

Responsáveis: Rogério Nakamura; Márcio Menegatti

Empresa: SEG Automotive Components Brazil Ltda.

2024 Innovation Week CEMEAI:

Planejamento Logístico e Nivelamento de Produção Inteligente com redução de Custo de Capital e Aumento de Giro de Estoque

Palavras-chaves: Efeito Chicote, Bullwhip Effect, Production Planning, Nivelamento, Heijunka, Machine Learning, Time-Series; Supervised Learning.

Contexto

A SEG Automotive atua para minimizar o efeito chicote (*bullwhip effect*, Vide Figura 1) no planejamento de produção e de materiais com sistemáticas e metodologias tradicionais e manuais (e.g., Quadro Físico de Nivelamento – *Heijunka Box*, planilhas eletrônicas, ERP¹, Sistema de EDI², outros), atenuando os ruídos (oscilações) de demanda dos clientes, efeitos de mercado externo (e.g., COVID, conflitos, greves, instabilidade econômica, etc.), que afetam a performance da linha de produção e consequentemente sua cadeia de fornecimento. Como resultado operacional é dar estabilidade a linha de produção, evitando perdas na sua performance, disponibilidade e produtividade (OEE³), assim como aumentar o giro de estoque; ou seja, no campo financeiro, é otimizar o custo variável, assim como reduzir o custo de capital (e.g., redução de estoque de segurança e estoque em trânsito).

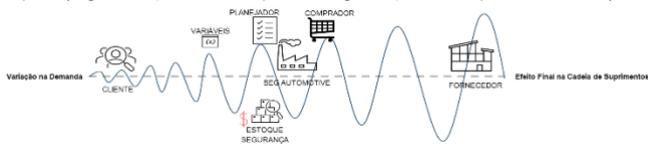


Figura 1 - Efeito Chicote (Bullwhip Effect)

Normalmente, a(s) montadora(s) envia(m) uma previsão de demanda (necessidade de produtos acabados da SEG a serem entregues à montadora) com uma visão de 12 meses de antecedência via sistema eletrônico de pedido (EDI). A medida que se passam os meses, esta demanda oscila, reduzindo ou aumentando ao longo do tempo, até chegar na data de entrega / coleta do produto.

Para efeito de planejamento de materiais, o que inclui fatores como tempo de importação, desembaraço aduaneiro e demais, o setor de Planejamento de Produção precisa realizar um corte / congelamento (o que chamamos de *Frozen Zone*) para trazer materiais e componentes dos fornecedores em tempo hábil. Este tempo hábil é de 2 a 3 meses devido ao tempo em trânsito de importação. No momento deste corte, o planejador logístico faz o pedido aos fornecedores da quantidade com um fator de segurança, que chamamos de *Underplanning*, sobre a quantidade da demanda da montadora. Este fator de segurança tem uma variação de 15% a 20% de corte / ou aumento sobre a demanda da montadora no momento do corte, gerando estoques de segurança (ou falta de material).

A forma de conduzir a sistemática e metodologias descritas acima é ainda realizada de forma manual e repetitiva, consumindo cargas de trabalhos consideráveis, que concorrem com as atividades analíticas. A tomada de decisão de consumo e planejamento de materiais dependem exclusivamente das experiências tácitas dos especialistas, o que acarretam um fator de segurança sensível no planejamento de aquisição, importação de materiais e de estoques. E normalmente, o tempo de reação (corte) é um fator crucial para minimizar o impacto dos insumos e materiais em trânsito.

¹ ERP – Enterprise Resource Planning

² EDI – Electronic Data Interchange

³ OEE – Overall Equipment Effectiveness

Desafio

A partir de um modelo testado em escala reduzida, MVP⁴, em Python, refiná-lo para sair de uma maturidade TRL⁵ 3/4 para uma maturidade TRL 6 na seguinte solução:

“sistema inteligente, que forneça uma previsão do planejamento logístico de produtos acabados (preditora), otimizando a margem de segurança de estoque acabado, por meio dos parâmetros internos (features) como estoque de produto acabado, vendas realizadas e demanda do cliente eletrônico temporal (janelas de demanda a 1, 2 e 3 meses); e também considerando os parâmetros externos como Vendas de Veículos, Estoques nas Montadoras / Concessionárias, Licenciamento de veículos, Produção de Veículos, Taxa de desemprego e Empregos no setor automotivo, os quais são fornecidos em organizações / associações como ANFAVEA, Bancos e outros”.

Histórico

Este projeto foi apresentado em Maio de 2023 dentro dos [20 projetos finalistas no treinamento](#) em Inteligência Artificial para Indústria ministrada pela I2A2 com patrocínio da ABDI.

Objetivo

Reduzir a média de incerteza de 12% para 5% (estoque de segurança) a partir da escolha do fator de segurança no momento do corte (*frozen zone*). Para a peça analisada, a solução reduziria uma quantia aproximada de R\$ 160.000,00 por mês, o que daria anualizado uma redução de R\$ 1.920.000,00 no ano de redução de estoque em trânsito / na Planta. Viabilizar a solução para condição de TRL6 com definições pré-estabelecidas (premissas) para conduzir a TRL9.

Resultado do MVP

Atingindo a redução de R\$ 250.000,00 por ano para a peça e para um cliente (montadora)

Modelamento do MVP

Para definir o sistema e suas fronteiras (features, preditoras e dependentes), modelamos o processo desde suas entradas e interações externas e internas como mostra na Figura 2.

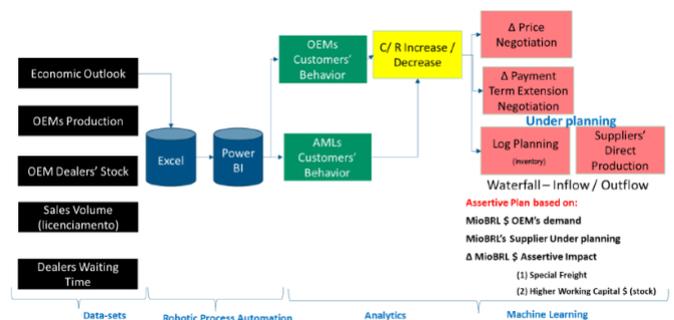


Figura 2- Modelo da Análise

Análise Exploratória de Dados

Seguindo o modelo de referência em desenvolvimento de mineração de dados CRISP-RM⁶, fizemos os ciclos iterativos de exploração, limpeza, preparação e definição das premissas (amostras e duração) como mostra na Figura 3.

⁴ MVP – Minimum Viable Product

⁵ TRL – Technology Readiness Level

⁶ CRISP- RM -

Cross Industry Standard Process for Data Mining Reference Model



Figura 3 - Modelagem

Em seguida, rodamos vários modelos (algoritmos) de séries temporais, conseguindo rodar com base somente em 1 feature dependente, chegando a um resultado positivo, mas não suficiente (Figura 3).

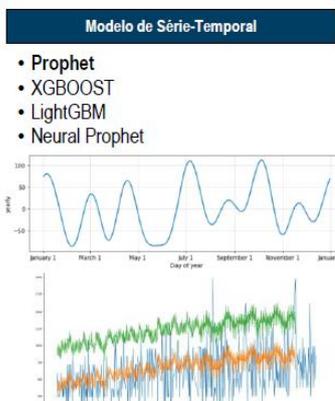


Figura 3 - Algoritmos avaliados

Análise Crítica

Ainda faltam etapas de inclusão de outras variáveis (Figura 4), melhorando a estratégia de metas dados / regressoras para avaliar oportunidades em reduzir ainda mais a margem de segurança e aumentar a assertividade da previsibilidade.

