Universidade Federal do Paraná
Setor de Ciências Exatas
Departamento de Estatística
Programa de Especialização em *Data Science* e *Big Data*

Victor Mussolin Lopes

Aplicação de Machine Learning na Gestão de Riscos da Supply Chain de Uma Empresa de Alta Tecnologia

Curitiba
2024

Victor Mussolin Lopes

Aplicação de Machine Learning na Gestão de Riscos da Supply Chain de Uma Empresa de Alta Tecnologia

Monografia apresentada ao Programa de Especialização em *Data Science* e *Big Data* da Universidade Federal do Paraná como requisito parcial para a obtenção do grau de especialista.

Orientador: Prof. Luiz Eduardo Soares de Oliveira

Curitiba
2024

Aplicação de aprendizagem de máquina na Gestão de Riscos da Supply Chain de uma Empresa de Alta Tecnologia

Victor Mussolin Lopes[1]

[1]Departamento de Estatística, Universidade Federal do Paraná R. Evaristo F. Ferreira da Costa 383-391, Jardim das Américas, 81530-090, Curitiba, PR, Brasil*

A gestão das cadeias de suprimento global dentro do escopo de manufatura tem se tornado cada vez mais complexa e vunerável a paradas de entregas. Em tal ambiente, empresas devem mapear riscos em suas cadeias de suprimento para que possam agir a tempo de impedir ou remediar essas interrupções. Essa vulnerabilidade aumentou o interesse na Gestão de Riscos de Cadeias de Suprimento (GRCS) nos ambientes corporativo e acadêmico. A GRCS visa entender as causas das interrupções, monitorá-las e tratá-las quando necessário. A ferramenta de Aprendizagem de Máquina (AM) está se apresentando como um ótimo meio de facilitar as interações com os novos dados das cadeias de suprimento. Esse artigo documenta a aplicação de Aprendizagem de Máquina em conujnto com a biblioteca SHAP do *Python* como uma ferramenta de suporte para diversas etapas do GRCS dentro de uma empresa de manufatura de alta tecnologia. Essa aplicação irá focar em prever atrasos de entregas e desenvolver informação dos riscos relacionados.
Palavras-chave: GRCS, aprendizagem de máquina, Cadeia de Suprimento, SHAP

Supply Chain Management in global manufacturing has become more complex and vulnerable to interruptions. In such environment, companies must be able to identify related risks before it is too late to address or mitigate these interruptions. Because of such vunerability, the interest in Supply Chain Risk Management (SCRM) has increased both in the academic and cooperative scenes. SCRM seeks to understand, track and treat the cause of interruptions. Machine Learning has been presented as a great tool to facilitate interactions with the new data in supply chains. This article documents the implementation of ML in junction with SHAP python library as a tool to support various steps in SCRM inside a high techonology manufacturing company. This implementation will predict delivery delays and develop information about the various risks related to these delays.
Keywords: SCRM, Machine Learning, Supply-Chain, SHAP

1. Introdução

A Gestão de Cadeia de Suprimento (GCS), tem como objetivo de manter as entregas com qualidade, dentro do tempo estabelecido e com custo mínimo. Para gerencias os riscos de interrupções dessas entregas, a subvertende conhecida como Gestão de Riscos de Cadeias de Suprimentos (GRCS), foi criada [1]. As grandes perdas financeiras provindas desses atrasos e interrupções geram grande interesse na sub-vertente. Em 2011, Thun e Hoenig [2] já confirmavam que empresas de manufatura deveriam se adaptar a incerteza e complexidade de suas cadeias de suprimentos.

Mesmo dez anos depois, essa complexidade e incerteza é um desafio, Wieland e Durach [3] indicam que, no ambiente dinâmico da cadeia de suprimento, seus vários agentes, inumeras conexões e caracteristicas únicas desvalidam uma abordagem a partir de listagem de riscos. Esse ambiente incerto incentivou o uso de novos avanços tecnológicos e novas ferramentas.

Harju et al.[4] argumentam que a digitalização dentro do controle das cadeias de suprimentos, em conjunto com tecnologias avançadas (como *Big Data Analytics* e Inteligência Artificial (IA)) provêm uma visão holística que diminui a incerteza desses processos a partir de melhor visualização de riscos e tomadas de decisões com informação focada em dados. Uma dessas ferramentas que tem se demonstrado efetiva é a aprendizagem de máquinha (AM), que gerou grande interesse na área depois de 2020 [5], com várias aplicações de algoritimos de AM em diversos aspectos da GRCS.

*victor.mussolin.vml@gmail.com

Kara et al.[6] argumentam que AM detém a capacidade de transformar dados e métricas comuns em informação e conhecimento novo para tomada de descisões mais inteligêntes dentro da GRCS. AM também pode trazer flexibilidade, melhor tempo de resposta, confiabilidade e precisão em informações[7].

Considerando métricas como bases para estudos de AM dentro de GRCS para desenvolvimento de informação, É importante garantir que a mesma possa ajudar na compreenção dos riscos relacionados às interrupções. Esse artigo irá trabalhar com uma versão de uma das métricas mais importantes para cadeias de suprimentto, o *On-Time Delivery* (OTD), que normalmente funciona como um controle de confiabilidade de entrega de fornecedores [8], porém em uma visão do departamento de compras , irá se referir á confiabilidade de entregas do departamento para o setor de manufatura..

A aplicaçao será efetuada em uma empresa de manufatura de alta tecnologia. A empresa em questão trabalha por projetos B2B, com grandes impactos financeiros relacionados a atrasos de entregas. Grande parte de seus processos de industrialização são terceirizados, aumentando a complexidade e e etapas de controle necessárias. O escopo a ser trabalhados será de suas entregas de 2023.

Esse trabalho irá monitorar o OTD do setor de compras, considerando que reflete o risco de interrupção da cadeia de suprimento. Adicionalmente, irá mapear riscos que possam afetar a métrica, avaliando-os em importância. Em questão de ferramentas, o trabnálho irá utilizar testes de diferentes algoritmos de regressão, sobreamostragem, e o uso da biblioteca SHAP. O processo terá apoio de especialistas e gerência da área. Em resumo, é possível dizer que os objetivos desse artigo são:

- Aplicar AM dentro de GRCS sobre atrasos de entregas, de forma que a empresa possa reagir antes da disrupção.
- Extrair conhecimento que possa ser utilizado dentro da GRCS, permitindo tomada de decisões focadas em dados sobre riscos relacionaos aos atrasos.

A estrutura do artigo será dividida em cinco partes. A seção 2 irá realizar uma breve revisão bibliográfica sobre aspectos principais da GRCS, como AM tem sido utilizada dentro da GRCS e uma breve explicação da biblioteca SHAP. A seção 3 irá explicar o planejamento da aplicação de AM, englobando os testes de algoritimos e o desenvolvimento da database. A quarta seção (4) irá documentar os resultados das ações planejadas na seção anterior, também como gráficos do SHAP e suas interpretações iniciais. A quinta seção (5) irá discutir esses resultados, incluindo como a empresa reagiu à apresenteção das etapas anteriores. Por fim, o artigo irá terminar com a conclusão, dificuldades e considerações para estudos futuros.

2. Revisão Bibiográfica

2.1. Gestão de Risco de Supply Chain (GRCS)

O objetivo da GRCS é controlar os riscos de interrupções. Ela deve ser capaz de analisar interrupções passadas para adiquirir conhecimento para próximas tomadas de decisões [7]. Uma das visões mais comuns de seu funcionamento pode ser visto na figura 1.

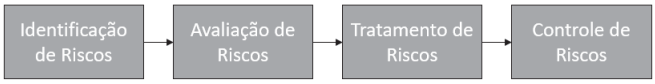

Figura 1: Sub-processos do Processo de GRCS, divididos em identificação, avaliação, tratamento e monitoramento de riscos relacionados a interrupções de entregas, adaptado de Fan e Stevenson [9].

GRCS só será efetiva se os seus riscos forem identificados adequadamente [10]. O foco da primeira etapa da GRCS é identificar o máximo de riscos possíveis que possam gerar vunerabilidades para a cadeia de suprimentos [11]. Fan e Stevenson [9] afirmam que os ricsos podem ser categorizados entre internos e externos, ou seja, de dentro ou fora dos processos da empresa.

Segundo Fan e Stevenson [9] A avaliação de riscos tem o objetivo de esclarecer os riscos mais importantes para o GRCS. Esse objetivo é atigindo a partir da análise de diferentes aspectos de cada risco, como probabilidade, e dedetectabilidade, identificando quais partes da cadeia de suprimento está mais vulnerável [6].

A etapa de tratamento do risco procura selecionar respostas adequadas aos riscos avaliados na etapa anterior. Dependendo dos fatores reconhecidos, as diferentes estratégias podem ser escolhidas: mitigação, aceitação, evitação, transferência e compartilhamento [12]. Com recursos finitos, empresas devem escolher as estratégias de forma eficiente [9], um exemplo pode ser visto na figura 2.

Segundo Yang et al. [5], o controle ou monitoramento de riscos tem a função de verificar e detectar eventos prejudiciais na cadeia de suprimento a partir de métri-

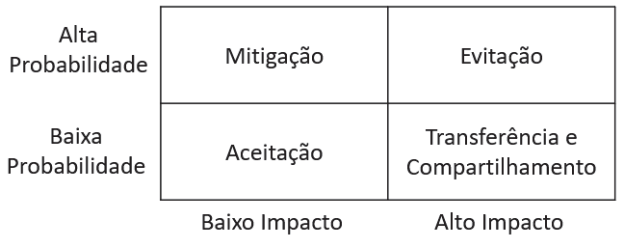

Figura 2: Guia para escolha de tratamento de risco a partir de probabilidade e impacto, adaptado de Fan e Stevenson [9].

cas de controle contínuo. Chu et al. [13] afirmam que a compreenção e monitoramento de riscos são os principais fatores para melhorar o desempenho da GRCS. Monitaração preventiva pode avisar gerentes de possíveis interrupções antes que aconteçam, permitindo tomadas de decisões eficazes [14].

2.2. Aprendizagem de Máquina (AM) em GRCS

O aumento do uso de AM dentro de GRCS teve como foco em aumentar a gestão proativa dos riscos de interrupçõs [1]. Segundo Yang et al. [5], a aplicação de AM em GRCS em todas as suas etapas, porém grande parte tende a focar em uma ou duas.

Steinberg et al. [15] utilizaram algoritimos de regressão para estudar dias de atraso para fornecedores de usinagem na Alemanhã. Em seu estudo, indicou que para conseguir tempos de resposta para gerência, é possível manter uma boa predição utilizando apenas dados do começo de processos de compra. Oliveira et al. [16] realizaram um estudo de escopo parecido, utilizando AM para prever tempo de processamento de pedidos de itens farmaceuticos, um ambiente onde as consequências de atrasos podem ser catastróficas.

Cavalcante et al. [8] utilizaram a combinação de simulação e aprendizagem de máquina, utilizando K-NN e Regressão Logistíca, com objetivo de verificar a métrica de OTD de seus fornecedores para escolher os que apresentaram menor chance de interrupções.

Além de aplicações, também ouve estudos empíricos e estudos bibliográficos como: Gupta et al. [17]; e Ganesh e Kalpana [1]. Ambos focaram em entender como as novas ferramentas de data estão afetando o ambiente de GRCS discutindo meios em que AM pode ajudar na visibilidade de riscos dentro da cadeia de suprimentos.

2.3. Biblioteca SHAP

Os autores Feng et al. [18] afirmam que apesar dos diversos usos de Aprendizagem de Máquina, os seus processamentos e resultados são vistos como saídas de "caixa pretra", isso é, a maneira em que conseguimos o resultado não pode ser totalmente entendido por humanos. Os mesmos autores em seu trabalho explicam como o pacote do *python* SHAP utiliza a teoria de jogos de Shapley [19], que procura indicar como cada jogador coletivamente alcança um resultado quando tentam atingir um objetivo colaborativamente. O pacote demonstra como diferentes características afetam predições realizadas pelo modelo de AM, com valores SHAP positivos e negativos indicando se o valor da características afetou posisitvamente ou negativamente o valor da predição.

3. Planejamento da Aplicação

3.1. Etapas da Aplicação de AM em GRCS

A aplicação de AM irá dar suporte para GRCS, utilizando o conhecimento levantado em conjunto com os *experts* do departamento, pois o conhecimento que detém é essencial para a gestão de risco pro-ativa [1].

O trabalho será feito dentro do departamento de suprimentos de uma industria de alta tecnologia, dentro da métrica de OTD, que é calculada a partir da taxa de itens entregues *On-Time* para o departamento de manufatura sobre o total de entreguas, dentro do escopo de 2023. A empresa em questão liberou o uso dessa base de dados com a condição de desconfigurar as características e não mencionar o seu nome.

A primera etapa da aplicação será feita a partir de uma discussão de *experts* de diferentes departamentos relacionados a entrega. Nela, aspectos considerados importantes para atraso / interrupção serão levantados. Esses fatores, quando possível, serão incluídos na base de dados.

Com a adição dessas características às entregas, a base de dados para processamento estará pronta. A AM será aplicada com a optimização de algoritimos de regressão, escolhendo o algoritimo com menor erro sobre a variável resposta utilizando a função *Gridsearchcv* da biblioteca de *python*, *scikit-learn*, especificadamente, a raiz do erro médio quadrado.

A variável resposta escolhida será o atraso na necessidade de entregas (ANE), calculada pela diferença em dias entre a data de entrada na manufatura (DE) e a

data de necessidade da entrega (DN). Ver a fórmula abaixo.

$$ANE \equiv DE - DN \tag{1}$$

A escolha de regressão sobre classificação foi feita a partir da visão de Steinberg et al. [15], com a visiblidade do número de dias é extremamente importante para as industrias de manufatura, pois permitem medir o impacto da interrupção e tratá-la de forma mais eficaz

Por fim, a biblioteca SHAP será utilizada para analisar como as características discutidas no primeiro passo afetaram as predições realizadas no modelo escolhido no segundo passo. Isso irá permitir ver não apenas os fatores mais importantes, mas como elas afetaram as predições.

Em relação ao GRCS, O primeiro passo está relacionado a identificação de riscos, com a possibilidade de identificar riscos a partir das características levantadas. O terceiro passo irá ajudar na availiação desses riscos, indicando seus impactos nas interrupções. A etapa de tratamento terá suporte indireto a partir dos resultados anteriores, já que tanto a identificação e avaliação são essenciais para a escolha do melhor tratamento [12] [9] [11].

Por fim, o algoritimo de regressão será utilizado para controlar os impactos de atrasos de itens críticos, analizando itens ainda em processo de produção, ajudando o GRCS a identificar possíveis interrupções antes que aconteçam.

3.2. Optimização dos Algoritimo de AM

Para garantir que tanto a previsão de atraso como o comportamento das características não gerem decisões exaltadas, é imperativo minizar o erro do algoritimo escolhido. Isso será feito a partir de testes de diversos algortimos de regressão, esses sendo: *Gradient Boosting (GB)*; Floresta Aleatória (FA); Árvore de Decisão (AD) ; *Adaptive Boosting (AB)*; Árvore de Decisão Extrema (ADE); Máquina de Vetores de Suporte (MVS) e Perceptron Multicamadas (MLP). Todos os algoritimos provém da biblioteca de *python*, *scikit-learn*.

Cada algoritimo será testado e optimizado utilizando a função *Gridsearchcv* da mesma biblioteca, que irá encontrar hiperparâmetros que geram os menores erros para cada algoritmo citado, o com menor erro sendo escolhido para a regressão.

4. Resultados

4.1. Base de Dados

A reunião com *experts* levantou um total inicial de 35 características, incluíndo a variável resultado. Depois de uma revisão das características, algumas foram indicadas como enviesadas, marcadas no apêndice B. Ambas poderiam ter seus valores mudados por causa de atrasos, ou seja, são dependentes da variável resultado. Como o foco do processo é analisar itens ainda em aberto, manter essas características causaria viés no modelo. Um novo atributo foi criado para subistituir uma das características, sendo igual ao primeiro valor definido no sistema.

Para desconfigurar a base de dados, cada característica foi classificada dentro dos seguintes grupos: Atributos (ATT), Processos (PROC), Falhas no Processo (FALHA), Tempo de Resolução (PROC FALHA), categorias (CAT) e Variável Resultado. Cada categoria teve o respectivo número de características: 19; 8; 4; 2; 3; e a própria variável resultado.

Processos são o tempo em dias para a realização de processos estabelecidos. Tempo de Resolução são são os dias para resoluções de falhas de qualidade, considerando da identificação até fechamento de documentação do erro. Falhas são contagens de casos de não conformidades dos processos. Todas foram separadas entre internas (Int) e externas (Ext), em relação se o responsável pela característica é a empresa ou seus fornecedores, podendo também ser de ambas as partes ou nenhuma (indicado como -"no apêndice A). Foram classificadas 15 características internas, oito externas, quatro que podem com responsabilidades em ambas as partes e oito que são independentes de inputs externos ou internos. Para a relação de grupos e responsabilidade, ver apêndice A.

Foi utilizado *OneHotEncoder* para transformar as características categórias (CAT1,CAT2) em características de valores binários. Com essa mudança, a base de dados ficou com o total de 50 características.

4.2. Optimização e Escolhas de Algoritimos

Com a coleta, revisão e limpeza da base de dados, prossegui-se com os testes de algorítimos. Durante testes iniciais na base de dados, foi identificado certas operações melhoravam o desempenho dos algoritimos, sendo esses: a retirada de *outliers* da variável resposta e de variáveis com alta correlações. No apêndice A está indicado quais características foram removidas.

Modelo	REMQ	EMA	R²
GB	32.03	20.84	85.06%
MPL	40.26	27.35	76.38%
AB	41.87	32.98	74.47%
FA	45.95	33.17	69.24%
MSV	49.59	33.94	64.24%
AD	52.19	36.91	60.32%
ADE	58.51	43.42	50.14%

Tabela 1: Resultados dos Algoritimos por Menor REMQ

Os resultados dos melhores modelos pode ser visto na tabela 1, com raiz do erro médio quadrático (REMQ), erro médio absoluto (EMA), e coeficiente de determinação (R^2). Os Hiperparâmetros utilizados para cada modelo podem ser vistos no apêndice B. Os resultados foram calculados a partir de *Kfold* repetido de 5 grupos e 5 repetições.

A partir dos resultados da tabela 1, o algoritimo escolhido foi *Gradient Boosting*, apresentando uma diminuição de erro considerável em relação aos demais. O valor, porém, não estava a par com outros estudos [15]. Em uma tentativa de melhorar a predição, realizou-se um estudo sobre a distribuição dos erros. Pelo gráfico 3 de distribuição de erro foi possível identificar que os maiores erros aconteciam quando ANE era maior que 100.

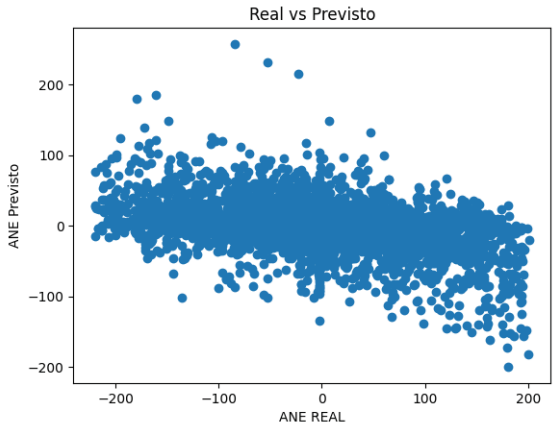

Figura 3: Distribuição de Erros

Essa análise foi a base para a proposta do uso de SMOTE, categorizando a base de dados a partir das seguintes categorias: ANE menor que -100; ANE entre 100 e o primeiro Quartil (-48); ANE entre o primeiro e terceiro quartil (43); ANE entre o terceiro quartil e 100; e ANE maior que 100. Ao verificar como o erro se comportava nessas categorias pela figura 4, foi possível identificar o grupo de ANE maior que 100 como o maior detrator de erros, e se decidiu realizar as diferentes sobreamostragem para diminuir o erro em suas predições:

- O uso de SMOTE com estratégia de minoria para o grupo de ANE>100.
- O uso de SMOTE sem estratégia de minoria.
- O uso da biblioteca smogn.

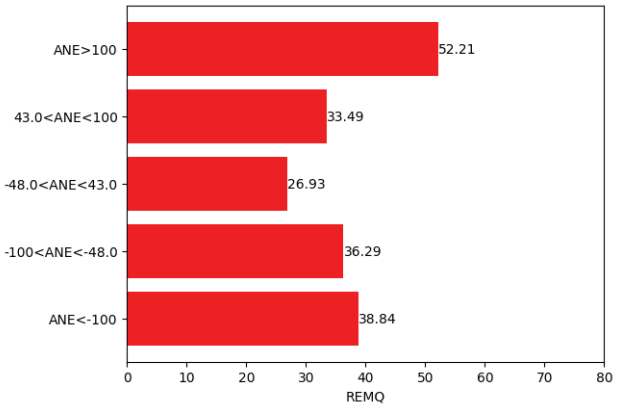

Figura 4: REMQ por Categoria

Infelizmente, nenhuma das sobreamostragens trouxeram melhoria nas predições dos itens acima de 100 dias de atraso, causando apenas maior erro na previsão. Logo, utilizamos o modelo originalmente escolhido.

4.3. Gráficos SHAP

A partir do algoritimo selecionado, inciou-se a análise de comportamento de características pela biblioteca SHAP. Para entender a importância dos algorítimos e seus comportamentos, dois gráficos da biblioteca foram escolhidos: o de barra e o de *beeswarm*.

Lundeber [20] explica que o gráfico de barra pode ser utilizado como indicador de importância das características, utilizando a média absoluta dos valores SHAP calculados em todos os exemplos análisados. Na figura 5 temos o resultado de quais características tiveram mais impacto na análise do modelo.

O gráfico mostra as 20 caracteristicas com maior impacto, com as quatro primeiras características apresentando uma importância consideravelmente maior que as restantes, com suas médias absolutas dos valores SHAP acima de 10.

Quanto ao gráfico de *beeswarm*, Lundeber [20] define que o objetivo do gráfico é demonstrar e documentar como os valores das características contribuíram para as previsões do modelo utilizado. Cada característica é colocada em uma linha, na qual cada previsão

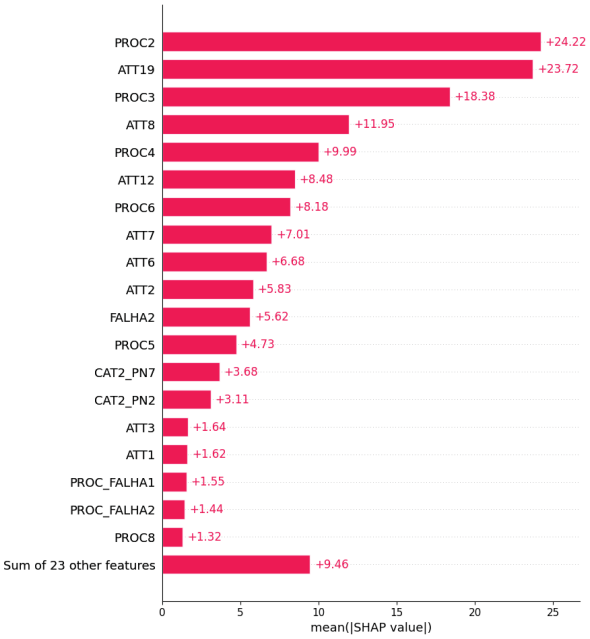

Figura 5: Gráfico SHAP de Barra

é representada por um ponto, as quais se acomulam de forma vertical. O valor SHAP dessas instancias é colocado de forma horizontal, enquanto o valor da característica é representado pela cor, de azul a vermelho de forma gradiente entre os menores e maiores valores respectivamente.

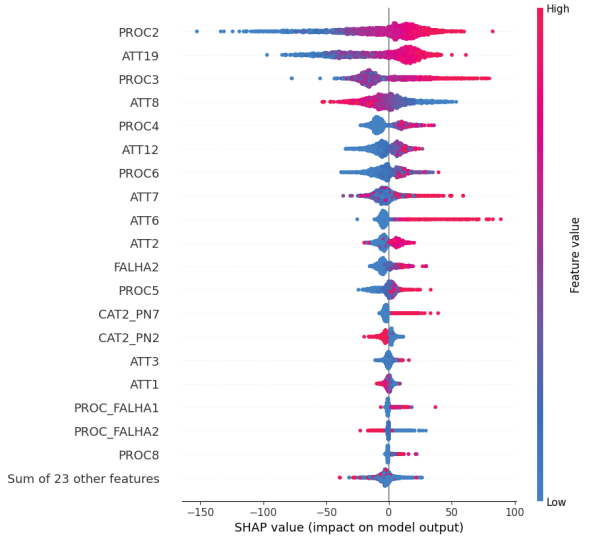

Figura 6: Gráfico SHAP de *beeswarm*

O gráfico 6 permite entender como as caracteristicas afetaram as predições do modelo escolhido. A ordem vertical é relacionada à importância das características. As três primeiras são positivamente relacionadas com a predição do ANE, aumentando a predição do atraso quando seu valores crescem. O contrário pode ser observado na quarta característica. Na sub-etapa de impactos da análise na empresa 5.1, iremos ver como os *experts* que definiram as características da primeira etapa interpretaram esses resultados.

5. Discussão

A partir dos resultados apresentados, é possível dizer que o primeiro objetivo foi alcançado. O algoritmo conseguindo ter acurácia aceitável em suas predições a partir de informações de pré-produção.

O algoritimo será aplicado em em processos que estão começando ou para começar a sua produção no fornecedor, com o foco de identificar atrasos e adiantamentos discrepantes. Isso irá permitir a gerência e especialistas do departamento de compras a tomar ações para mitigar ou evitar completamente interrupções de entregas para a manufatura da empresa.

O uso de SMOTE, iniciado depois dos primeitos testes não gerou benefício o estudo, pois não aumentou a qualidade do modelo, nem mesmo aos itens de alto atraso.

A identificação da base de dados, em conjunto com os gráficos da biblioteca SHAP gerou várias informações que podem ser analizadas como origens de riscos de interrupções, porém para garantir que elas podem ser utilizadas como fontes de tomadas de decisões, uma apresentação dos gráficos e resultados dos algoritmos foi realizada com o mesmo grupo que participou da primeira reunião desse artigo na sub-etapa 4.1. O resultado pode ser visto na sub-etapa 5.1.

É importante adicionar que três das quatro das características mais importantes nas predições são todas de responsabilidade interna, com a outras sendo de responsabilidade compartilhada. Para essa predição, os atrasos e antecipações acontecem principalmente por escolhas de planejamento e gestão, ao invés de desempenho de fornecedores.

5.1. Reações da Empresa

Com os resultados prontos e revisados, uma reunião foi marcada para apresentar os resultados discutidos nesse artigo. Ao apresentá-los para os *experts* do departamento da cadeia de suprimentos, alguns pontos foram levantados:

1. A alta importância de características de responsabilidade interna condiz com a experência dos *experts*.

2. Existe grande valor para conseguir identificar antecipações, a empresa irá ter um novo foco em diminuir o uso de estoque evitando grandes antecipações.
3. Dos quatro primeiros, três são problemas conhecidos com controles existentes e ações para a mitigações de seus riscos, gerando confiança na ferramenta de predição por parte dos *experts*.
4. O quarto item (ATT8) foi um ponto de alta discussão, pois, apesar de colaboradores com grande tempo de casa já suspeitarem que poderia estar causando impacto, não havia análise de dados concreta para suportar ações de tratamento.
5. Novas características, como ordem de entrega de itens e cliente do projeto foram levantadas como possívelmente substanciais para melhorar a predição, e serão incluídas em modelos futuros.

No final da reunião, o ponto principal de discussão foi o item 4, pois os resultados dos gráficos SHAP, confirmando com dados uma suposição, permitiu o começo de revisão desse atributo. O ATT8 se trata de uma característica definida na formulação dos projetos, por um departamento fora da cadeia de suprimentos, dificultando o seu questionamento. Alguns colaboradores já haviam levantado que esse atributo estava sendo calculado erroneamente, causando atraso, porém não detinham uma análise em dados para conseguir questionar o outro departamento. No final da reunião chegou-se à um consenso que se esse atributo estivesse sendo calculado corretamente, o seu impacto não deveria ser aparente.

Ter a informação com base de dados dos gráficos SHAP aumentou a confiabilidade do modelo, permitindo o departamento de compras ter confiança para questionar a formulação da característica. Essa reunião gerou ações de revisões desses valores para itens futuros, mitigando a chance de afetar atrasos.

6. Conclusão

Atrasos e interrupções são uma grande preocupação para empresas dentro do escopo manufatureiro. O campo de gestão de riscos de cadeias de suprimentos se desenvolveu para conseguir controlar e tratar esses riscos. Infelizmente nos últimos anos o controle de dados e informações se tornou complexo, dificultando o processo da GRCS. Um dos meios levantados para aliviar tal problema foi a aprendizagem de máquina, com diversos estudos realizados em suas diferentes etapas.

Com o uso do *Gridsearch* encontramos o melhor algoritmo de regressão para o caso estudado, o *Gradient Boosting*. Focando em melhorar a acurácia para os itens de maior atraso, tentamos utilizar sobreamostragem sobre esse modelo, porém sem melhora nas previsões. Para avaliar os riscos relacionados a entregas, os gráficos SHAP foram apresentados para *experts* dos departamentos com responsabilidades nas entrega de itens.

Esse trabalho teve como seu primeiro objetivo conseguir prever atrasos de entregas para a necessidade da manufatura de uma empresa de alta tecnologia, de forma que quando aplicado para novos itens, seria em uma etapa no começo ou antes da produção no fornecedor, garantindo tempo de resposta para o departamento tratar ou diminuir o impacto do atraso.

O segundo objetivo foi de trazer informação para tomada de decisão baseado em dados, inicialmente uma barreira quando utilizando algoritimos de aprendizagem de máquina, já que muitos não explicam como calculam suas previsões. Para remediar esse obstáculo, o uso da biblioteca SHAP foi realizado. Seus gráficos permitiram uma visão mais clara e baseada em dados, permitindo uma argumentação de alta confiabilidade para um tratamento de risco de um processo fora do departamento.

A empresa apresentou interesse em manter o algoritimo para predições no futuro, com a condição de atualizá-lo trimestralmente para garantir que ações de tratamento de riscos tiveram efeito e verificar se o ambiente para predições mudou.

Uma das dificuldades do artigo foi a mudança de alta gerência e medidas durante o a produção do artigo, dificultando a reunião com os *experts* do departamento. Esse algoritmo não está considerando informações fora do processo de cadeia de suprimentos, e seria cego a grandes mudanças de ambiente econômico, como COVID e Guerras, fatores que já influenciaram a empresa no passado. Isso torna o modelo vunerável a grandes erros em suas predições caso tais eventos ocorram.

Agradecimentos

Agradecimentos ao meu orientador, Prof. Luiz Eduardo Soares de Oliveira, pelo apoio durante o desenvolvimento desse artigo, e suas explicações sucintas e produtivas. Gostaria de agradecer ao curso de ciência

de dados e *Big Data* pela acessibilidade aos conteúdos mesmo para profissionais de áreas separadas a programação. Por fim gostaria de agradecer a minha família pelo apoio dado durante a produção desse artigo.

Referências

[1] A. Deiva Ganesh and P. Kalpana. Future of artificial intelligence and its influence on supply chain risk management – a systematic review. *Computers Industrial Engineering*, 169:108206, 2022.

[2] Jörn-Henrik Thun and Daniel Hoenig. An empirical analysis of supply chain risk management in the german automotive industry. *International Journal of Production Economics*, 131(1):242–249, 2011. Innsbruck 2008.

[3] Andreas Wieland and Christian F. Durach. Two perspectives on supply chain resilience. *Journal of Business Logistics*, 42(3):315–322, 2021.

[4] Aleksi Harju, Mika Immonen, and Katrina Lintukangas. The impact of procurement digitalization on supply chain resilience: empirical evidence from finland. *Supply Chain Management: An International Journal*, 28(7):62–76, 2023.

[5] Mei Yang, Ming K. Lim, Yingchi Qu, Du Ni, and Zhi Xiao. Supply chain risk management with machine learning technology: A literature review and future research directions. *Computers Industrial Engineering*, 175:108859, 2023.

[6] Merve Er Kara, Seniye Ümit Oktay Fırat, and Abhijeet Ghadge. A data mining-based framework for supply chain risk management. *Computers Industrial Engineering*, 139:105570, 2020.

[7] Meike Schroeder and Sebastian Lodemann. A systematic investigation of the integration of machine learning into supply chain risk management. *Logistics*, 5(3), 2021.

[8] Ian M. Cavalcante, Enzo M. Frazzon, Fernando A. Forcellini, and Dmitry Ivanov. A supervised machine learning approach to data-driven simulation of resilient supplier selection in digital manufacturing. *International Journal of Information Management*, 49:86–97, 2019.

[9] Yiyi Fan and Mark Stevenson. A review of supply chain risk management: definition, theory, and research agenda. *International Journal of Physical Distribution Logistics Management*, 48(3):205–230, 2018.

[10] Muhammad Saeed Shahbaz, Mudaser Javaid, Abdul Ghafoor Kazi, Khawar Hussain, Bestoon Othman, and Raja Zuraidah RM Rasi. Identification, assessment and mitigation of environment side risks for malaysian manufacturing. *Engineering, Technology & Applied Science Research*, 9(1), 2019.

[11] Daniel Kern, Roger Moser, Evi Hartmann, and Marco Moder. Supply risk management: model development and empirical analysis. *International Journal of Physical Distribution & Logistics Management*, 42(1):60–82, 2012.

[12] António A.C. Vieira, José Rui Figueira, and Rui Fragoso. A multi-objective simulation-based decision support tool for wine supply chain design and risk management under sustainability goals. *Expert Systems with Applications*, 232:120757, 2023.

[13] Chih-Yuan Chu, Kijung Park, and Gül E. Kremer. A global supply chain risk management framework: An application of text-mining to identify region-specific supply chain risks. *Advanced Engineering Informatics*, 45:101053, 2020.

[14] Muhammad Adeel Munir, Amjad Hussain, Muhammad Farooq, Ateekh Ur Rehman, and Tariq Masood. Building resilient supply chains: Empirical evidence on the contributions of ambidexterity, risk management, and analytics capability. *Technological Forecasting and Social Change*, 200:123146, 2024.

[15] Fabian Steinberg, Peter Burggräf, Johannes Wagner, Benjamin Heinbach, Till Saßmannshausen, and Alexandra Brintrup. A novel machine learning model for predicting late supplier deliveries of low-volume-high-variety products with application in a german machinery industry. *Supply Chain Analytics*, 1:100003, 2023.

[16] Maiza Biazon de Oliveira, Giorgio Zucchi, Marco Lippi, Douglas Farias Cordeiro, Núbia Rosa da Silva, Manuel Iori, et al. Lead time forecasting with machine learning techniques for a pharmaceutical supply chain. In *ICEIS (1)*, pages 634–641, 2021.

[17] Shivam Gupta, Surajit Bag, Sachin Modgil, Ana Beatriz Lopes de Sousa Jabbour, and Ajay Kumar. Examining the influence of big data analytics and additive manufacturing on supply chain risk control and resilience: An empirical study. *Computers & Industrial Engineering*, 172:108629, 2022.

[18] De-Cheng Feng, Wen-Jie Wang, Sujith Mangalathu, and Ertugrul Taciroglu. Interpretable xgboost-shap machine-learning model for shear strength prediction of squat rc walls. *Journal of Structural Engineering*, 147(11):04021173, 2021.

[19] Lloyd S Shapley et al. A value for n-person games. 1953.

[20] Scott Lundberg. Welcome to the shap documentation. `https://shap.readthedocs.io/en/latest/index.html`, 2018. Accessed: 15/05/2024.

A. Apêndice da Base de dados

Na tabela 2 está a separação das características mapeadas, com tipo de dados e responsabilidade. O tipo de dado pode ser Inteiro (I), Real (R), Binário (B) ou categórico (C), enquanto a responsabilidade pode ser interna (Int), Externa (Ext), compartilhada (Int/Ext) e independente (-).

Tabela 2: Mapeamentos das Características

Numeração Caract.	Tipo de Dado	Responsabilidade
Variável Resultado	I	-
ATT1	I	Int
ATT2	I	-
ATT3	R	-
ATT6	I	Int
ATT7	I	-
ATT8	I	Int
ATT9 (Retirada por Viés)	I	Int
ATT10	B	Int
ATT11	I	Ext
ATT12	I	Int
ATT13	B	Int
ATT14 (Retirada por Viés)	I	Int
ATT15	I	Ext
ATT16	I	Ext
ATT17	I	-
ATT18	I	-
ATT19 (Subistituiu ATT9)	I	Int
CAT1	C	-
CAT2	C	-
CAT3	B	Int
FALHA1	I	Ext
FALHA2	I	Int
FALHA3	I	Ext
FALHA4 (Retirada por Correlação)	I	Int/Ext
PROC1 (Retirada por Correlação)	I	Int
PROC2	I	Int/Ext
PROC3	I	Int
PROC4	I	Ext
PROC5	I	Ext
PROC6	I	Ext
PROC7	I	Int
PROC8	I	Int/Ext
PROCFALHA1	I	Int
PROCFALHA2	I	Int/Ext

B. Apêndice da Tabela de Hiperparâmetros

A tabela abaixo está indicando quais foram os parâmetros utilizados quando comparando os desempenhos de cada algoritimo, escolhidos a partir de *Gridsearch*. Hiperparâmetros não mencionados são iguais ao valores padrões da função do *scikit-learn*.

Tabela 3: Mapeamentos das Características

Começo da Tabela		
Algoritimo	Hiperparâmetro	Valor
AB	estimator	Decision Tree
	learning_rate	0.2
	loss	linear
	n_estimator	500
AB_ESTIMATOR	ccp_alpha	500
	max_depth	10
	max_features	0.2
	min_samples_leaf	7
	min_samples_split	15
	min_impurity_decrease	1
EDT	bootstrap	True
	ccp_alpha	0.1
	max_depth	10
	max_features	0.3
	min_samples_leaf	5
	min_samples_split	10
	warm_start	True
DT	bootstrap	True
	ccp_alpha	0.1
	max_depth	10
	max_features	0.3
	min_samples_leaf	5
	min_samples_split	10
	warm_start	True
MPL	activation	tanh
	beta_1	0.5
	beta_2	0.1
	epsilon	1e-08
	hidden_layer_sizes	(500,)
	max_iter	2200
	warm_start	True
RF	bootstrap	True
	ccp_alpha	0.5
	criterion	friedman_mse
	max_depth	10
	max_features	0.3
	min_impurity_decrease	0.5
	min_samples_leaf	5
	min_samples_split	10

Continuação da Tabela		
Algoritimo	Hiperparâmetro	Valor
	n_estimators	2200
	warm_start	True
GB	alpha	0.5
	max_depth	10
	max_features	0.9
	min_impurity_decrease	0.1
	min_samples_leaf	50
	min_samples_split	100
	n_estimators	2200
	n_iter_no_change	500
	subsample	0.8
	warm_start	True
SVM	C	1000
	gamma	0.01
	kernel	rbf
	max_iter	10000
	epsilon	2
Final da Tabela		