

Universidade Federal do Paraná
Setor de Ciências Exatas
Departamento de Estatística

Bruno Godoi Graebin

Previsão de Demanda Utilizando Séries Temporais

**Curitiba
2024**

Bruno Godoi Graebin

Previsão de Demanda Utilizando Séries Temporais

Trabalho de Conclusão de Curso apresentado à disciplina Laboratório B do Curso de Graduação em Estatística da Universidade Federal do Paraná, como exigência parcial para obtenção do grau de Bacharel em Estatística.

Orientador(a): Fernando Lucambio Pérez

Curitiba
2024

Aos professores desta universidade, que me inspiraram ao longo do caminho e contribuíram para o meu crescimento profissional e pessoal.

Agradecimentos

Agradeço à Universidade Federal do Paraná, em especial ao curso de Estatística, por proporcionar um ambiente de aprendizado desafiador e enriquecedor. Ao meu orientador, Fernando Lucambio Pérez, pela dedicação, paciência e pelas valiosas orientações que foram cruciais para a elaboração deste trabalho. E aos amigos e colegas de curso, pela parceria e pelos momentos compartilhados que tornaram esta caminhada mais leve e enriquecedora.

*Democracia é oportunizar a todos o mesmo ponto de partida.
Quanto ao ponto de chegada, depende de cada um.*

Fernando Sabino.

Resumo

Este trabalho aborda a previsão de demanda em um contexto de pós-venda, com foco na redução de falhas de abastecimento e melhoria na gestão de estoques. O objetivo principal é desenvolver um modelo preditivo capaz de antecipar a necessidade de reposição de peças, minimizando quebras na cadeia de abastecimento. Para isso, foi utilizada a metodologia VAR (Vetores Autorregressivos) em séries temporais, com dados históricos tratados e analisados em R. Os resultados apontam uma redução significativa nas falhas de abastecimento, com impacto positivo na eficiência operacional. Conclui-se que o uso de técnicas preditivas avançadas, aliado à integração de ferramentas de análise, contribui para uma cadeia de suprimentos mais robusta e proativa, mitigando riscos e otimizando recursos.

Palavras-chave: Palavra-chave 1. Palavra-chave 2.

Sumário

1	INTRODUÇÃO	7
2	MATERIAL E MÉTODOS	8
2.1	Material	8
2.2	Métodos	10
3	RESULTADOS E DISCUSSÃO	16
4	CONSIDERAÇÕES FINAIS	22
5	REFERÊNCIAS	23

1 Introdução

A previsão de demanda no pós-venda é essencial para garantir que as peças estejam disponíveis quando necessário, sem gerar excesso de estoque ou custos desnecessários. Isso ajuda a evitar perdas, reduzir rupturas e melhorar o atendimento ao cliente, tornando o setor mais eficiente e lucrativo.

Este trabalho busca responder: como prever a demanda para melhorar a disponibilidade de peças sem aumentar os custos? Para isso, será usado um modelo de previsão baseado em séries temporais, com foco na otimização dos estoques.

Objetivos:

Estudar os dados de vendas passadas. Aplicar o modelo VAR (Vetores Autorregressivos) para prever a demanda. Avaliar se as previsões ajudam a melhorar os estoques. Por que o Modelo VAR? O VAR analisa como diferentes fatores, como demandas anteriores e sazonalidade, influenciam a demanda ao longo do tempo. Ele cria previsões mais completas, ajudando a tomar decisões que afetam a disponibilidade e a otimização dos estoques.

Benefícios

Com previsões mais precisas, as empresas evitam faltas e excessos de peças, reduzem custos e atendem melhor seus clientes. Isso fortalece a operação, melhora a eficiência e aumenta a competitividade no mercado.

O presente trabalho está dividido em quatro capítulos: o primeiro aborda a fundamentação teórica; o segundo apresenta a base de dados utilizada e a metodologia aplicada; o terceiro expõe a análise dos resultados e discussão; e o quarto traz as conclusões e sugestões para futuras pesquisas.

2 Material e Métodos

2.1 Material

Para este trabalho, foi utilizada uma base de dados real, que contém peças de reposição e suas respectivas demandas mensais, com um histórico de 7.5 anos, o que é suficiente para a identificação de padrões de demanda, sazonalidades e para o ajuste de modelos estatísticos.

A quantidade total de peças de reposição cadastradas na base é de cerca de 5 mil. Para este estudo, por questões computacionais e de tempo de processamento, foram selecionadas aleatoriamente 60 peças dessa lista das 5 mil peças.

A definição das 60 peças foi feita da seguinte forma: dois parâmetros amplamente reconhecidos foram usados para a classificação das peças em grupos de demanda semelhantes: o CV (Coeficiente de Variação), que corresponde ao desvio padrão da demanda dividido pela demanda média, e o ADI (Intervalo Médio entre Demandas), que se calcula pela razão entre o número de períodos sem demanda e o número de períodos com demanda. Esses parâmetros podem ser usados com valores de corte específicos, $ADI = 1,32$ e $CV = 0,49$ permitindo uma classificação detalhada da demanda de peças de reposição em quatro categorias:

- Smooth: demanda frequente e baixa variação (baixo ADI e baixo CV).
- Intermitente: demanda esporádica e baixa variação (alto ADI e baixo CV).
- Errático: demanda frequente e alta variação (baixo ADI e alto CV).
- Lumpy: demanda esporádica e alta variação (alto ADI e alto CV).

Essa categorização é essencial para investigar métodos de previsão de demanda específicos para cada tipo e faz parte da base de sistemas eficientes de gestão de estoques.

A representação gráfica de como essa categorização é feita, e seus valores de corte podem ser vistos na figura 1.

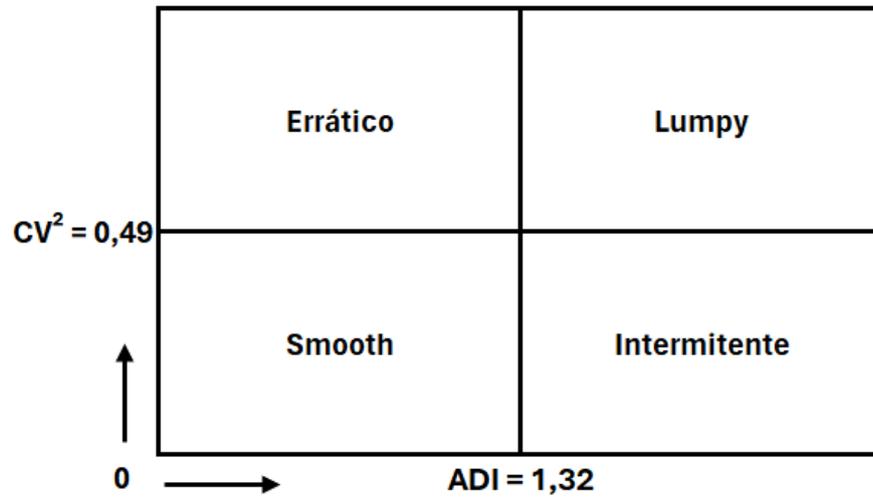


Figura 1 – Tipos de demanda

Utilizando esse método de classificação no grupo das 5 mil peças, foram obtidos os seguintes resultados:

- Smooth: 2345
- Intermitente: 0
- Errático: 534
- Lumpy: 1222

Dessa forma, como houve ocorrências em apenas três grupos, foram selecionados aleatoriamente 20 itens de cada grupo, totalizando 60 peças, com tipos variados de demanda que serão utilizados neste trabalho.

Nas figuras 2, 3 e 4 são apresentadas as 60 séries selecionadas, 20 Smooth, 20 Lumpy e 20 Erráticas respectivamente:

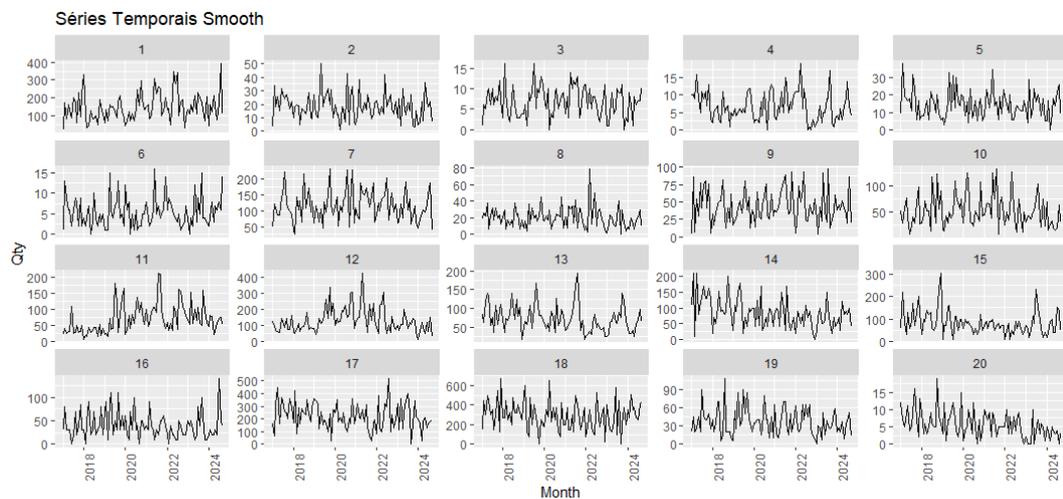


Figura 2 – 20 Séries Smooth

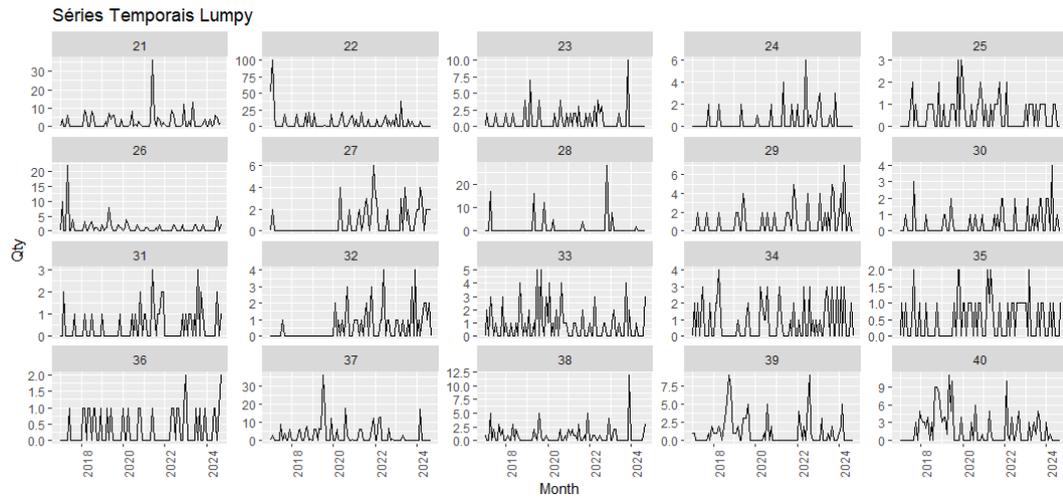


Figura 3 – 20 Séries Lumpy

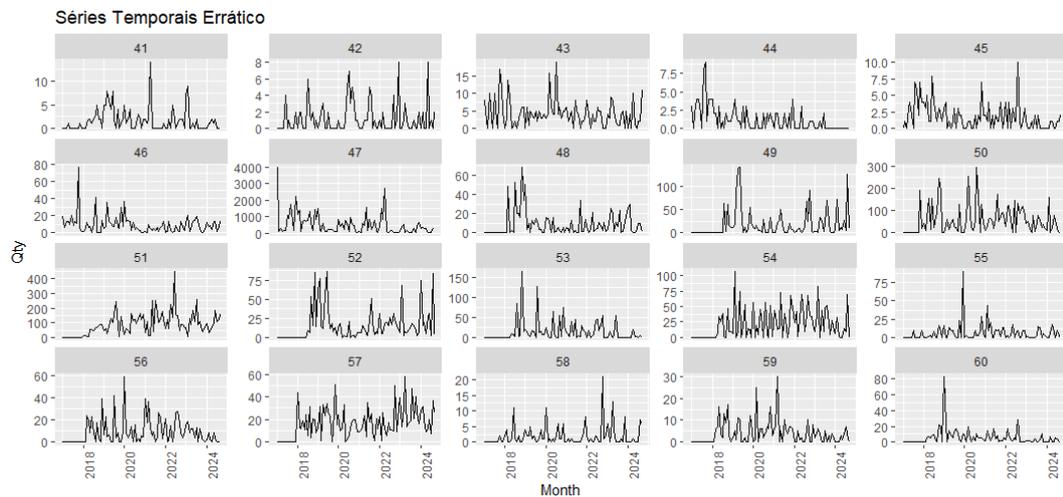


Figura 4 – 20 Séries Erráticas

2.2 Métodos

Para a previsão de demanda das séries temporais definidas para este trabalho serão utilizados modelos vetoriais autoregressivos (VAR), em que um mesmo modelo é ajustado para realizar a previsão de demanda de um grupo heterogêneo de séries.

O modelo VAR estende o modelo autoregressivo (AR) para um contexto multivariado, onde cada variável depende de suas defasagens e das defasagens de outras variáveis.

Serão definidos diversos grupos com características semelhantes, com base na variância da série, quantidades e frequência de zeros, e para cada um desses grupos será ajustado um modelo vetorial autoregressivo (VAR).

Forma Geral do modelo VAR(p):

$$\mathbf{y}_t = \mathbf{c} + \sum_{i=1}^p \mathbf{A}_i \mathbf{y}_{t-i} + \mathbf{u}_t$$

Onde:

- \mathbf{y}_t é um vetor ($k \times 1$) das variáveis no tempo t ,
- \mathbf{c} é um vetor ($k \times 1$) de constantes (termos de intercepto),
- \mathbf{A}_i são matrizes ($k \times k$) de coeficientes para as defasagens i ,
- \mathbf{u}_t é um vetor ($k \times 1$) de inovações (ruído branco multivariado).

Suposições dos Erros:

$$\mathbf{u}_t \sim N(0, \Sigma_u)$$

Onde:

- \mathbf{u}_t possui média zero,
- Σ_u é a matriz de covariância constante dos erros.

Um dos desafios encontrados ao ajustar o modelo VAR aos dados deste trabalho é a presença de valores nulos ou zeros, mesmo em séries categorizadas como *Smooth*. Esses valores podem impactar negativamente a estimação do modelo e prejudicar a verificação da estacionariedade das séries temporais, que é essencial para o ajuste adequado de modelos VAR.

Para resolver esse problema e garantir as propriedades estatísticas necessárias, será utilizado o conceito de *retorno* ou *variação percentual*, combinado com o acréscimo de uma constante positiva c a todas as observações de cada série temporal, que no caso deste trabalho a constante foi definida como 10.

O *retorno* aplicado a cada observação das séries com o acréscimo da constante c é definido como:

$$r_t = \ln \left(\frac{y_t + c}{y_{t-1} + c} \right),$$

Onde:

- y_t representa o valor da série no tempo t ,
- y_{t-1} é o valor no tempo anterior,
- c é uma constante maior que zero.

Na prática, trabalhar com retornos oferece vantagens significativas, pois os retornos são invariantes à escala e tendem a apresentar propriedades estatísticas mais interessantes, como maior probabilidade de estacionariedade, facilitando o ajuste de modelos VAR.

Após ajustar os modelos, as estimativas serão obtidas na escala dos retornos. Portanto, para recuperar os valores na escala original, será necessário realizar uma transformação inversa.

A fórmula para essa transformação é dada por:

$$\hat{y}_{t+1} = y_t \cdot \exp(\hat{r}_{t+1}) + c \cdot \exp(\hat{r}_{t+1}) - c,$$

onde:

- \hat{y}_{t+1} é o valor estimado na escala original no tempo $t + 1$,
- y_t é o valor da série temporal no tempo t ,
- \hat{r}_{t+1} é o retorno estimado no tempo $t + 1$,
- c é a constante adicionada durante o cálculo inicial dos retornos.

Essa transformação garante que os valores retornem à escala original de maneira consistente, considerando a estrutura da série temporal e a constante c utilizada no modelo, sendo este um procedimento recursivo.

Nas figuras 5 e 6, é apresentado o exemplo das 20 séries Smooth, plotadas em conjunto, antes e depois da aplicação da transformação de retorno, respectivamente:

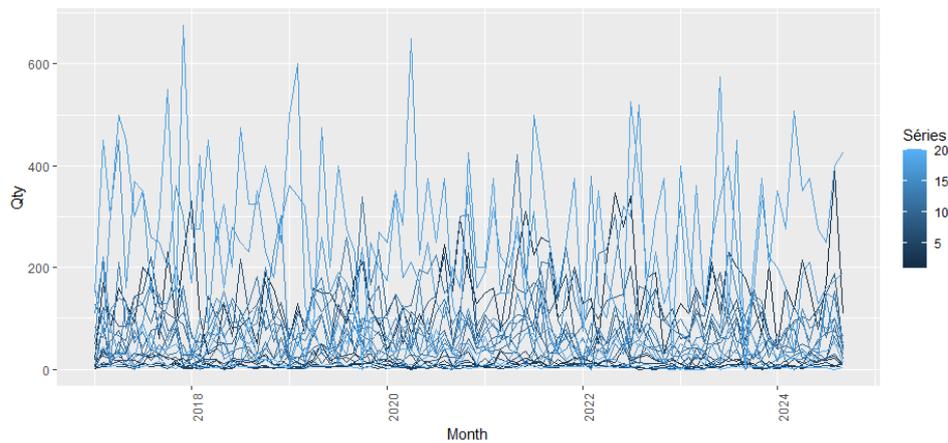


Figura 5 – Séries Smooth sem transformação

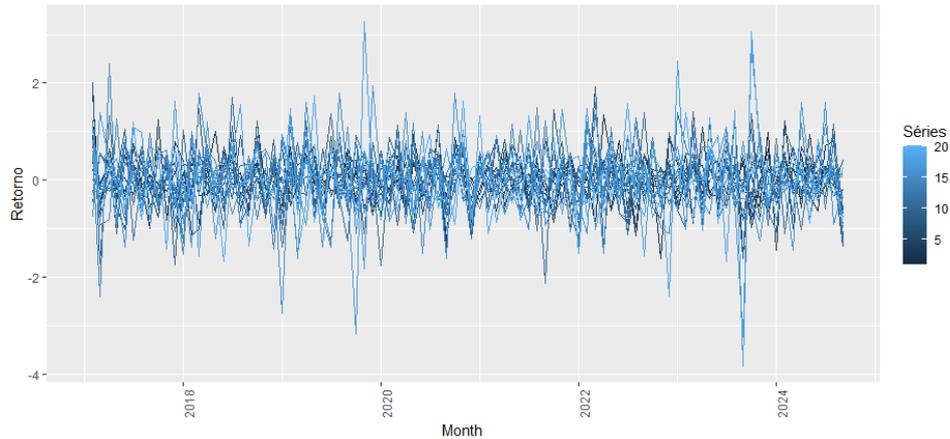


Figura 6 – Séries Smooth com aplicação do retorno

A partir deste ponto, com as séries na mesma escala, o ajuste dos modelos VAR torna-se mais consistente. No entanto, ainda identificamos que o grupo de peças não é homogêneo, o que pode comprometer a eficiência do ajuste.

Para aumentar a homogeneidade dentro dos grupos de séries que serão ajustadas conjuntamente, adotou-se o seguinte critério de discriminação:

- **Cálculo da média do retorno:** Para cada série temporal, foi calculada a média de seus valores de retorno.
- **Segmentação em subgrupos:** Dentro de cada categoria principal (Smooth, Lumpy e Intermitente), as séries foram subdivididas em 3 subgrupos com base nos tercís da média do retorno.

Essa abordagem permite agrupar séries com características mais similares dentro de cada subgrupo, tornando o ajuste do modelo mais robusto e garantindo que as relações dinâmicas capturadas sejam mais representativas de suas respectivas categorias.

Com isso, tem-se agora, 3 sub-grupos dentro de cada grupo de demanda, totalizando 9 sub-grupos a serem ajustados pelo modelo VAR. Nos gráficos 7, 8 e 9 é apresentado o exemplo dos três sub-grupos da categoria Smooth, A, B e C, respectivamente.

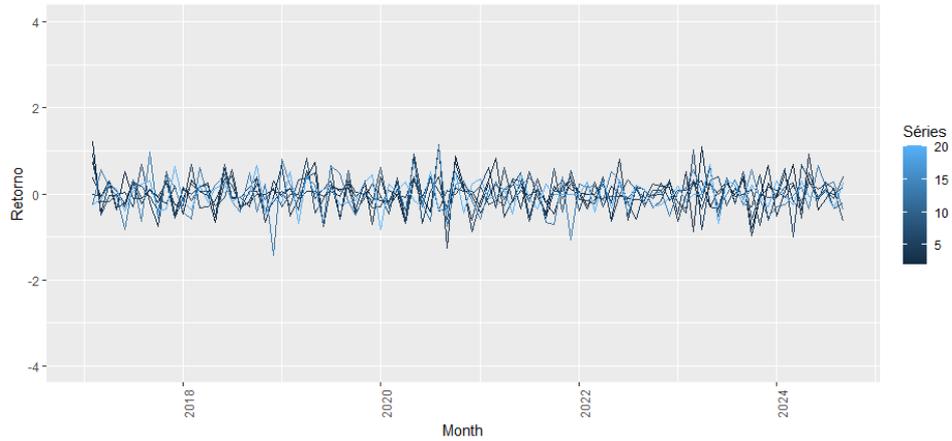


Figura 7 – Séries Smooth sub-grupo A

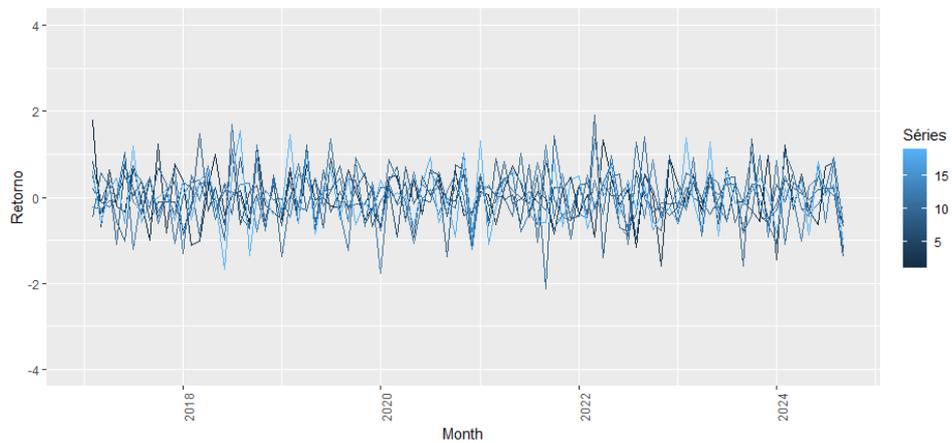


Figura 8 – Séries Smooth sub-grupo B

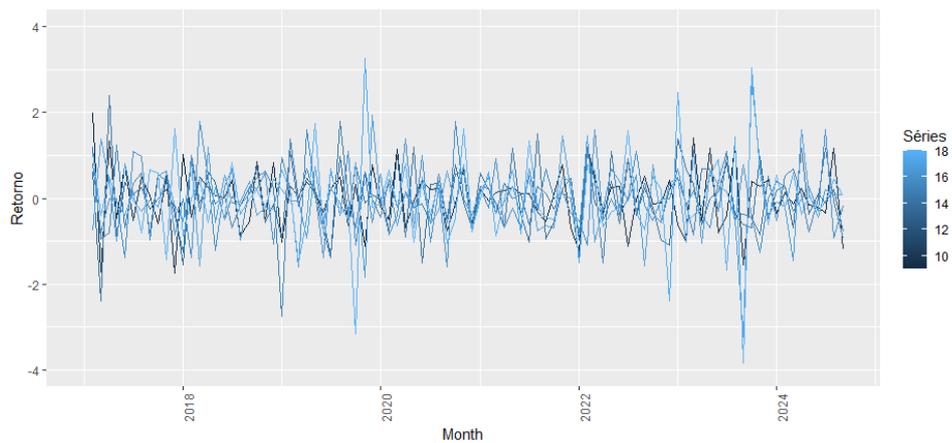


Figura 9 – Séries Smooth sub-grupo C

Para o ajuste do modelo VAR, exige-se a especificação do parâmetro p , que representa a ordem do modelo, e determinar a ordem ideal do modelo VAR (número de defasagens) é um passo essencial para garantir que o modelo capture corretamente as

relações entre as variáveis e realize boas previsões, evitando tanto o subajuste (falta de informações relevantes) quanto o sobreajuste (inclusão de ruído desnecessário).

Para este trabalho, a escolha da ordem será baseada no *Akaike Information Criterion* (AIC). Este critério é amplamente reconhecido por seu bom desempenho em análises cujo foco principal é a previsão, pois prioriza o ajuste do modelo aos dados observados, minimizando o erro residual dentro da amostra. Além disso, modelos selecionados com base no AIC tendem a apresentar desempenho preditivo consistente fora da amostra, tornando-o uma escolha confiável em contextos preditivos.

3 Resultados e Discussão

Aplicando a metodologia descrita neste trabalho, foi ajustado um modelo vetorial autoregressivo (VAR) para cada um dos nove sub-grupos de peças definidos, e foi realizada a previsão de demanda para três períodos a frente para cada uma dessas peças, o período de três meses foi definido com base na realidade de negócio do qual os dados foram retirados, em que busca-se manter em estoque uma quantidade de peças suficiente para atender três meses de demanda. Devido ao grande volume de dados gerado por todos os modelos, serão apresentados os resultados de um único modelo, uma vez que os resultados dos demais apresentam comportamentos semelhantes.

Definição da Ordem do Modelo: Para o subgrupo A do tipo de demanda Smooth, o ajuste do modelo VAR, foi realizado com $p=3$ cseguindo o critério AIC:

```
> VARselect(base_tratada_A[,-1], lag.max=4, type="both")
$selection
AIC(n)  HQ(n)  SC(n)  FPE(n)
      3      1      1      3

> ajuste_A <- VAR(base_tratada_A[,-1], p=3, type = 'both')
```

Correlação dos resíduos: A matriz de correlação dos resíduos não indica nenhum problema de dependência significativa, o que sugere que os resíduos são suficientemente independentes e não há nenhum problema de correlação dos resíduos.

```
Correlation matrix of residuals:
      X2      X3      X4      X5      X6      X13      X20
X2  1.000000  0.31547  0.38799  0.2959  0.22575  0.19483  0.008828
X3  0.315469  1.00000  0.32032  0.2708  0.46730  0.09656  0.017506
X4  0.387987  0.32032  1.00000  0.3182  0.37690  0.07032 -0.087863
X5  0.295929  0.27078  0.31825  1.0000  0.53157  0.20186  0.203532
X6  0.225754  0.46730  0.37690  0.5316  1.00000  0.05927  0.096931
X13 0.194833  0.09656  0.07032  0.2019  0.05927  1.00000  0.104158
X20 0.008828  0.01751 -0.08786  0.2035  0.09693  0.10416  1.000000
```

Matriz de covariância: A matriz de covariância dos resíduos não indica problemas significativos. As variâncias (diagonal principal) estão razoavelmente distribuídas, e as covariâncias (fora da diagonal) são baixas ou moderadas, sugerindo que os resíduos são amplamente independentes entre si.

```
Covariance matrix of residuals:
      X2      X3      X4      X5      X6      X13      X20
X2  0.1403211 0.028930 0.037213 0.03969 0.019793 0.031539 0.0008289
X3  0.0289303 0.059933 0.020079 0.02373 0.026776 0.010216 0.0010743
X4  0.0372129 0.020079 0.065559 0.02917 0.022586 0.007781 -0.0056392
X5  0.0396872 0.023733 0.029173 0.12817 0.044543 0.031231 0.0182654
X6  0.0197929 0.026776 0.022586 0.04454 0.054781 0.005995 0.0056868
X13 0.0315393 0.010216 0.007781 0.03123 0.005995 0.186748 0.0112828
X20 0.0008289 0.001074 -0.005639 0.01827 0.005687 0.011283 0.0628334
```

Teste de Autocorrelação: Pelo teste de Portmanteau, os resíduos do modelo não apresentam evidência estatisticamente significativa de autocorrelação serial (independência temporal).

```
> serial.test(ajuste_A, type = "PT.asymptotic") # Teste Autocorrelação

Portmanteau Test (asymptotic)

data: Residuals of VAR object ajuste_A
Chi-squared = 656.5, df = 637, p-value = 0.2879
```

Teste de Normalidade: Aplicando um teste de normalidade tem-se que os resíduos apresentam uma distribuição aproximadamente normal, o teste não indica assimetria significativa nos resíduos, sugerindo que os resíduos são aproximadamente simétricos, e não indica curtose excessiva ou insuficiente. Todos os testes indicam que não há evidências para rejeitar a hipótese de normalidade dos resíduos.

```
> normality.test(ajuste_A)
$JB

JB-Test (multivariate)

data: Residuals of VAR object ajuste_A
Chi-squared = 15.546, df = 14, p-value = 0.3419

$Skewness

Skewness only (multivariate)
```

```
data: Residuals of VAR object ajuste_A
Chi-squared = 10.105, df = 7, p-value = 0.1827
```

```
$Kurtosis
```

```
Kurtosis only (multivariate)
```

```
data: Residuals of VAR object ajuste_A
Chi-squared = 5.4413, df = 7, p-value = 0.6063
```

Análise de Resíduos: Na figura 10 tem-se os valores ajustados x valores reais, os resíduos do ajuste e suas funções de autocorrelação e autocorrelação parcial para a umas das sete séries ajustadas por este modelo. Onde vemos que o modelo captura bem as variações da série e que não temos problemas com os resíduos, o mesmo padrão se repete para todas as séries, deste e dos demais sub-grupos.

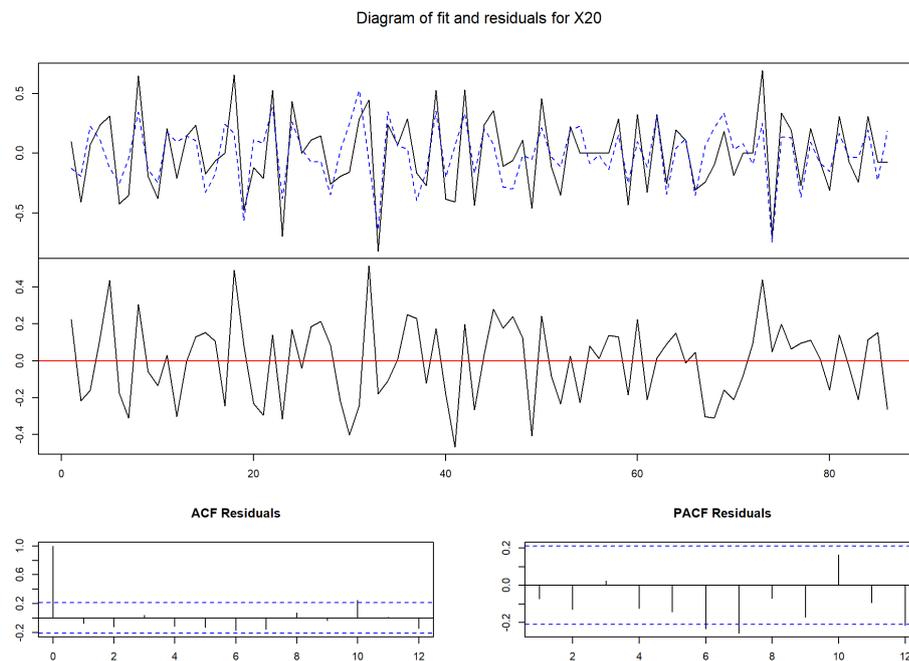


Figura 10 – Diagrama de valores ajustados e resíduos

Previsões: Na figura 11 são apresentadas as sete séries deste sub-grupo e suas respectivas previsões três períodos a frente.

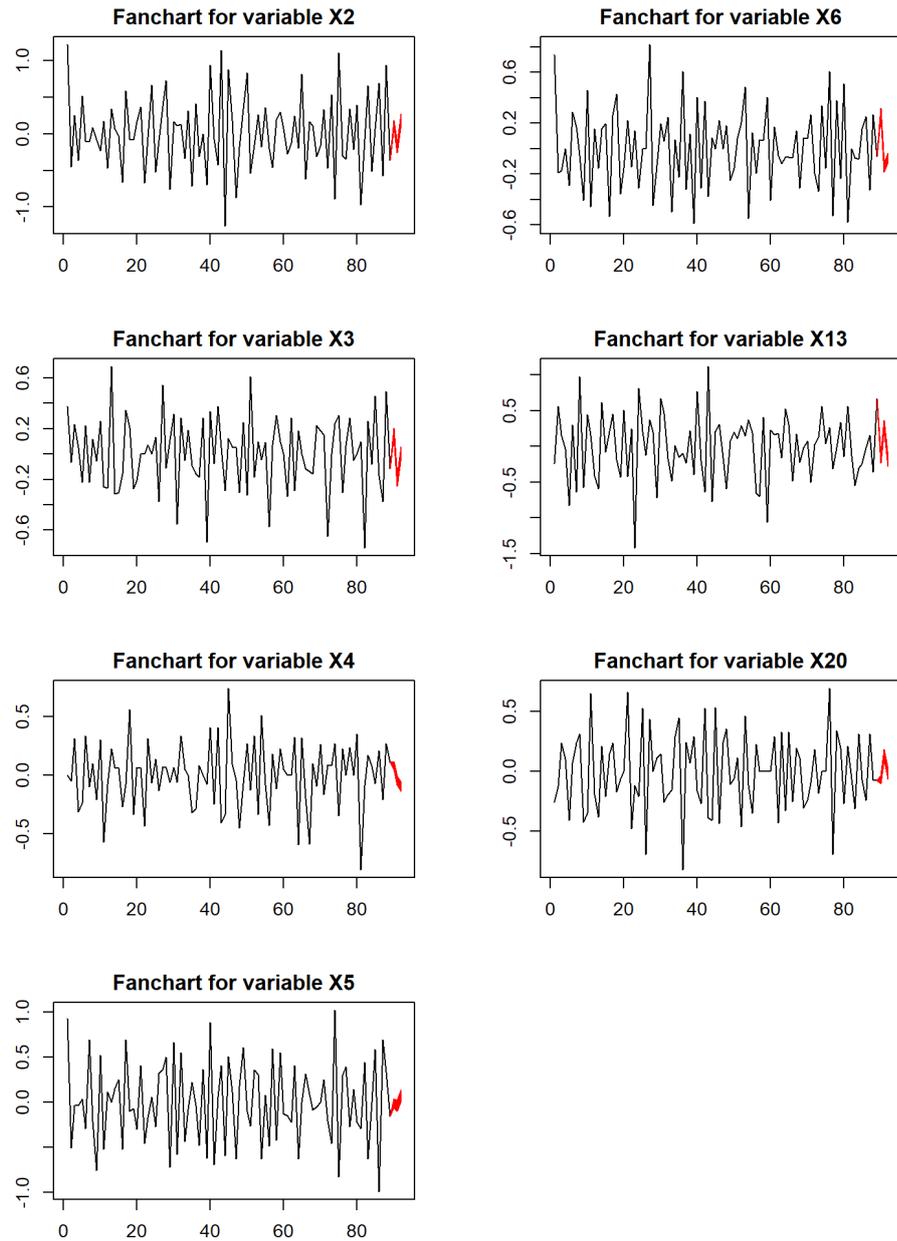


Figura 11 – Previsões três períodos a frente para as peças do sub-grupo Smooth A

Na figura 12 tem-se, para cada uma das peças, a quantidade real, a predição feita pelo modelo e os limites inferior e superior para um intervalo de confiança de 90%.

Item		jul/24	ago/24	set/24	Total
2	Qty	18	22	7	47
	Forecast	26,4	19,9	26,5	72,85
	Inferior	9,7	-3,0	-6,5	
	Superior	57,5	117,9	371,2	
3	Qty	7	7	10	24
	Forecast	9,0	5,4	5,6	20,01
	Inferior	2,7	-3,6	-6,1	
	Superior	18,5	27,1	52,2	
4	Qty	14	7	4	25
	Forecast	10,6	9,7	7,8	28,12
	Inferior	3,5	-2,0	-5,6	
	Superior	21,4	38,3	62,0	
5	Qty	22	26	9	57
	Forecast	13,8	12,9	14,7	41,4
	Inferior	3,2	-4,1	-7,1	
	Superior	32,9	79,0	202,4	
6	Qty	8	6	14	28
	Forecast	11,4	8,5	7,2	26,98
	Inferior	4,5	-2,1	-5,5	
	Superior	21,4	33,2	55,0	
13	Qty	71	98	64	233
	Forecast	46,8	66,9	52,3	165,99
	Inferior	17,9	6,9	-4,0	
	Superior	105,7	340,2	633,1	
20	Qty	4	0	3	7
	Forecast	2,1	4,0	3,6	9,7
	Inferior	-2,0	-4,6	-6,9	
	Superior	8,3	25,8	50,6	

Figura 12 – Previsões para as peças do sub-grupo Smooth A

Métricas de Erro: Na figura 13, são apresentados os principais erros de previsão para cada uma das séries ajustadas pelo modelo. Os três primeiros erros são calculados da forma padrão, mês a mês, e os dois últimos erros são calculados trimestralmente.

Item	Erro Absoluto Médio	Erro Quadrático Médio	Erro Percentual Absoluto Médio	Erro Trimestral Absoluto	Erro Trimestral Percentual
2	10,0	12,3	111,8	25,9	55,0
3	2,7	2,9	32,1	4,0	16,6
4	3,3	3,3	52,5	3,1	12,5
5	9,0	9,5	50,3	15,6	27,4
6	4,2	4,6	44,0	1,0	3,6
13	22,3	23,7	28,0	67,0	28,8
20	2,2	2,6	22,7	2,7	38,6

Figura 13 – Métricas de erro para as peças do sub-grupo Smooth A

Os três primeiros erros apresentados são métricas comumente utilizadas em modelos de previsão, sendo calculados individualmente para cada observação. Esses erros fornecem uma visão acumulada das discrepâncias, já que erros positivos e negativos não

se anulam no período analisado, permitindo uma análise mais precisa do desempenho do modelo mês a mês.

Por outro lado, o quarto e o quinto erros foram calculados de forma trimestral, comparando a soma das demandas reais e das previsões dos três meses a frente. Essa abordagem se mostra mais adequada ao contexto em que os dados foram obtidos, considerando a existência de um estoque que permite o acúmulo de mais peças do que serão demandados no mês em questão. Há um consenso, no contexto de onde os dados foram retirados, de que manter um estoque para três meses oferece um equilíbrio entre os custos de armazenagem e os riscos associados à falta de peças no momento em que são demandados. Portanto, essa forma de cálculo reflete melhor a realidade operacional e da gestão de estoque, proporcionando uma visão mais alinhada às necessidades logísticas e financeiras do negócio em questão.

Smooth: Para o grupo de demanda Smooth, estatisticamente todos os modelos tiveram um bom ajuste aos dados. Com relação as previsões, os resultados foram satisfatórios para os três sub-grupos analisados, com poucos casos destoando significativamente dos valores reais. Para este grupo a utilização dos modelos VAR e de três meses de estoque para uma boa escolha para minimizar custos com estoque e atender a demanda de forma eficaz. Ficando como ponto de atenção os casos em que a previsão ficou significativamente abaixo dos valores reais, indicizando que para estes casos o uso de um valor próximo ao limite superior fosse necessário.

Errático Para o grupo de demanda Errática, estatisticamente todos os modelos tiveram um bom ajuste aos dados. Com relação as previsões, os resultados foram parcialmente satisfatórios, com as peças tendo uma previsão razoável quando considerando o total trimestral, mas destoando consideravelmente em meses pontuais, o que pode ocasionar falta de peças em um determinado mês por um pico de demanda não esperado. Ficando como ponto de discussão se três meses são suficientes para peças com esse padrão de demanda.

Lumpy Para o grupo de demanda Lumpy, estatisticamente o ajuste dos modelos não foi tão significativo quanto para os demais grupos, mas ainda assim atendeu os requisitos estatísticos mínimos. Com relação as previsões, este grupo foi o que teve o pior desempenho, desempenhando razoavelmente para algumas peças, e destoando bastante para outras. Para este grupo ficou evidente que é necessária uma maior quantidade maior que três de meses em estoque para atender a demanda, dada a sua alta variabilidade e incerteza sobre o momento dessa demanda.

4 Considerações Finais

Este trabalho teve por objetivo realizar a previsão de demanda para grupos peças com diferentes comportamentos de demanda em um contexto de pós-venda, onde existe uma grande incerteza relacionada ao comportamento do mercado. Para isso foram aplicados métodos estatísticos com o objetivo de minimizar os erros de previsão, e aumentar a eficiência do negócio.

Estatisticamente os modelos VAR aplicados aos dados, tiveram um bom ajuste, e foram capazes de capturar os padrões de comportamento das diferentes séries.

Na prática, olhando para os erros das previsões, os modelos que tiveram os melhores desempenhos foram aqueles ajustados as peças do grupo de comportamento Smooth, em que os erros trimestrais percentuais giram em torno de 12%, que se comparados com os erros de previsão atuais do negócio de onde os dados foram retirados apresentam uma melhora razoável.

Para o grupo de peças Errático e Lumpy, por seu comportamento mais imprevisível, os erros de previsão foram maiores, ficando em torno de 25% e 35% respectivamente. Mas apesar dos erros de previsão maiores, esta análise contribui para a discussão de que as políticas de estoque para estas peças devem ser revisadas, possivelmente considerando uma cobertura para mais meses de demanda, devido a alta variabilidade de suas demandas.

Considerando os resultados obtidos neste trabalho, fica evidente o valor que a sua aplicação pode ter na prática. Melhorando as previsões em um mercado repleto de incertezas, ajudando na otimização dos estoques, no entendimento do negócio, na eficiência e lucratividade do negócio e em um melhor atendimento as demandas dos clientes.

Uma dificuldade encontrada neste trabalho foi a necessidade de analisar uma grande quantidade de séries (60), e que se pensarmos na realidade do negócio essa é uma pequena amostra, ficaria inviável analisar uma a uma as séries ajustadas. Por este motivo, para a aplicação destes métodos na prática seria necessário o desenvolvimento de uma forma mais automatizada de realizar as análises, com o objetivo de replicar a análise para todo o universo de itens.

Outra idéia para aplicação futura, pensando na realidade do negócio, seria a optar por modelos que errem levemente para mais. Uma vez que na prática é preferível um pequeno excedente de peças em estoque, que podem facilmente ser consumidas no futuro, do que uma falta de peças, que impacta no faturamento da empresa, na satisfação do cliente e na imagem que ele tem do negócio.

Dessa forma, este estudo reforça a importância de modelos preditivos na gestão eficiente de estoques, contribuindo para decisões estratégicas e redução de custos operacionais. E os resultados e conhecimentos obtidos com este trabalho serão aprimorados, para que se adaptem cada vez mais a realidade do negócio, e contribuam para o desenvolvimento deste mercado.

5 Referências

SYNTETOS, A.A., BOYLAN, J.E., CROSTON, J.D. On the categorisation of demand patterns. *Journal of the Operational Research Society*. 56, 495–503, 2005.

AKAIKE, H. Canonical correlations analysis of time series and the use of an information criterion. In *Advances and Case Studies in System Identification*. New York: Academic Press, 1976. p. 27-96.

SIMS, Christopher A. Macroeconomics and reality. *Econometrica*, v. 48, p. 1-48, jan. 1980.