



Otimização do planejamento da Cadeia de Suprimentos com Ciência de Dados e Inteligência Artificial: Um caso real



por Thiago Gatti
10 min leitura.

Motivação

Depois de anos de consultoria em Supply Chain e cargos de gestão em multinacionais no Brasil e na Alemanha, implementando softwares líderes de mercado e criando soluções em Excel para Finanças e S&OP, decidi integrar o meu conhecimento e experiência em um único aplicativo Python.

Planejamento Integrado de Negócios (IBP) é o foco do app, pois sincroniza algoritmos de Finanças e Supply Chain em um único conjunto de números. Dessa forma o planejamento fica mais rápido e fácil, que é o objetivo da Orkideon, ao invés de apenas construir um “software”.

Com este business case, espero expor oportunidades em Supply Chain, Vendas e Finanças a partir de dados reais, com digitalização e estratégia.

Espero que você goste da leitura e considere a Orkideon para fazer um projeto na sua empresa.

Cenário do Business Case

A empresa em questão foi um grande player da indústria química no Brasil em 2011, com três fábricas, cerca de 200 funcionários, mais de 6.000 itens e cerca de 1.500 clientes de nicho B2B, que foram os considerados neste estudo.

O baixo nível de serviço foi o principal problema, com reclamações de clientes devido a itens não produzidos, seguido por movimentação lenta de estoque e altos custos de transferência. Basicamente, aquela equipe de planejamento estava tendo dificuldade em escolher o que produzir e quando.

Fui contratado como Gerente PJ para ajudar a resolver o problema. Minha abordagem foi usar decisões baseadas em dados para avaliar pragmaticamente os obstáculos. Juntos, projetamos e implementamos bancos de dados e APO's em Excel.

A utilização desses APO's pela equipe de Planejamento e Controle de Produção, sob minha responsabilidade, aumentou a previsão de demanda de 30% para cerca de 75%, melhorando a qualidade do Master-Schedule, o que melhorou o throughput, que é excelente.

As melhores práticas de Master Production Scheduling (MPS) e algoritmos de previsão de demanda foram implementadas e, combinadas, geraram um efeito multiplicador, que aumentou o nível de serviço em cerca de 50% e cessou as reclamações dos clientes.

Apesar do sucesso, uma questão permanece: o aprendizado de máquina poderia ter tido um desempenho melhor?

Objetivos do Business Case

1. Demonstrar a aplicação sendo desenvolvida em Python usando dados reais.
2. Demonstrar alguns dos APO's em Excel mencionados.
3. Demonstrar o uso de freeware de mineração de dados.

Esses sistemas são usados em conjunto para responder a questões comuns do Planejamento da Cadeia de Suprimentos, como:

- a. Qual design de banco de dados?
- b. Qual período de revisão do planejamento?
- c. Qual a precisão da previsão de demanda?
- d. Quantos dados são necessários?
- e. Quais recursos considerar?
- f. Qual plano mestre de produção?
- g. Qual redução de estoque / liberação de capital de giro?
- h. Qual a capacidade de armazém?
- i. Qual nível de serviço?
- j. Qual meta de inventário?
- k. Qual capacidade de produção?
- l. Qual ROI?
- m. Qual preço?
- n. Quais insights surpreendentes?

Machine Learning




Figura 1: Python com Streamlit: o módulo de aprendizado de máquina.



Qual design de banco de dados?




Figura 2: Visão geral simplificada da estrutura interna do aplicativo.

Os dados originais são transformados até estarem prontos para a Machine Learning. Os KPI's estão presentes em todas as etapas. Quanto mais avançado o estágio, mais revelador é o KPI. Como será observado nas páginas seguintes, os KPI's disponíveis abrangem todas as camadas do Analytics, descritas pela Gartner como: Descritivo, Diagnóstico, Preditivo e Prescritivo.

Original Features	Augmented Features	Relevant Features
Year	Period	sc__COGS_Sum_PV
Month	Group	sc__Un Price_W_Mean_PV
Day	year	sc__Gross Revenue_Sum_PV
Region	month	
Quantity	day	
Gross Revenue	BU	
Net Revenue	Item	
COGS	Region	
Gross Profit	Un Price_Cut	
Reference Cost	Occurences	
Replacement Cost	Gross Revenue_Sum	
BU	COGS_Sum	
Client	Quantity_Sum	
Item	Salesman_Count	
Salesman	Un Price_W_Mean	
Un Price	Interest_W_Mean	
	COGS_Sum_PV	
	Gross Revenue_Sum_PV	
	Un Price_W_Mean_PV	
	Delta_Perc_Un Price_W_Mean_PV	
	Delta_Perc_Quantity_Sum	
	Un Price_W_Mean_PV_Arc_Elasticity_of_Quantity_Sum	
	Un Price_W_Mean_PV_x_Quantity_Sum	
	Delta_Un Price_W_Mean_PV_x_Quantity_Sum	
	Delta_Quantity_Sum	
	Marginal_Un Price_W_Mean_PV_x_Quantity_Sum	

Final (arguably) Data Model
Occurences
Item
Salesman_Count
Un Price_W_Mean_PV_Arc_Elasticity_of_Quantity_Sum
BU
Gross Revenue_Sum_PV
day
month
Region
Period
Un Price_W_Mean_PV
Quantity_Sum
COGS_Sum_PV
year
Group

Figura 3: Dados em diferentes fases do processo de preparação.

O processo de transformação (também conhecido como: pré-processamento, wrangling, etc.) é dinâmico, incluindo e excluindo colunas (recursos), alterando valores e número de linhas.

Os dados utilizados no estudo são reais e foram totalmente anonimizados para este business case.

Qual período de revisão do planejamento?

Mensal

Autocorrelation (ACF)




Figura 4: Python com Statsmodels e Plotly: Autocorrelação.

Os dados originais são consolidados por semana. A autocorrelação atinge seu pico em 4 e 10 semanas. Como 4 tem menos erros, o modelo de dados será reconsolidado mensalmente e o período de revisão do planejamento deverá seguir o mesmo princípio.

Qual a precisão da previsão de demanda?

95%

Quantos dados são necessários?

2 anos de movimento

Learning Rate (Estimator Accuracy)




Figura 5: Python com Scikit-Learn e Plotly: Taxa de aprendizagem.

95% é a nova precisão da previsão de demanda global em comparação com os 75% anteriores. Isso representa uma melhora de quase 30%. A alta precisão é alcançada após cerca de 300 amostras ou o equivalente a 2 anos de dados.

A métrica utilizada neste caso foi 1 - WMAPE (1 - Weighted Mean Average Percentage Error).

O modelo vencedor é um Decision Tree Regressor com codificação One-Hot e transformação Quantile.

Os aplicativos Python e Excel foram medidos em relação aos dados de teste, que são um subconjunto do banco de dados original.

Quais recursos considerar?

COGS ou CPV

Feature Importances / Predictive Power




Figura 6: Python com Scikit-Learn e Plotly: Estimator Feature Importances.


Quando a estimativa do CPV está presente, é possível obter maior precisão nas previsões.

A previsão de CPV é comumente exigida pelo departamento Financeiro e também pode contribuir para a qualidade das previsões da Cadeia de Abastecimento.

Oportunidade Futura

Prever o CPV antes de prever a demanda e/ou trabalhar com cenários econométricos.

Qual Plano Mestre de Produção? ... para o item 1



1 - Master Schedule (APICS/MIT Model)

Week	Inventory Before	Demand Forecast	Active Orders	Production /Supply	Inventory After	Backlog	Available To Promise	To Discount
1	5000	6700	0	20000	18300	0	18300	0
2	18300	9110	0	0	9190	0	9190	8475
3	9190	11525	0	20000	17665	0	17665	0
4	17665	13935	0	0	3730	0	3730	3655
5	3730	16345	0	20000	7385	0	7385	7385
6	7385	8075	0	20000	19310	0	19310	0
7	19310	10490	0	0	8820	0	8820	7100
8	8820	12900	0	20000	15920	0	15920	0
9	15920	15315	0	0	605	0		

2 - P&L [R\$]

Week	Revenue	COGS	Backlog Inventory	Warehousing	EBITDA	Service	ROI
1	13,552	7,088	0	19,361	5,121	1,343	100% 0.1
2	18,427	9,638	0	9,723	2,572	6,217	100% 0.6
3	23,312	12,193	0	18,689	4,943	6,176	100% 0.3
4	28,187	14,743	0	3,946	1,044	12,400	100% 3.1
5	33,062	17,293	0	7,813	2,067	13,702	100% 1.8
6	16,334	8,543	0	20,430	5,404	2,387	100% 0.1
7	21,219	11,098	0	9,331	2,468	7,652	100% 0.8
8	26,093	13,648	0	16,843	4,455	7,990	100% 0.5
9	30,978	16,203	0	640	169	14,606	100% 22.8
Sum:	211,164	110,448	0		28,242	72,474	
Average:				11,864			100%
Std Dev:	27%						
							ROI: 0.7

Figura 7: Excel: Simulação do Master-Schedule no APO.

Qual redução de estoque?

Qual liberação de capital de giro? ... para o item 1

50% Working Capital liberado

Foi adotado um modelo APICS/MIT Master-Schedule para receber a previsão do item 1 e calcular a necessidade. Em seguida, um P&L é calculado para cada linha e o ROI final é apresentado.

Parâmetros de Simulação

A capacidade do reator é de 20 toneladas, o item produzido é armazenado em tambores de 200 kg cada quando cheios, 4 tambores por pallet. O custo de armazenamento é de 25% do CPV. O custo do backlog é o dobro do CPV. Os dados sobre pedidos ativos não estão disponíveis, portanto, presume-se zero. O estoque inicial do item 1 é desconhecido, então são assumidos 5.000 kg.

A reconsolidação do modelo de dados para o período semanal aumenta a granularidade, que diminui a precisão. Porém, um modelo feito sob medida, específico para previsão semanal, conseguiu atingir 91% de precisão, quando uma estimativa de CPV está presente e 85% sem CPV. Alternativamente, a previsão mensal poderia ser dividida por 4,3 para uma aproximação da demanda semanal.

O estoque médio inicial de 11.864 kg foi para 6.211 kg (redução de quase 50%) adotando-se lotes de 12.000 kg.

Qual a capacidade do armazém? ... para o item 1

Bônus: Qual EOQ - Lote Econômico? ... para o item 1

O APO em Excel calcula algumas métricas comuns da cadeia de suprimentos, como EOQ e capacidade de armazém necessária, conforme segue.




Figura 8: Excel: Métricas da Cadeia de Suprimentos no APO.

Qual nível de serviço?
Qual meta de inventário?
Qual capacidade?
Qual ROI?




Figura 9: Excel: Módulo de Definição de Metas do APO.

Todas as metas do IBP de uma vez!

Continuando o exercício para o item 1, um reator com capacidade de 12 toneladas é capaz de fornecer 4,7 ROI em comparação com 0,7 ROI do atual reator de 20 toneladas. Isso acontece porque grandes lotes elevam o estoque.

O ótimo da simulação é melhor que o EOQ em termos de ROI porque leva em consideração as restrições “ocultas” daquela operação específica, que não estão incluídas no algoritmo do EOQ. Embora ambas as quantidades sejam próximas, o mesmo não acontece para o ROI, que é parcialmente explicado pelo fato do item 1 ser uma commodity.

A julgar apenas pelo item 1, a sugestão é substituir o reator atual por um menor.

Gestão de Metas Corporativas (OKR/MBO)




Fig. 10: Simplificação do Sistema de Metas Corporativas Matriciais correspondente ao IBP.

O alinhamento de metas do IBP foi derivado em metas corporativas matriciais e distribuído respeitando a estrutura da empresa.

Qual preço?

Pricing Fine Tuning for Maximum Profit at Different What-If COGS Scenarios

year	month	Quantity	BU	Item	Elasticity	Commissions and Taxes	Un COGS	Interest	Profit Margin	Un Price
2012	1	189,507	BU 1	Item 1	1	0.33	3.00	0.50	0.30	3.48
2012	1	196,621	BU 1	Item 1	1	0.33	3.00	0.50	0.25	3.42
2012	1	190,912	BU 1	Item 1	1	0.33	3.00	0.50	0.20	3.41
2012	1	189,507	BU 1	Item 1	1	0.33	3.00	0.60	0.30	3.48
2012	1	196,621	BU 1	Item 1	1	0.33	3.00	0.60	0.25	3.42
2012	1	190,912	BU 1	Item 1	1	0.33	3.00	0.60	0.20	3.41
2012	1	189,507	BU 1	Item 1	1	0.33	3.30	0.50	0.30	3.48
2012	1	196,621	BU 1	Item 1	1	0.33	3.30	0.50	0.25	3.42
2012	1	190,912	BU 1	Item 1	1	0.33	3.30	0.50	0.20	3.41
2012	1	189,507	BU 1	Item 1	1	0.33	3.30	0.60	0.30	3.48
2012	1	196,621	BU 1	Item 1	1	0.33	3.30	0.60	0.25	3.42
2012	1	190,912	BU 1	Item 1	1	0.33	3.30	0.60	0.20	3.41

Fig 11: Orange: sugestões de preços.

Existe uma sugestão de preço de lucro máximo diferente para cada cenário. E pode ser ajustada em tempo real.

A variação de preço afeta a demanda, que afeta o plano mestre, que afeta o estoque, que afeta o ROI.




Fig 12: Orange data mining freeware canvas.

Quais insights surpreendentes?

Itens Especiais




Figura 13: Python com Seaborn: histograma univariado.

Para o item 4, um aumento delta no preço representa um pequeno número de eventos de vendas, enquanto a mesma diminuição delta representa um grande número de eventos de vendas. Então, é preferível diminuir os preços para aumentar o número de eventos. Este é considerado um perfil cauteloso.

O perfil agressivo permite aumentar preços, indicando potencial de diferenciação ou espaço para designação de itens especiais.

Quais insights surpreendentes?

Vendas

Quantity_Sum: Relevant Correlations (spearman)




Figura 14: Python com Scipy: Correlações de Spearman.

Conditional Probabilities

		Salesman_Count	
Un Price_W_Mean_PV	Quantity_Sum	(1.0, 8.0]	(8.0, 15.0]
{"left": 0.07, "right": 2.1}	{"left": -77.2, "right": 148830}	0.535	0.095
{"left": 0.07, "right": 2.1}	{"left": 148830, "right": 297440}	0	0.477
{"left": 2.1, "right": 4}	{"left": -77.2, "right": 148830}	0.465	0.095
{"left": 2.1, "right": 4}	{"left": 148830, "right": 297440}	0	0.333

+43%

Figura 13: Python com Pandas: Probabilidades Condicionais.

O headcount de vendas associado ao volume pode indicar vendas concentradas em grandes clientes com altos volumes e/ou melhores comissões, visto que é mais fácil vender a preços mais baixos e é também mais conveniente fazê-lo em menos visitas.

No cenário de alta quantidade, há 43% mais representantes do que quando os preços são mais baixos.

Esta prática estaria minimizando a rentabilidade da empresa?

Quais insights surpreendentes?

Comissões

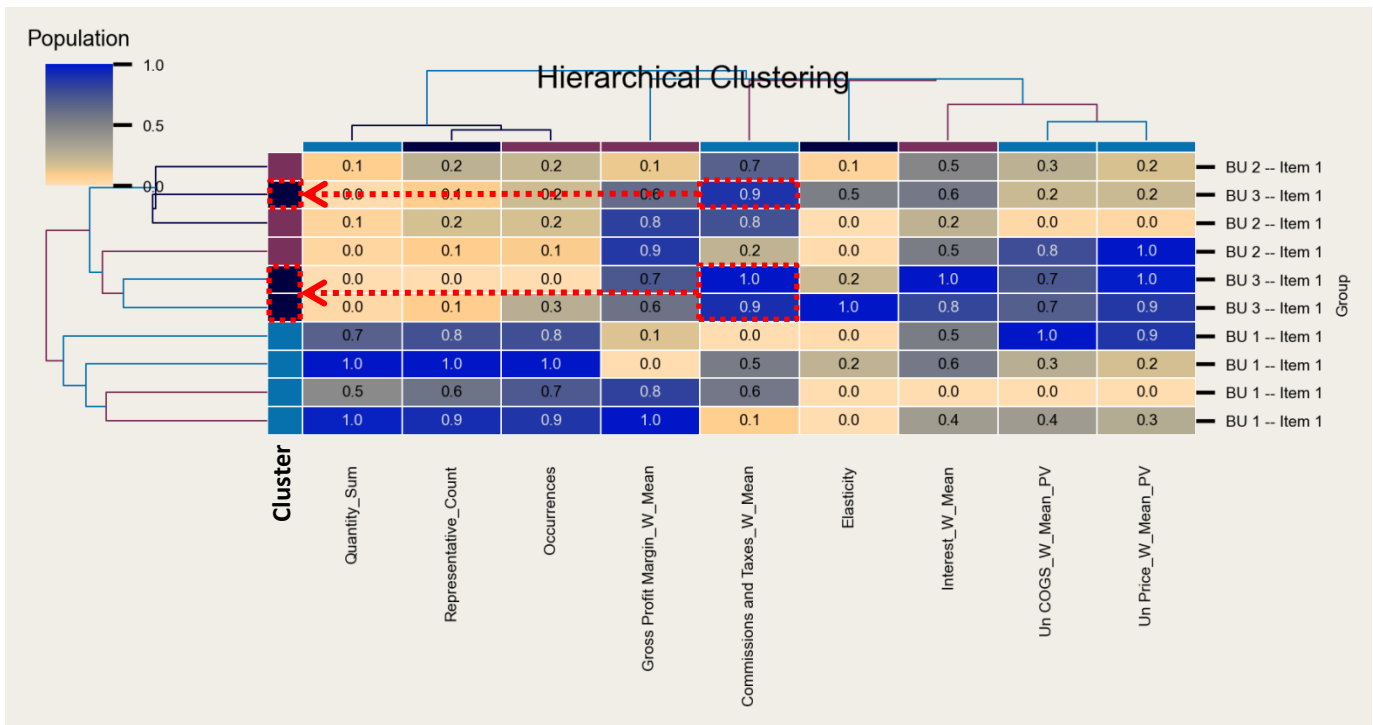


Figura 15: Python com Seaborn: Clustering Hierárquico.

Comissões e Impostos constituem um "padrão oculto", com cluster específico nas BU's 2 e 3.

Por outro lado, na BU 1, a contagem de representantes e o volume total desempenham um papel mais significativo.

Quais insights surpreendentes?

Canibalização, ou não, de itens

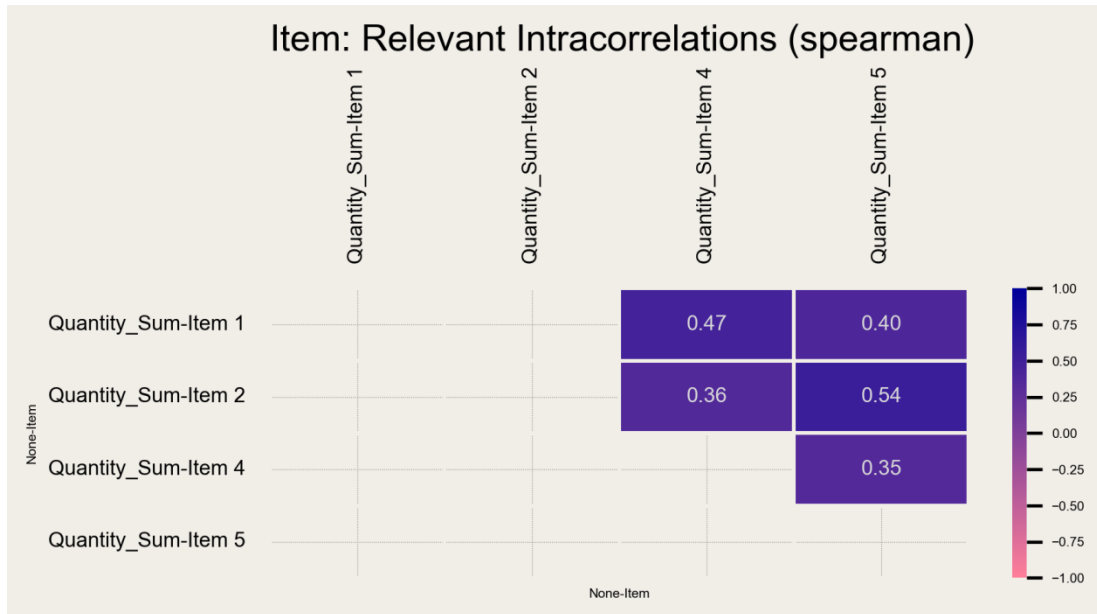


Figura 16: Python com Seaborn: Canibalização versus itens complementares.

Os itens 2 e 5 são complementares. As vendas de um ajudam a vender o outro. Caso esta relação fosse negativa um estaria canibalizando o outro.

Considerações Finais

Conforme mencionado anteriormente, o objetivo deste business case foi demonstrar a capacidade da Orkideon de responder a questões comuns de Supply Chain e de estabelecer metas gerenciais. Todas as questões propostas foram respondidas e, ao longo do caminho, insights surpreendentes apareceram. Finalmente, novas portas se abriram para a exploração de possibilidades futuras.

O aprendizado de máquina aplicado ao planejamento da cadeia de suprimentos é um campo verde porque o conhecimento ainda é pego emprestado de outras áreas.

Com experiência, conhecimento, metodologia e as ferramentas certas, a tomada de decisão é rápida e fácil. As empresas podem se tornar mais responsivas e é possível alternar entre operações e estratégia como nunca antes.

Este estudo levou apenas alguns minutos, mas o projeto que o alavancou já tem 2 anos. Sabe-se que a maioria dos executivos não têm predisposição para investir em projetos internos de longo prazo como esse mas, o resultado é evidente. A boa notícia é que agora as empresas podem atingir resultados similares através da Orkideon.

Espero que você tenha gostado da leitura tanto quanto gostei de prepará-la.

Entre em contato e saiba mais.

Cordialmente,

Thiago



Python app

<https://www.orkideon.com/app-1>