma moeda de forma aleatória. Deve-se, no entanto, destacar nos resultados, principalmente, o elevado valor obtido de Precisão e Recall obtidos na Tabela 2. Pelos valores altos nestes dois índices, pode-se entender que as combinações das realizações das variáveis aleatórias, aprendidas pelo modelo como causadoras de atraso, continuaram ao longo de todo o período compreendido pela base de aprendizado sendo simultâneas a atrasos reais. Caso estes valores continuarem altos na base de teste pode-se inferir que os fatores causadores de atraso são perenes na operação e não estaria havendo atuações reparadoras para resolvê-los.

Figura 4 - Curva Característica de Receptor (CCR)



Nota: Obtido a partir de simulação com o software Orange Data Mining.

Fonte: Autores.

Em sequência, O modelo de RL, parametrizado com a base completa de aprendizado, foi utilizado para a predição de atraso de cada uma das OE da base de teste. A comparação de qualidade feita foi averiguar se as predições de atraso se traduziram em atrasos reais. O risco inerente é de que dada a natureza dinâmica do negócio, os fatores causadores de atraso tenham mudado. A qualidade das predições foi medida com as Tabelas 3 e 4.

A Tabela 3 contém uma matriz de confusão, explicitando divergência e convergência entre os valores observados e os previstos. Os valores também são exibidos como proporção do total. Na Tabela 3 é possível inferir algumas informações tanto a respeito do processo de entrega quanto da qualidade das predições. É possível verificar que o processo de entrega está sob controle, pois a grande maioria, 82.7% das OE não atrasa com frequência, possibilitando que 79.9% da amostra concorde quanto às predições de não atraso e real ocorrência de entregas pontuais. Com isso é gerada uma proporção alta de verdadeiros negativos 85.9%. Já na região de interesse, a de predição de atraso, a divergência foi mais alta. O Recall ficou em 24.7% e a Precisão ficou em 61.3%. Esta discrepância de valores leva a inferir duas observações. (i) A Precisão 61.3%, resultado inferior em 22% ao da Tabela 2 mostra que parte dos dados da base de aprendizado, que ajudavam a explicar o porquê no atraso das entregas, deixaram de ser simultâneos a atrasos na amostra da base de teste. Já (ii) o Recall de 24.7%, resultado 60.7% inferior ao da validação cruzada obtido na Tabela 2, mostra que atrasos passaram a ocorrer simultâneos a outros dados que não os observados na base de aprendizado, gerando um denominador maior de casos de atrasos reais que não são explicados pelo modelo.

Tabela 3 - Tabela de confusão comparando atraso previsto contra realizado

		Atraso Previsto		Total
		Não	Sim	
Atraso Real	Não	3,747 (79.96%)	127 (2.71%)	3,874
	Sim	611 (13.03%)	201 (4.28%)	812
Total		4,358	328	4,686

Nota: Obtido a partir de simulação com software Orange Data Mining.

Fonte: Autores.

Este resultado, no entanto, pode ser explicado pela natureza dos dados. Primeiramente a base de teste é extraída de uma amostragem posterior à da base de aprendizado. Adicionalmente, esta base possui um intervalo amplo de seis semanas, escolhido de forma a possibilitar um represamento de uma população considerável de dados e classificações. Com isto, este decréscimo na qualidade das predições de atraso reflete que as circunstâncias geradoras da parametrização do modelo de classificação mudaram sensivelmente de um período para o outro, o que é esperado em um negócio de natureza tão dinâmica. Fatos geradores de atraso podem ter sido identificados e corrigidos durante este período. Também vale-se notar que existe uma parcela razoável dos dados que estão sujeitas atraso por fatores aleatórios e que não são capturados pelo modelo.

Apesar das mudanças detectadas, existe ainda uma parcela dos dados para os quais se espera que a parametrização do modelo preditor ainda seja boa. Espera-se que uma parcela dos dados seja mais estática às mudanças. Para esta parcela as realizações das variáveis que eram simultâneas a atrasos na base de aprendizado devem também ser na base de teste. Estas variáveis devem ser as que possuem os coeficientes mais altos e que, portanto, quando presentes, devem gerar os maiores valores de probabilidade de atraso. Por isso, espera-se que, apesar da perda de qualidade nas predições quando se muda do contexto da base de aprendizado para a base de teste, que as predições associadas a altas probabilidades se mantenham boas. Para identificar isto foi gerada a Tabela 4.

A Tabela 4 mostra agrupamentos, a partir das probabilidades de atraso das OE, separando-as em faixas de probabilidade de atraso, a quantidade real de OE em cada faixa, que atrasou ou não, e mostra também a razão destas quantidades e o quanto este grupo representa do total.

A Tabela 4 permite identificar em que faixa de probabilidade as predições são crescentemente mais eficazes. É possível observar que em 81% dos casos, em que a probabilidade prevista de atraso é baixa, a razão de atraso por não atraso é condizentemente pequena. Quando a probabilidade de atrasar é próxima de 50% a razão de atraso por não atraso; conforme esperado, ficou próximo de 1. Por fim,

para 5% das entregas, que têm a probabilidade de atrasar acima de 80% é observado um índice quase duas vezes superior de atraso. Ou seja, a cada entrega que não atrasa, duas atrasam. Este resultado mostra que existe de fato uma correlação positiva entre a probabilidade prevista de atraso e a proporção real de atraso, e principalmente, ilustra que as probabilidades traduzem uma proporção real e observável de atraso.

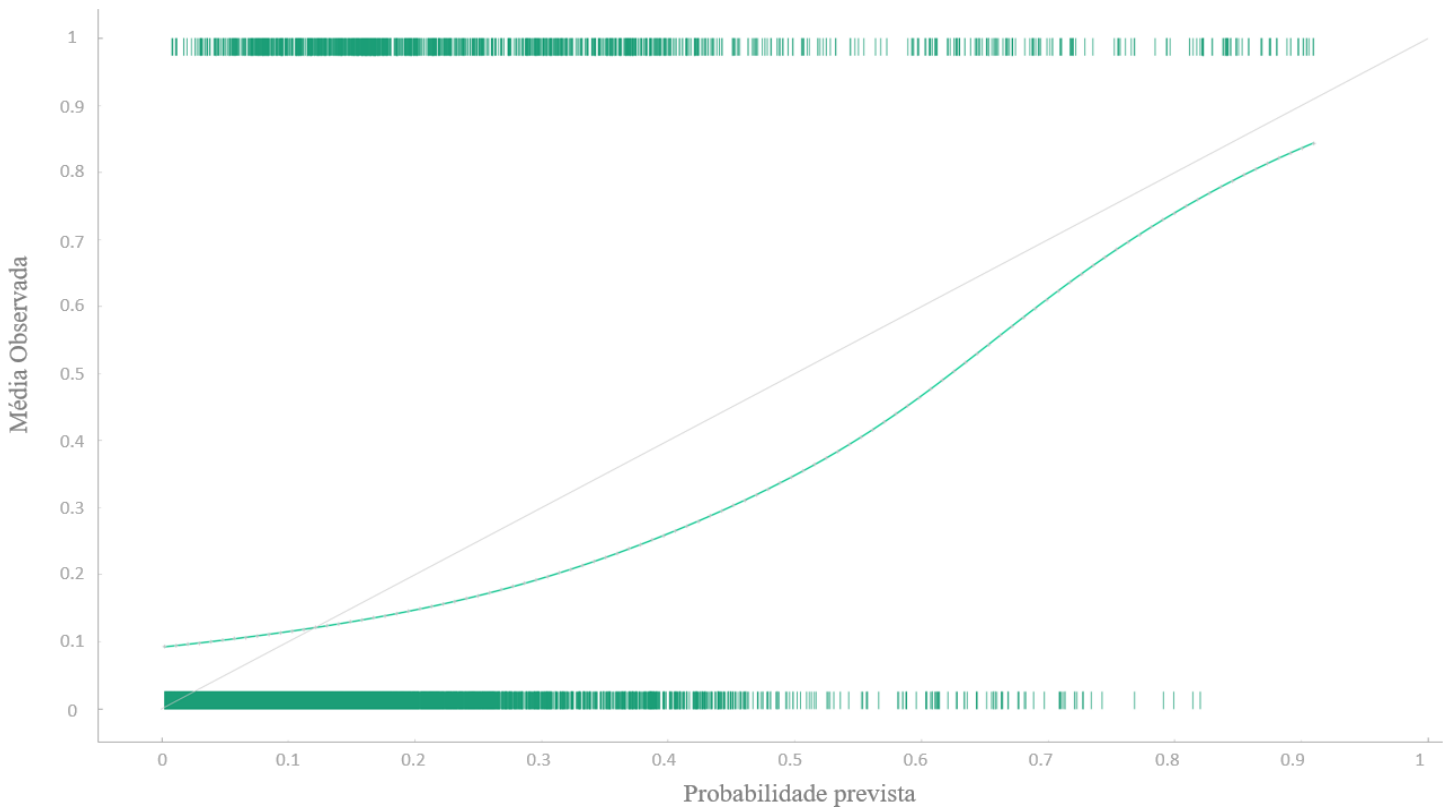
Tabela 4 - Tabela de Proporção de Atraso por Faixa de Probabilidade

Faixa de probabilidade	Real	Contagem	Sim/Não (Real)	Proporção
Muito Alta [0.8, 1]	Não	84	1.83	0.05
	Sim	154		
Alta [0.5, 0.8]	Não	43	1.09	0.02
	Sim	47		
Média [0.3, 0.5]	Não	414	0.32	0.12
	Sim	132		
Baixa [0, 0.3]	Não	3,333	0.14	0.81
	Sim	479		

Fonte: Autores.

A curva que explicita esta correlação pode ser observada na Figura 5. Observa-se a relação entre a média de atraso observada na base de teste e a probabilidade teórica de atraso, obtida com a calibração do modelo na base de aprendizado. A forma como a curva se aproxima da bissetriz em faixas de alta probabilidade mostra como a probabilidade prevista se reflete em uma proporção real de atraso, logo é um bom mecanismo preditor nesta faixa de probabilidades. Isto é, pela aproximação da curva de calibração da bissetriz, a partir de valores previstos acima de 70%, pode-se esperar que as previsões com valores acima desta faixa refletirão médias observadas de atrasos de proporções similares.

Figura 5 - Curva de Calibração da Regressão Logística



Nota: Obtido de simulação com software Orange Data Mining.

Fonte: Autores.

4.3 Validação do modelo de valor esperado

Não basta auferir com alta confiança que uma OE tem chance alta de atrasar. É necessário que ela seja de alta prioridade para o time de monitoramento de entrega logística. Isto só ocorre caso ela seja uma entrega com um número alto de peças, pois estas são as entregas cuja falha impacta com maior relevância o indicador de desempenho OTD.

Porém, como o mecanismo de priorização por VE recebe de entrada as probabilidades da RL, que por sua vez, conforme observado têm confiabilidade crescente com seu valor, pode-se gerar VE que são igualmente confiáveis ou não confiáveis. Como exemplo, pode-se ter entregas na base de teste com quantidades desproporcionalmente mais altas de peças, que apesar de possuírem probabilidades baixas de atraso, ainda gerariam um VE alto. Porém, por utilizar probabilidades baixas estes VE, seriam pouco confiáveis. Pretende-se, portanto, identificar se para o grupo de entregas de VE alto tem-se como observar uma taxa alta de atraso real. Caso isto aconteça será identificado um grupo de entregas de alta relevância para atuação dos profissionais de monitoramento, pois este seria um grupo cujos fatores geradores de atraso vêm se mantendo perenes, e cuja relevância é alta em caso de falha.

Por isto, para testar o modelo de priorização de entregas por VE, foram seguidos os seguintes passos. As probabilidades de atraso foram calculadas para cada OE da base de teste, assim como também foi calculado o VE de cada uma, multiplicando-se as probabilidades pelas quantidades das OE.

Em sequência foram criados grupos diferentes de OE os segregando por valor de VE, para isto, foram utilizados as médias e os desvios padrão dos VE calculados. A Tabela 5 mostra esses resultados para os cinco diferentes grupos (Faixas de VE).

Desta forma, pela Tabela 5, é possível comparar como se comporta a razão de atraso por não atraso em diferentes faixas de VE. É observável que apenas na faixa mais alta de VE tem-se um comportamento favorável, em que a taxa de atraso por não atraso é superior a 50%. Em geral a proporção de entregas atrasadas por entregas em tempo é inferior a 26%. Observa-se também o tamanho dos grupos da Tabela 5. O grupo de maior importância possui apenas 1% do total de pedidos. Logo, priorizá-los, é uma atividade de mínimo esforço.

Tabela 5 - Proporção de Atraso por Faixas de VE

Faixa de VE	Real	Contagem	Sim/Não	Proporção
> Média +3 desvpad	Não	42	0.64	0.01
	Sim	27		
> Média +2 desvpad	Não	66	0.17	0.02
	Sim	11		
> Média +1 desvpad	Não	111	0.26	0.03
	Sim	29		
> Média	Não	696	0.16	0.17
	Sim	112		
< Média	Não	2959	0.21	0.77
	Sim	633		

Fonte: Autores.

Apesar do resultado favorável no grupo de maior VE, é possível perceber que as sugestões de priorização dos demais grupos não seriam viáveis, dado suas baixas taxas de atraso. Com isto, foi percebido que a utilização do VE introduziu também um fator complicador, onde o agrupamento por VE sem uma pré-filtragem, gera uma mistura de dados de probabilidades menos confiáveis com mais confiáveis, o que acaba contaminando grupos de VE alto. Com os resultados obtidos pode-se apenas defender que o método de priorização apresentado é eficaz, apenas quando se pretende segregar dos demais dados, apenas o topo de 1% da população de maior VE, para ações corretivas. Ainda assim, este resultado foi particular ao contexto da empresa estudada.

Alternativamente, visando evitar o problema de mistura de dados não confiáveis, poder-se-ia ter separado as entregas de maior probabilidade de atraso das demais, e utilizar o VE para priorizar estas somente. Desta forma seriam criados grupos de valor de VE apenas com dados confiáveis, sem incorrer nos problemas de contaminação discutidos.

5 Conclusões

Foi possível validar que os valores de probabilidades obtidos pela técnica de RL são de boa qualidade e que, entregas classificadas baseadas em seu VE em grupo de risco alto são a menor parte das entregas e, também, as que proporcionalmente mais atrasam. Concluiu-se que o modelo proposto é um eficaz mecanismo de priorização de entrega e sua aplicação dentro de empresas, simultâneo ao planejamento e monitoramento de transporte, geraria oportunidades no direcionamento de trabalho, minimização de esforços e redução de atrasos.

Em contrapartida, os resultados obtidos também são sensíveis em alguns pontos relevantes. Em primeiro lugar, o modelo matemático escolhido toma como premissa regras que nem sempre são verdades para os dados, como: independência linear e não colinearidade. Igualmente válido, a tentativa de interpolar uma curva de regressão também traz diversas fragilidades, como passibilidade de superajuste (*overfit*) aos dados de aprendizado, alta sensibilidade aos dados de entrada e a *outliers*, e passibilidade de que problemas de baixa amostragem e separação total dos dados possam gerar distorções e até invalidar o modelo. Por isso, foi necessário fazer diversas tratativas nos dados e rodadas de simulação que minimizassem os efeitos descritos.

Este estudo contribui para a bibliografia de logística ao aplicar uma técnica que permite com que membros de áreas funcionais, pertencentes a grupos corporativos, dediquem esforços em atividades que estejam alinhadas com a maximização de seus indicadores de desempenho. Em curto prazo o VE obtido pode auxiliar equipes de monitoramento remoto a priorizar entregas. Porém, no longo prazo, outros resultados como os valores dos coeficientes da RL permitem identificar as variáveis que mais impactam a chance atraso, e pode auxiliar as áreas de aquisições, comerciais e de planejamento estratégico a redesenhar e substituir o grupo de fornecedores, clientes, operações e demais variáveis, que tenham seu desempenho desalinhado com o objetivo estratégico da empresa.

Este trabalho também contribui para a bibliografia de AE, pois traz uma implementação prática de um modelo matemático bem estabelecido e de amplo uso em diversos campos da ciência, mas que ainda possui baixa disseminação na área de logística. Tópicos relacionados a aprendizado de máquina, inteligência artificial e aprendizado estatístico têm ganhado, paulatinamente, popularidade e importância, e é crescente o número de aplicações nos mais diversos segmentos de pesquisa. A relevância deste trabalho advém da criação de uma aplicação, que faz o elo entre estas áreas de conhecimento.

Adicionalmente, pode-se atribuir como uma contribuição relevante deste trabalho ser possivelmente o primeiro na aplicação de técnicas de predição de atraso na área de logística empresarial. Com isto, este trabalho preenche uma lacuna existente na segregação entre produção científica e aplicabilidade prática em contextos de negócios.

Como limitações deste estudo, é válido ressaltar a escolha das variáveis logísticas aqui usadas. Neste estudo foi feita uma escolha parcial e pouco abrangente das variáveis de entrada relacionadas à

probabilidade de atraso. Estudos futuros poderiam explorar quais as variáveis, do contexto de logística, que mais impactam a probabilidade de atraso.

Como oportunidades de futuros de estudo, cabe comparar quantitativamente modelos diferentes de AE. Alternativamente, cabe um estudo de caso utilizando a técnica de priorização de entregas por VE dentro de uma empresa, para comparar os cenários de antes e depois, ilustrando uma redução real de atraso.

Finalmente, a escolha do segmento da operação destinada a este estudo foi feita visando excluir cenários de alta complexidade. Em cenários mais complexos possivelmente seria mais difícil defender as premissas do modelo matemático escolhido, e, portanto, seriam mais passíveis de questionamento os resultados obtidos. Futuros estudos poderiam, no entanto, explorar os resultados de simulações em cenários mais complexos e assim, validar a possibilidade de generalização dos resultados aqui obtidos.

Referências

- Beamon, B. M. (1999). Measuring supply chain performance. *International Journal of Operations & Production Management*, 19(3), 275–292. <https://doi.org/10.1108/01443579910249714>.
- Berssaneti, F. T., & Carvalho, M. M. (2015). Identification of variables that impact project success in Brazilian companies. *International Journal of Project Management*, 33(3), 638–649. <https://doi.org/10.1016/j.ijproman.2014.07.002>.
- Bertrand, J. W. M., & Fransoo, J. (2002). Modelling and Simulation: Operations management research methodologies using quantitative modelling. *International Journal of Operations & Production Management*, 22(2), 241–264. <https://doi.org/10.1108/01443570210414338>.
- Cai, J., Liu, X., Xiao, Z., & Liu, J. (2009). Improving supply chain performance management: A systematic approach to analyzing iterative KPI accomplishment. *Decision Support Systems*, 46(2), 512–521. <https://doi.org/10.1016/j.dss.2008.09.004>.
- Hastie, T., Tibshirani, R., & Friedman, J. (2009). The Elements of Statistical Learning. In *Bayesian Forecasting and Dynamic Models* (Second Edi, Vol. 1). <https://doi.org/10.1007/b94608>.
- Hosmer, D. W., Lemeshow, S., & Sturdivant, R. X. (2013). Applied Logistic Regression. In *John Wiley & Sons* (3rd Editio). <https://doi.org/10.1002/9781118548387>.
- James, G., Witten, D., Hastie, T., & Tibshirani, R. (2017). *An Introduction to Statistical Learning: With Applications in R* (8th Editio; G. Casella, S. Fienberg, & I. Olkin, Eds.). <https://doi.org/10.1007/978-7-4614-7138-7>.
- Kuhn, N., & Jamadagni, N. (2017). *Application of Machine Learning Algorithms to Predict Flight Arrival Delays*. 1–6.
- Lee, H. L., Padmanabhan, V., & Whang, S. (1997). Information Distortion in a Supply Chain: The Bullwhip Effect. *Management Science*, 43(4), 546–558. <https://doi.org/10.1287/mnsc.43.4.546>.
- Lessan, J., Fu, L., & Wen, C. (2018). A hybrid Bayesian network model for predicting delays in train operations. *Computers and Industrial Engineering*, (March). <https://doi.org/10.1016/j.cie.2018.03.017>.
- Long, J. S. (1997). Regression models for categorical and limited dependent variables. *American Journal of Sociology*, Vol. 103, p. 328. <https://doi.org/10.1086/231290>.

- Long, W. J., Griffith, J. L., Spelker, H. P., & D'Agostino, R. B. (1993). A Comparison of Logistic Regression to Decision-Tree Induction in Medical Domain. *Computers and Biomedical Research*, (26), 74–97.
- Mukherjee, A., Grabbe, S. R., & Sridhar, B. (2014). Predicting Ground Delay Program At An Airport Based On Meteorological Conditions. *14th AIAA Aviation Technology, Integration, and Operations Conference*, (June), 1–18. <https://doi.org/10.2514/6.2014-2713>.
- Neely, A., Gregory, M., & Platts, K. (1995). Performance measurement system design: A literature review and research agenda. *International Journal of Operations & Production Management*, 15(4), 80–116. <https://doi.org/10.1108/01443579510083622>.
- Ni, J., Wang, X., & Li, Z. (2017). *Flight Delay Prediction using Temporal and Geographical Information*. 1–4. Retrieved from <https://cseweb.ucsd.edu/classes/wi17/cse258-a/reports/a032.pdf>.
- Patah, L. A., & Vargas Neto, D. M. (2016). Avaliação Da Relação Entre a Virtualidade De Equipes E O Desempenho Operacional De Projetos: Uma Análise Quantitativa. *Revista de Gestão e Projetos - GeP*, 7(2). <https://doi.org/10.1017/CBO9781107415324.004>.
- Raschka, S., & Mirjalili, V. (2019). *Python Machine Learning* (3rd ed.). Retrieved from <https://www.packtpub.com/product/python-machine-learning-third-edition/9781789955750>.
- Shepherd, C., & Günter, H. (2006). Measuring supply chain performance: current research and future directions. *International Journal of Productivity and Performance Management*, 55(3/4), 242–258. <https://doi.org/10.1108/17410400610653219>.
- Sterman, J. D. (1989). Modeling Managerial Behavior: Misperceptions of Feedback in a Dynamic Decision Making Experiment Author(s): MODELING MANAGERIAL BEHAVIOR: MISPERCEPTIONS OF FEEDBACK IN A DYNAMIC DECISION MAKING EXPERIMENT*. *Source: Management Science MANAGEMENT SCIENCE*, 35(3), 321–339. <https://doi.org/10.1287/mnsc.35.3.321>.
- Takagi, Y., Mizuno, O., & Kikuno, T. (2005). An Empirical Approach to Characterizing Risky Software Projects Based on Logistic Regression Analysis. *Empirical Software Engineering*, 10(4), 495–515. <https://doi.org/10.1007/s10664-005-3864-z>.
- Tibshirani, R. (1996). Regression Shrinkage and Selection Via the Lasso. *Journal of the Royal Statistical Society: Series B (Methodological)*, 58(1), 267–288. <https://doi.org/10.1111/j.2517-6161.1996.tb02080.x>.
- Vieira, J. G. V., Yoshizak, H. T. Y., & Ho, L. L. (2015). The effects of collaboration on logistical performance and transaction costs. *International Journal of Business Science & Applied Management (IJBSAM)*, 10(1), 1–14.
- Wang, Z., Liang, M., & Delahaye, D. (2018). A hybrid machine learning model for short-term estimated time of arrival prediction in terminal manoeuvring area. *Transportation Research Part C: Emerging Technologies*, 95(January), 280–294. <https://doi.org/10.1016/j.trc.2018.07.019>.
- Yaghini, M., Khoshraftar, M. M., & Seyedabadi, M. (2013). Railway passenger train delay prediction via neural network model. *Journal of Advanced Transportation*, 47(3), 355–368. <https://doi.org/10.1002/atr.193>.