



CONFERÊNCIA **VALUATION** 20

BRASIL 2024

*Aplicação de IA na
estimativa de desempenho
futuro de
empreendimentos*

*Um case de projeção de demanda
em indústria de bens de consumo
“Fast Moving”*




No processo de elaboração de estimativas de valor de mercado de empresas, para fins de M&A ou de IPO, além de medir os ativos tangíveis, é fundamental obter previsões de lucratividade, receitas e market share, construindo vários cenários ao longo de horizontes de curto e médio prazos, principalmente. Para tanto, estimativas de demanda são pivotais, delas derivando as de vendas e receitas.

O exemplo que analisaremos aqui usa uma combinação de algoritmos para elaborar uma projeção de demanda para uma empresa industrial produtora de bens de consumo rápido (“Fast Moving”), tipicamente produtos de limpeza doméstica e de higiene pessoal.



Essa combinação de redes neurais regressivas (GRNNs), otimizadas por algoritmos genéticos (selecionando os melhores GRNNs de cada geração para criar novas) é usada na escolha das variáveis “exógenas” que serão adicionadas como fatores externos a algoritmos autorregressivos do tipo SARIMAX. Essa combinação de 3 classes de algoritmos permite-nos eliminar o efeito “caixa preta” típico de muitos modelos de IA e assim apresentarmos a “capacidade explicativa” das variáveis independentes utilizadas na estimativa.





Variáveis comumente utilizadas em previsão de demanda de produtos “Fast-Moving”



Indicadores Econômicos:

- **Renda Disponível:** Renda disponível média das famílias.
- **Taxa de Desemprego:** Taxas de desemprego locais ou nacionais.
- **Índice de Confiança do Consumidor:** Uma medida do sentimento do consumidor.

Dados Demográficos:

- **Densidade Populacional:** Número de pessoas por unidade de área.
- **Distribuição por Idade:** Percentual da população em diferentes faixas etárias.
- **Tamanho das Famílias:** Número médio de pessoas por família.

Tendências de Mercado e Indústria:

- **Preços da Concorrência:** Preços de produtos similares oferecidos por concorrentes.
- **Gastos com Marketing:** Quantia gasta em publicidade e promoções para detergentes de cozinha.
- **Lançamentos de Produtos:** Introdução de novos produtos na mesma categoria.
- **Lançamentos e vendas de produtos acionadores:** máquinas lava-louças

Fatores Ambientais:

- **Fatores Sazonais:** Diferentes estações podem afetar os padrões de uso de detergente.
- **Condições Climáticas:** Padrões climáticos podem influenciar o comportamento de compra e uso do produto.

Dados de Loja e Vendas:

- **Número de Lojas de Varejo:** Número de lojas que vendem o produto.
- **Espaço nas Prateleiras:** Quantidade de espaço nas prateleiras dedicado a detergentes de cozinha nas lojas.
- **Promoções e Descontos:** Frequência e tipo de promoções e descontos oferecidos.

Comportamento do Consumidor:

- **Tendências de Busca:** Volume de buscas online relacionadas a detergentes de cozinha.
- **Menções nas Redes Sociais:** Número de menções ou discussões sobre detergentes de cozinha nas plataformas de redes sociais.
- **Avaliações dos Clientes:** Análise de sentimento das avaliações dos clientes.

Fatores da Cadeia de Suprimentos:

- **Níveis de Estoque:** Níveis de estoque de detergentes de cozinha em armazéns e lojas.
- **Disrupções na Cadeia de Suprimentos:** Quaisquer disrupções na cadeia de suprimentos que possam afetar a disponibilidade do produto.

Eventos Externos:

- **Eventos Públicos:** Principais eventos públicos ou feriados que possam influenciar o comportamento de compra.
- **Políticas Econômicas:** Mudanças nas políticas econômicas que possam impactar os gastos do consumidor.
- **Eventos disruptivos:** ex.: enchentes


Variáveis usadas neste exemplo

- **Anomes:** Ano e mês de competência dos dados da variável dependente (PercVendaMax)
- **hotelrooms:** (quantidade de quartos de hotel reservados para uma temporada)
- **Realestate:** quantidade de lançamentos imobiliários
- **Washmach:** quantidade de lava-louças vendida
- **Events:** previsão de público em eventos (esportivos, musicais, corporativos, etc.). Eventos disruptivos (ex.: inundações)
- **Officeoccup:** população de escritórios ocupados
- **Restaurseats:** quantidade de assentos em restaurantes

PercVendaMáximo: Variável dependente a ser prevista pelo modelo



Análise de correlação entre as variáveis independentes e entre estas e a variável dependente (PercVendaMax)



Ajuste de sincronismo das séries históricas



PercVendaMax

hotelrooms

realestate

washmach

Events


Officeoccup

Restaurseats


Nossa solução realiza automaticamente os ajustes de “lag” para obter o sincronismo de causa e efeito. Para isso aplica coeficientes de correlação lineares (ex. Pearson) e não lineares (ex.: ξ de Chatterjee)

Conforme explicado anteriormente, usamos uma combinação de redes neurais regressivas (GRNNs) adicionando fatores externos (as variáveis acima exibidas em letras brancas) a serem adicionados a algoritmos autorregressivos do tipo SARIMAX, combinado assim o comportamento de variáveis externas à evolução histórica da própria variável que está sendo prevista (no caso, PercVendaMax)


Separação dos componentes de tendência e de sazonalidade




Análise de autocorrelação (ARIMA-like) de PercVendaMax



Importância relativa das variáveis independentes



Comparação do previsto com o observado em backtesting (insample)




Comparação do
previsto com o
observado em
backtesting
(out-of-sample)

Statistics resulting from predicting the data rows with the network

☒ Enhanced generalization	Advanced...
Number of processed rows:	20
Number of unprocessed rows:	0
R-squared	0,924934
Avg.error	0,058584
Correlation	0,985109
MSE	0,005299
RMSE	0,072791
% in range	0,0%
% same sign	100,0%


#	Actuals	Predicted
101	0,522438	0,475459
102	0,575032	0,519825
103	0,646885	0,571485
104	0,685955	0,637155
105	0,503816	0,452723
106	0,074336	0,078453
107	0,468831	0,340162
108	0,044636	0,174241
109	0,708098	0,610143
110	0,164434	0,211138
111	0,528828	0,505259
112	0,470433	0,486666
113	0,238331	0,25761
114	0,175941	0,182494
115	0,044887	0,055953
116	0,553285	0,492773
117	0,081069	0,174945
118	0,669936	0,592397
119	0,123475	0,145239
120	0,974279	0,81751



Training set: 6 inputs X 100 rows Rows for learning: 100, rows for applying: 20 Missing rows: 0,0%

Training time: 0:21"

Gráfico de dispersão





OBRIGADO(A)!

Carlos Antonio Campos Nogueira
carlos.nogueira@fractalsventures.com.br
+55 11 99225-4003

Site: <https://www.fractalsventures.com.br/>

Linkedin: <https://www.linkedin.com/in/carlos-antonio-campos-nogueira-228162/>