

Previsão de demanda de sobressalentes na indústria ☆

Lucas Jordi Nascimento da Silva¹

Salvador 2019, Brazil

Resumo

Este artigo compara dois tipos de métodos de previsão de dados, chamados de suavização exponencial e *Moving average* (MA), métodos frequentemente utilizados em fontes desse tipo para prever demanda de sobressalentes. Além disso mostra uma análise prática para aplicação desses métodos de previsão comparando-os com as técnicas de gerenciamento de estoque comumente utilizadas. Esses métodos foram aplicados com dados reais, utilizando ferramentas computacionais. Visando como ponto focal a diminuição dos custos da organização e propor um debate da relação entre as técnicas de previsão e de controle de estoque.

Palavras chave: Demanda de sobressalentes, Previsão de sobressalentes, Sobressalentes, Controle de estoque

1. Introdução

Prever e gerenciar estoque e demanda de sobressalentes é uma tarefa muito difícil. Segundo Nenes (2010), o gerenciamento de inventário é uma das tarefas mais importantes na indústria e nas organizações comerciais, sendo assim um mal gerenciamento de estoque de sobressalentes pode gerar grandes impactos no geral. Esse fato pode ser tanto problema do armazém como por exemplo ressuprimentos tardios e da demanda propriamente dita. Uma má parametrização de estoque também gera perdas expressivas em qualquer empresa. Prever a demanda de sobressalentes ainda é um desafio em várias áreas como é afirmado por Ghobbar (2003). Segundo o autor, na área de aviação, a previsão da demanda precisa ter o máximo de precisão possível pois a maioria dos componentes são críticos e precisam de uma preocupação maior. A sua supressão ou invalidação pode ocasionar problemas sérios tanto economicamente falando quanto na integridade dos clientes que utilizam os serviços de aviação. A aplicação de métodos probabilísticos ainda sofre muito com a má estruturação de dados de empresas forçando uma análise mais aprofundada dos dados disponibilizados, desse modo faz-se necessária uma utilização mais aprimorada de técnicas que classificam os dados de forma a diminuir esses erros de apontamentos. O que é comumente visto nas indústrias é a utilização de parâmetros de estoque empíricos/intuitivos. Para prever a demanda

☆Trabalho de conclusão de curso com o objetivo de aprovação em graduação de Engenharia Mecânica.

¹Aluno de graduação do Curso de Engenharia Mecânica da Universidade Católica do Salvador

de estoque, adotado por funcionários que tem uma larga experiência na área. Estabelecendo, desse modo, estoques mínimos e máximos que muitas vezes são imprecisos gerando um custo altíssimo à organização devido ao excesso de material ou a falta do mesmo.

É importante entender os impactos positivos e negativos que os modelos de previsão e gerenciamento exercem em uma empresa. Visto que estão sujeitos a erros que podem ocorrer de forma esporádica ou eventual, dependendo muito da análise feita. Ter um estoque “cheio” pode gerar um custo tão grande quanto a indisponibilidade do mesmo.

Nenes (2010) afirma que algumas singularidades podem e devem ser adicionadas a uma série temporal como é o caso de certas políticas dos fornecedores. Um exemplo é o de uma empresa fabricante que trabalha com estoque de peças em almoxarifado para seus diversos equipamentos onde lida com diversos fornecedores. Para cada situação e fornecedor existe um *lead time* (Tempo da solicitação de requisição de compra até a disponibilização) diferente. Cada fornecedor oferece um certo tempo para a disponibilidade de envio e entrega que segue normas pré-estabelecidas pela própria empresa. Se o produto precisa ser ou não fabricado, tempo de fabricação, logística entre outros são um dos fatores adotados para a disponibilidade do item.

Ghobbar (2003) divide a demanda em basicamente 2 tipos, determinísticos e probabilísticos, sendo também divididos em entre os três processos primários da manutenção, *Hard Time* (HT), *Condition-Monitored* (CM) e o *On condition* (OC). Para os itens determinísticos podemos tratá-los dentro da manutenção preventiva pois já têm uma demanda pré-determinada e com data pré-definida, portanto não necessitam diretamente de um modelo probabilístico. Por outro lado temos os probabilísticos que estão ligados às atividades de manutenção corretivas e, deste modo, sendo necessária a utilização de um modelo probabilístico para prever sua demanda em dado período. É importante lembrar que esses dois tipos de demandas precisam ser analisados separadamente.

A forma mais conhecida para interpretar dados históricos de demanda é o método de séries temporais que é um conjunto de dados organizados em um espaço de tempo. É comum utilizar de processos estocásticos para se trabalhar com as variáveis da série, ou seja, utilizam leis probabilísticas. Um processamento de dados adequado é um requisito importante para a análise de dados e que consome muito tempo de dedicação. Essa atividade se torna importante principalmente no contexto de predição de dados. Em outras palavras os desafios que serão enfrentados neste trabalho são a interpretação e análise dos dados obtidos além de uma possível segmentação, já que em muitas organizações não há uma classificação adequada dos dados armazenados. Exemplos disso são: compras em cartão, compras para estoque, itens de parada e itens emergenciais. Isso tudo é de grande importância para estabelecer critérios de gerenciamento de estoque.

Os objetivos deste artigo são analisar os diferentes métodos de previsão para cada tipo de demanda solicitada, conceituar e mostrar as diferentes ferramentas probabilísticas para auxiliar na previsão de demanda de sobressalentes, comparar a exatidão dos valores gerados, utilizando erros, das diferentes ferramentas probabilísticas para os diferentes casos analisados, comparar os modelos de previsão de demanda com os de controle de estoque. Desse modo visa encontrar uma solução adequada para o problema de previsão e gerenciamento de estoque por meio de ferramentas ideais de previsão de demanda e auxiliar no controle de estoque.

2. Metodologia da pesquisa

Este trabalho baseia-se em uma análise quantitativa, ou seja, por meio da interpretação dos diferentes modelos que simulam ou representam a demanda de sobressalentes utilizando indicadores como por exemplo: nível de sazonalidade, constância dos dados em relação ao tempo, linearidade ou intermitência.

A fase de coleta e tratamento de dados teve suporte do software Enterprise Resources Planning (ERP). Modelos matemáticos e probabilísticos foram utilizados para análises como média móvel (também chamada de MA) e suavização exponencial sendo os métodos mais utilizados. A partir disso modelam uma previsão tendo como ponto inicial dados históricos de demanda de diversos comportamentos como constante, intermitente e sazonal.

Para os cálculos, foi proposta a utilização de planilhas eletrônicas, por serem mais intuitivos e darem melhor visualização de resultados. As planilhas do Google © foram preferidas por serem uma ferramenta simples além de possibilitar um uso mais sofisticado de programação em *javascript*. Posteriormente uma análise mais aprofundada foi realizada utilizando a linguagem de programação *Python* para processar quantidades de informações maiores e gerar gráficos esteticamente melhores.

3. Modelos de previsão de demanda

3.1. Series temporais

De acordo com Adhikari (2013) uma série temporal é um conjunto de dados dispostos de forma sequencial, medidos tipicamente sobre espaços sucessivos no tempo em séries. Shumwai (2003) afirma que o impacto sobre análise de séries temporais em aplicações científicas pode abrir diversos campos para soluções de problemas como por exemplo no ramo de economia ou na previsão de demanda de sobressalentes. Outro exemplo disso, e segundo Shumwai (2003) que descrevem as imagens de ondas cerebrais de ressonância magnética. Usando padrões de uma série temporal pode-se estudar como o cérebro reage a certos estímulos e em várias condições experimentais.

Em geral, uma série temporal é afetada por quatro componentes primários, que podem ser separados da observação. Esses componentes são: tendência, ciclos, sazonalidade e componentes irregulares como apresentados por Adhikari (2013).

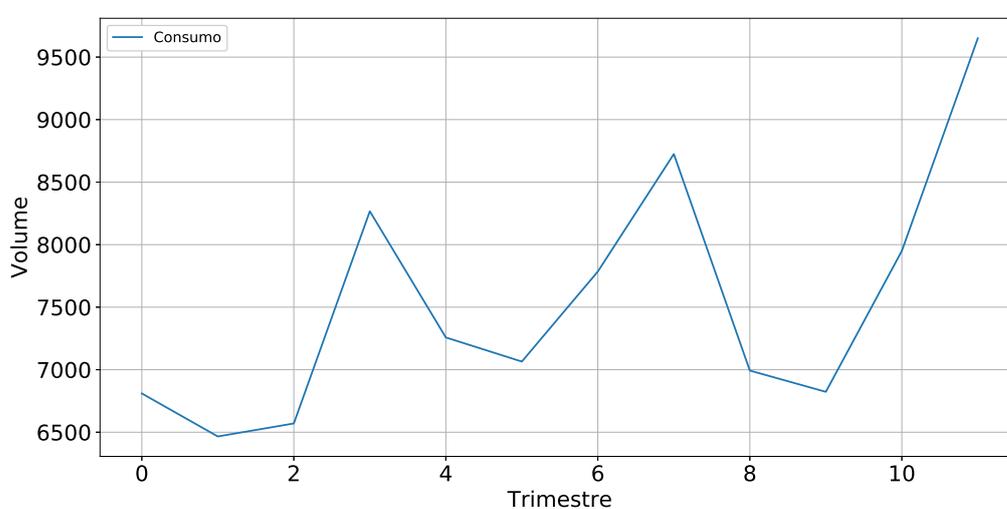
3.1.1. Sazonalidade

Existem variáveis que interagem em uma série temporal e que podem ser vistas e retiradas com a devida análise e compreensão do comportamento da série. A sazonalidade é um comportamento peculiar em uma série temporal, conforme afirma Smith (2009), a análise de uma série temporal é importante nos setores comerciais, além disso, o autor, constata o comportamento sazonal de uma série e como deve ser feita a verificação da variação sazonal de uma massa de dados. Muitas series exibem um comportamento que varia de forma periódica (Smith (2009)). Deve-se ter uma visão macro da massa de dados obtida, e para isso, entender o comportamento da série é imprescindível. Por exemplo, notar a variação dos dados em temporadas, ou seja, em ciclos que podem ser anuais, trimestrais, mensais, por exemplo é um meio de encontrar essa variação. Exemplificando: Supondo que seja traçada uma série temporal com as quantidades de vendas de uma determinada loja

de artigos para inverno. A cada ano as vendas sempre caem na época de verão e atingem seu pico no inverno, fato esse que se repete todo ano. E desse modo a sazonalidade da série é registrada em temporadas, significando que independente do ano a massa de dados sofre uma mesma tendência de crescimento/decrescimento no verão ou inverno.

A Figura 1 mostra um comportamento sazonal de certo conjunto de dados simulados. Tendo em mente apenas a variação por trimestre é difícil de verificar essa sazonalidade. Desse modo, é preciso analisar os dados de forma anual e doravante comparar a variação dos dados ano a ano.

Figura 1. Exemplo de comportamento sazonal



Fonte:Própria

3.2. Método de suavização exponencial

O modelo de suavização exponencial, proposto em meados da década de 50 inspirou diversos outros métodos de previsão conhecidos na atualidade. Previsões feitas pela suavização exponencial são uma média ponderada das observações passadas, como foi proposto por Hyndman (2013). A respeito da história do método chamado suavização exponencial Hyndman (2013) afirmam que existe uma grande variedade de métodos que começaram devido à suavização exponencial, cada qual com suas previsões combinando os ponderamentos das observações, sendo que as mais recentes costumam ter um peso relativamente maior do que as mais antigas. Claro que isso pode variar de acordo com o padrão da série e como os dados se comportam em diferentes espaços de tempo. Por esse motivo é tão importante analisar os dados por meio de uma série temporal para perceber o comportamento dos dados e como eles podem ser ponderados possibilitando uma precisão bem maior do modelo. Ord (2010) analisa dados de demanda intermitente de baixo volume e utiliza métodos de previsão, um deles é a suavização exponencial.

Conforme Ghobbar (2003), o método mais simples de suavização exponencial é o modelo de Croston são os mais utilizados para prever demandas intermitentes e de baixo lote, além disso o modelo simples assume que a observação mais recente é a única que importa, e todas as outras

observações passadas não fornecem nenhuma informação sobre o futuro (Hyndman (2013)). Essa afirmação pode ser correta em um conjunto de dados cuja tendência é quase nula. A equação do modelo simples de suavização exponencial é descrito por:

$$S_i = \alpha X_i + (1 - \alpha)S_{i-1}, \quad (1)$$

onde S_i é o dado previsto, α é a constante de suavização e X_i , a observação anterior já S_{i-1} é a previsão passada.

O método de suavização exponencial simples do segundo tipo, para Hyndman (2013) assume que todas as observações têm a mesma importância, portanto todas são consideradas na previsão fazendo da constante de suavização bem mais útil, mas como o primeiro tipo, existe um problema já que esses métodos simples proporcionam um peso igual para todas as observações em todas as previsões. Na maioria das vezes, não se consegue ter uma previsão muito confiável de Rutter, porém esse problema pode ser facilmente resolvido otimizando a constante de suavização de forma correta. Partindo desse pressuposto e de acordo com Hyndman e Athanasopoulos (2008), diz que às vezes é preciso de algo entre dois extremos, por exemplo: ser mais suscetível a dar maior peso às observações mais recentes que as distantes do passado, ponderando os dados, e esse é exatamente o conceito por detrás da suavização exponencial. As previsões são calculadas com o auxílio de médias ponderadas, onde o peso pode cair ou se intensificar exponencialmente em cada observação.

A constante de suavização age diretamente no modelo de Jonhston (1996). A escolha da constante age diretamente no erro da previsão, ressaltando a importância desta constante para uma correta ponderação das observações passadas. Além disso como Hyndman (2013) diz que para qualquer α entre 0 e 1, faz com que o peso sobre cada observação caia exponencialmente ou volte no tempo, por isso o nome “suavização exponencial”. Se α é menor (próximo de 0), maior o peso das observações distantes no passado. Se o α for maior (próximo de 1), maior o peso das mais recentes observações. Em casos extremos, quando $\alpha = 1$, o dado previsto é igual à observação anterior. A equação para a suavização exponencial do segundo tipo é descrita como:

$$S_i = \alpha(1 - \alpha)y_{i-1} + \alpha(1 - \alpha)^2y_{i-2} + \dots + \alpha(1 - \alpha)^ny_{i-n}, \quad (2)$$

3.3. Método Moving average (MA)

O método MA, de acordo com Hyndman (2013), é um considerado clássico originado em meados da década de 20 sendo bastante usado na década de 50. O MA, tem como base alguns métodos de decomposição de séries temporais. Ghobbar (2003) conclui em seu estudo que o modelo MA é superior a vários outros métodos apresentados por ele inclusive ao de suavização exponencial, podendo proporcionar ganhos mais tangíveis à indústria aeronáutica. Contudo, a média elimina dados aleatórios na observação, levando a um componente cíclico de tendência, Hyndman (2013). Para Hemeimat (2016) o método MA estima o próximo valor utilizando a média do último grupo de períodos de observações passadas.

A equação do MA nada mais é do que a média de n observações estudadas.

$$MA = \frac{\sum_{t=1}^n X_t}{n}, \quad (3)$$

onde n é o total de observações consideradas no modelo e X_t uma observação em dado tempo t .

Teunter and Duncan (2009) fazem uma comparação entre os métodos de suavização exponencial, Média móvel simples(MA), SBA e reamostragem. Eles focam mais na suavização exponencial e o método de MA são bem parecidos em seus resultados já que as previsões da demanda inicial de cada método ficaram próximos da média mensal de demanda do último ano. Isso é obvio já que o cálculo de MA se baseia na média de n observações.

4. Controle e gerenciamento de estoque

O estoque é definido como uma acumulação condensada de recursos materiais em um programa de transformação, sendo qualquer recurso pertencente a alguma organização, que por um determinado objetivo, está sendo armazenado. Slack diz que é algo extremamente importante ter um estoque prévio de determinados consumíveis principalmente em grandes organização onde grandes paradas acarretam em grande custo. Sendo assim o armazenamento em estoque visa diminuir o tempo de parada de produção ou serviço. Croston (1970) explica que regras para reabastecimento de estoque são estimadas por meio de uma relação entre a média das demandas passadas, se utilizando de diversas formas de previsão, como, por exemplo a suavização exponencial.

De acordo com Póvoa e Bárbara (2015) gerir materiais é uma prática que vem ganhando cada vez mais espaço em debates acadêmicos e corporativos, já que é algo muito bem visto nas corporações como um todo e a sua necessidade é notória. Devido ao fato desta operação absorver parte significativa de orçamento para qualquer organização. De acordo com Betts et al (2008), o armazém auxilia nas operações por terem suas vantagens em curto prazo. Mesmo se tratando de vantagens, o mal gerenciamento ocasiona um acúmulo de estoque sem uma demanda imediata, sendo um problema de capital e de espaço no estoque o que deve ser evitado em qualquer organização. "Olhando pelo lado do suprimento, escassez de algum item pode ocasionar em um prejuízo tão expressivo que é mais vantajoso pagar e manter certo nível de estoque Póvoa e Bárbara (2015). Fortuin (1980, apud Rego e Mesquita (2011) caracteriza o ciclo de vida útil das peças em três classe diferentes, que são a inicial, a normal ou repetitiva e fase final.

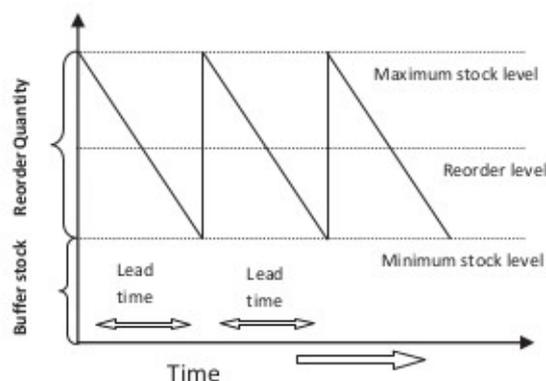
O ponto de ressuprimento é um fator extremamente importante no gerenciamento de estoque pois segundo Pozo (2010, apud Póvoa e Chaves 2014) é onde o número de peças que provê ao estoque segurança e continuidade no processo enquanto aguarda o novo lote de compra em um dado tempo de reposição (*lead time*). Isso significa que, se um item atinge seu ponto de reabastecimento o pedido deve ser imediatamente efetuado e o ressuprimento de estoque finalizado. Partindo disso deve ser criado uma metodologia para gerenciamento de níveis de estoque.

4.1. Técnicas de controle de estoque

Dentre as políticas apresentadas no trabalho, a mais abordada e utilizada para posterior comparação com o modelo de previsão de demanda é a política de parametrização de níveis de estoque em conjunto com o gráfico de serra. Assumindo que no mundo real a demanda no decorrer do tempo e o *lead time* variam de acordo com o fornecedor e item de consumo. Baseando-se no *lead time* e o consumo médio é feita uma parametrização de estoque com estoques mínimos e máximos juntamente com o ponto de reabastecimento (que fica entre o máximo e o mínimo). Essa parametrização é feita por dois motivos: evitar excesso de estoque ou ressuprimento ilimitado de

dados material (máximo) e para ter uma garantia de estoque até que ele seja totalmente ressuprido sem faltar material (Póvoa e Bárbara (2015)). Além disso Póvoa e Bárbara (2015) explica que “Nessa política, é utilizada a posição de estoque e não o estoque líquido para disparar um pedido. A razão é o fato de a posição de estoque incluir os pedidos de materiais que ainda não foram entregues pelo fornecedor” Póvoa e Chaves(2014). A Figura 2 apresenta um bom exemplo de um gráfico de serra e a sua aplicação:

Figura 2. Gráfico de serra



Fonte:Ahmed et al(2014)

Segundo et al (2011) Popovic diz que outro tipo de controle de demanda consiste em elaborar um modelo de reposição periódica em que a parametrização dos níveis máximos são estimados usando uma distribuição da demanda passada, inicialmente, e posteriormente corrigida usando uma inferência Bayesiana com informações históricas acumuladas. Em um primeiro momento a taxa de demanda (λ) é constante e representa um modelo alternativo para demandas variáveis ao decorrer do ciclo especificamente na forma $\Lambda(t) = (k + 1)\lambda t^k$.

Dessa forma é possível estabelecer uma estimativa cada vez mais aprimorada, já que como dito anteriormente, faz-se uma estimativa que no decorrer do tempo vai ganhando cada vez mais exatidão conforme vão sendo adquiridos dados reais de demanda. Conforme Croston (1970), regras de gerenciamento de demanda de estoque são baseadas frequentemente em uma combinação linear da média do histórico de uso seja por lote de consumo ou tempo entre uma demanda e outra que ele próprio aplica em seus métodos.

Um modo interessante de se aplicar métodos de controle de estoque é o uso de indicadores que interpretam o modo como os dados estão se comportando, como por exemplo se a demanda é intermitente, constante, esporádica. Syntetos (2005) assim como Ghobbar (2003) utilizam o que seria o coeficiente de variação ao quadrado (CV^2) e a média de tempos entre demandas (Average Demand Interval-ADI), para traçar comportamentos dos dados a fim de estabelecer uma lei para qual método de previsão e controle de estoque utilizar. et al (2008) após uma revisão de Syntetos (2005) que analisaram históricos de demandas de itens cuja classificação se deu segundo o ADI e o CV^2 . De acordo com essa análise et al (2008) chegaram a seguinte conclusão:

- Demanda errática ($CV^2 < 0,49$ e $ADI > 1,32$);

- Demanda esporádica ($CV^2 > 0,49$ e $ADI > 1,32$);
- Demanda suave ($CV^2 < 0,49$ e $ADI < 1,32$);
- Demanda intermitente ($CV^2 > 0,49$ e $ADI < 1,32$).

5. Aplicação dos métodos de previsão

Os métodos de suavização exponencial e MA foram utilizados para teste e comparação entre ambos e seu relacionamento nas técnicas de controle de estoque. Empregando diferentes tipos de MA e os dois tipos de suavização exponencial para comparação. Utilizando técnicas de erros para comparação da precisão dos dados, foram empregadas para a análise os modelos MAE e MSE descritos por:

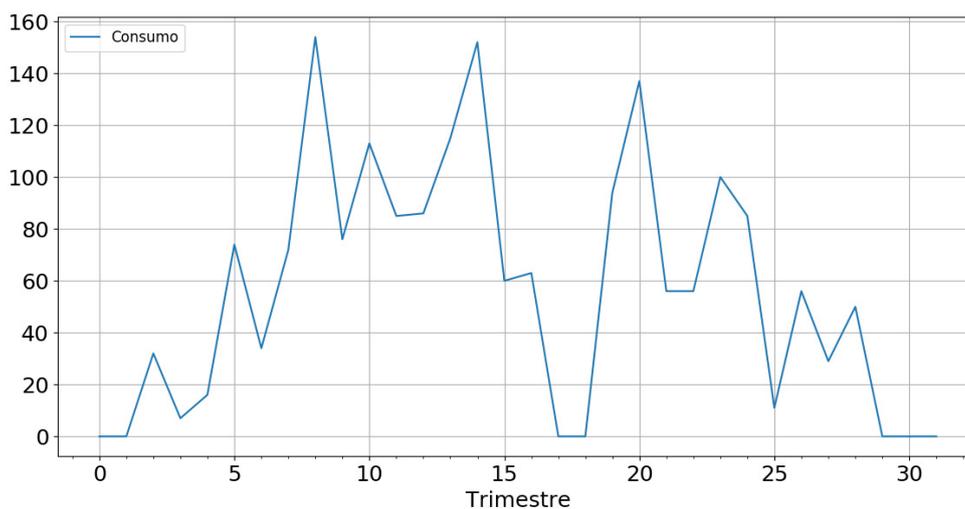
$$\mathbf{MAE} = \frac{\sum_{i=1}^n |y_i - x_i|}{n} \quad (4)$$

$$\mathbf{MSE} = \frac{\sum_{i=1}^n (y_i - x_i)^2}{n} \quad (5)$$

5.1. Análise de sazonalidade

Ao fazer uma análise dos dados obtidos para a execução do modelo foi observado um comportamento peculiar quando avaliado a massa de dados de consumo de abraçadeira como pode ser observado na Figura 3 :

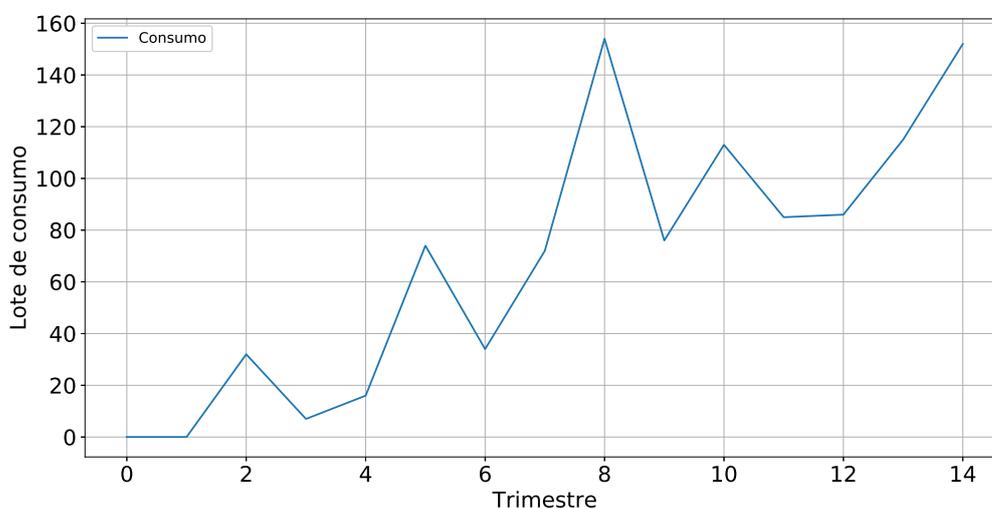
Figura 3. Consumo de abraçadeira por trimestre



Fonte:Própria

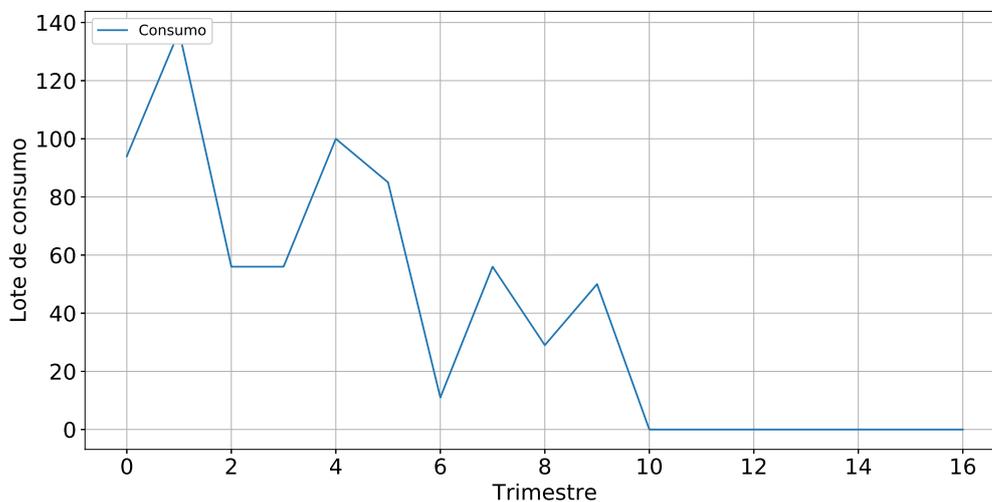
Como pode ser observado pela Figura 3, existe uma grande oscilação nos dados de consumo de abraçadeira e uma irregularidade entre os trimestres 15 e 20 que representam o segundo e terceiro semestre do ano de 2014. Essa evidência pode significar problemas de estoque da peça, ou seja, falta de estoque e posterior reposição tardia. Logo após esse intervalo pode-se observar uma retomada no consumo em relação aos 35 trimestres dos anos analisados. Outra observação feita é a presença de duas sazonalidades diferentes no gráfico que são divididas entre o período de estoque zerado. Sendo assim o consumo de abraçadeira foi dividido em dois gráficos, representando dados de 2010 a 2013 e 2015 a 2018 conforme mostrados nas Figuras 4 e 5, respectivamente:

Figura 4. Consumo de abraçadeira por trimestre - 2010 à 2013



Fonte:Própria

Figura 5. Consumo de abraçadeira por trimestre- 2015 à 2018



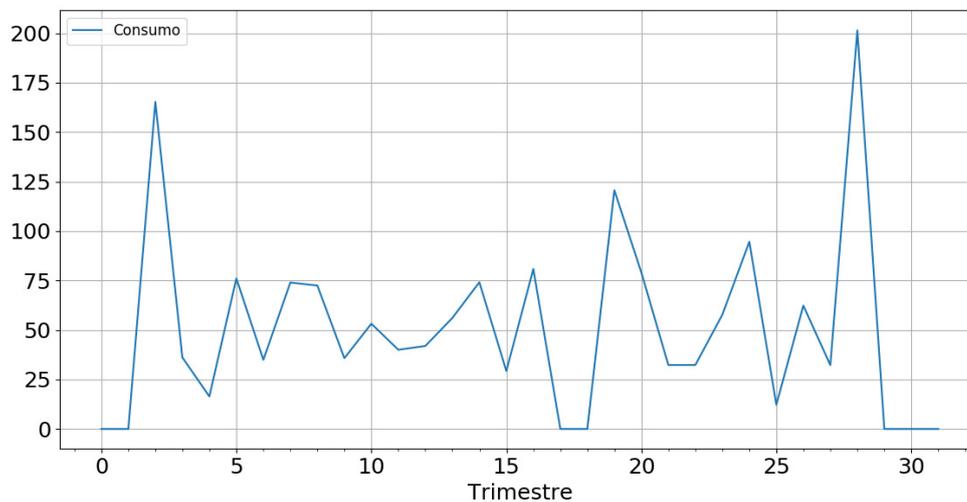
Fonte:Própria

É possível notar nos gráficos uma sazonalidade crescente e outra decrescente nas Figuras 4 e 5. Tendo isso em vista faz-se necessário efetuar o processo de desazonalização dos dados para que deste modo seja possível utilizar os modelos de previsão de forma correta, visto que nos métodos utilizados são aplicados apenas dados com baixa ou sem sazonalidade. A Tabela 1 mostra os índices de sazonalidade por ano analisando as duas amostragens feitas e o resultado da desazonalização que nada mais é do que a simplificação dos dados sazonais para dados mais constantes facilitando a aplicação dos métodos, na Figura 6:

Tabela 1. Índices de sazonalidade por ano

Ano	Índice
2010	0,19
2011	0,97
2012	2,12
2013	2,05
2014	0,78
2015	1,73
2016	0,90
2017	0,25
2018	0,10

Figura 6. Consumo de abraçadeira desazonalizado



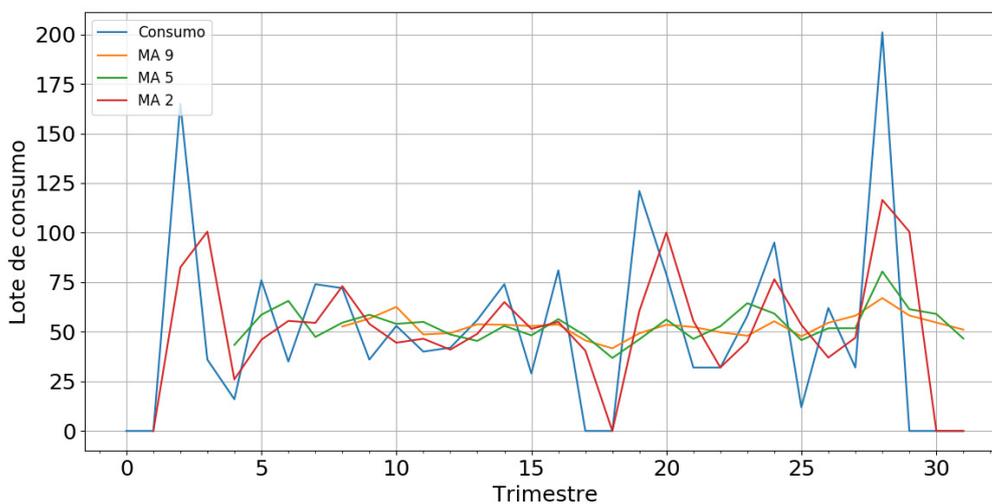
Fonte:Própria

É possível verificar que agora o gráfico perdeu, mesmo que não completamente, boa parte de seu comportamento sazonal, agora com esses dados simplificados é possível efetuar os passos para a previsão de demanda e controle de estoque.

5.2. Aplicação do método MA

Utilizando MA, conforme equação 3 do tipo 2, 5 e 9, cujo índice n , na equação 3, é respectivamente igual a 2, 5 e 9. Foi realizada uma comparação gráfica com 8 itens de consumo na manutenção:

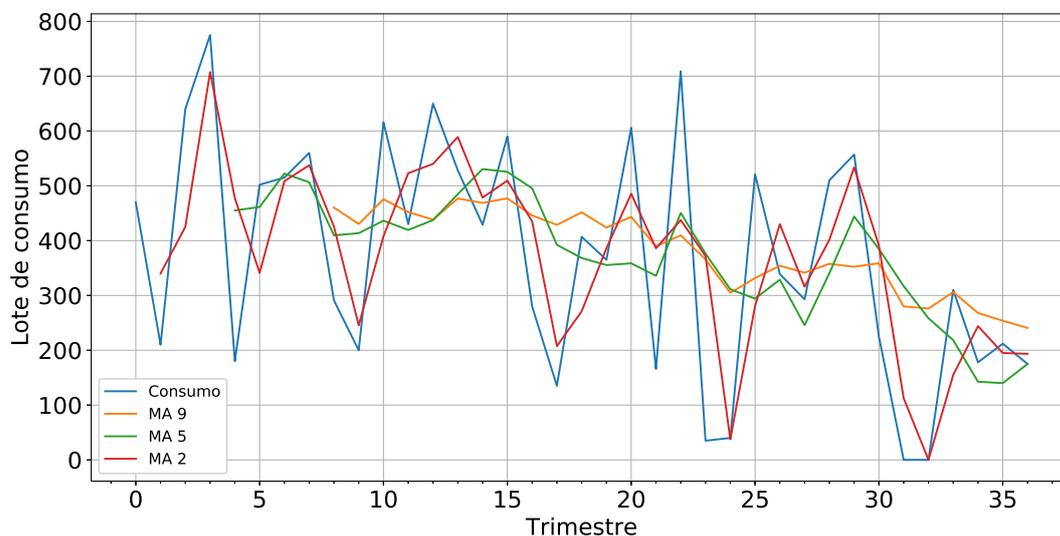
Figura 7. Gráfico comparativo MA consumo de abraçadeira



Fonte:Própria

A Figura 7 demonstra os dados históricos reais do item abraçadeira em forma gráfica utilizando os dados coletados, em azul, por meio da equação 3 foram previstos os dados com índices $n=2$, 5 e 9. Graficamente o método MA do tipo 2 foi o mais preciso como pode ser analisado, contudo o menor MAE foi o do tipo 1 com valor igual a 26,04 para 33,15 do tipo 2. Se for levado em conta o MSE, o tipo 5 tem uma precisão superior aos demais como é demonstrado na Tabela 1. Uma boa sugestão é comparar o método gráfico juntamente com o indicador de erro e tirar conclusões a partir dessa observação.

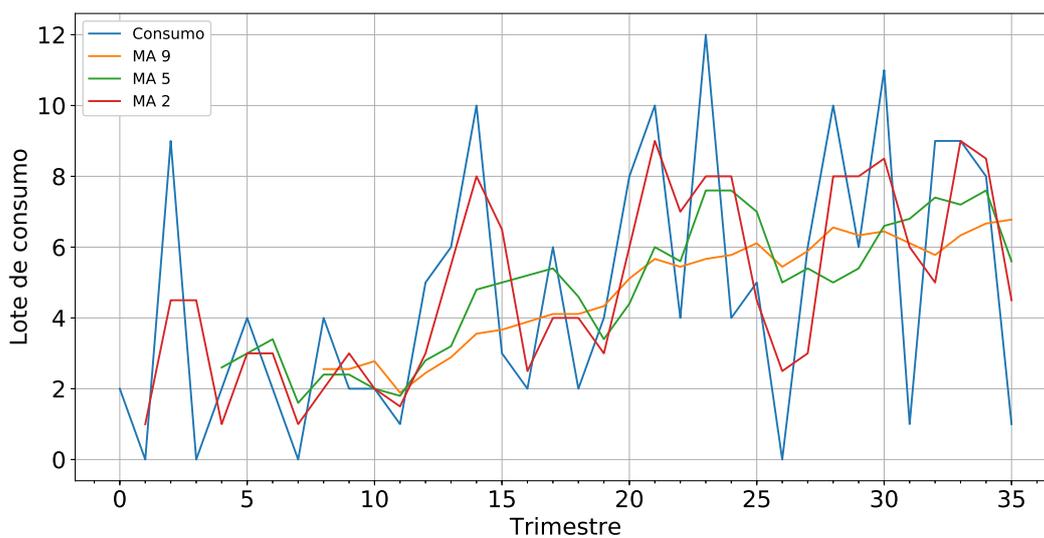
Figura 8. Gráfico comparativo MA consumo de cabo de instrumentação por trimestre



Fonte:Própria

Fazendo uma análise do item cabo de instrumentação e comparando a análise gráfica com a numérica é possível notar uma divergência bem grande, conforme a Figura 8. Graficamente o MA do tipo 2 é o mais confiável, mas numericamente tem o MAE mais alto de todos, sendo o do tipo 5 o mais exato se comparado com os demais. Fato esse que pode ser notado na tabela 1.

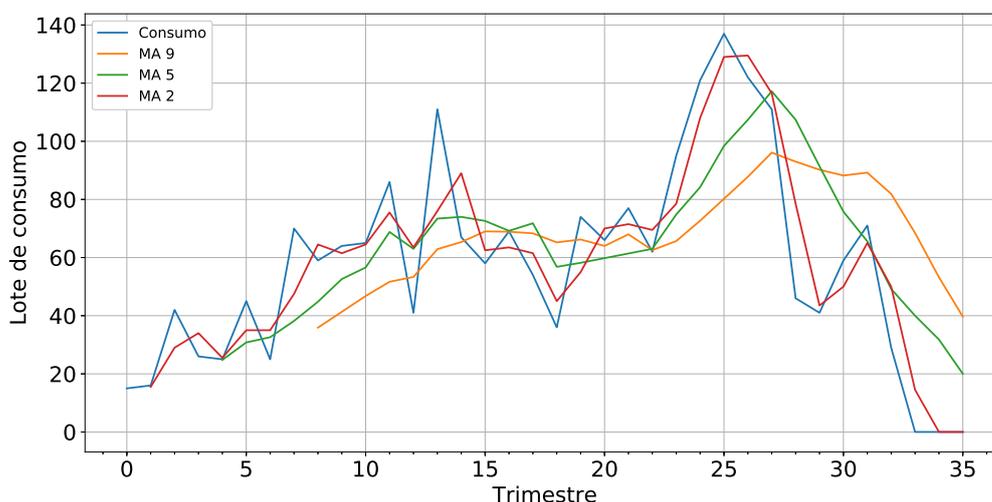
Figura 9. Gráfico comparativo MA consumo de gaxeta por trimestre



Fonte:Própria

Outro experimento foi feito com os dados coletados do item gaxeta conforme Figura 9.

Figura 10. Gráfico comparativo MA consumo de selante por trimestre



Fonte:Própria

Neste caso, de acordo com a Figura 10, pode-se notar que o gráfico está em conformidade com a tabela, ou seja, o ranking de exatidão mostrada gráfico é concordante com a tabela. Isso significa que é possível obter uma decisão bem mais apurada na escolha do método mais confiável, já que até mesmo os métodos de indicador de erros estão em conformidade (Tanto o MAE quanto o MSE) como pode ser analisado na Tabela 1.

Tabela 2. Comparativo de erros por itens

Item	MAE_2	MAE_5	MAE_9	MSE_2	MSE_5	MSE_9
Abraçadeira	33,15	27,09	26,04	4793,61	3057,89	3443,44
Cabo instrumentação	215,53	169,47	173,37	65366,03	44864,24	41980,83
Gaxeta	3,59	3,02	2,86	16,84	13,45	12,41
Selante	21,40	26,82	32,50	712,64	1053,26	1586,00

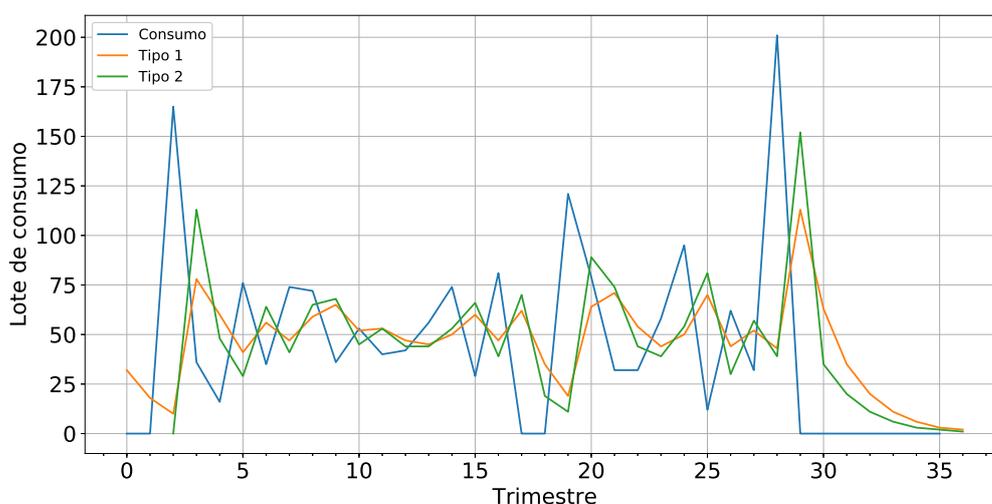
A Tabela 2 informa todos os testes feitos entre os tipos 2, 5 e 9 para comparação e decisão do melhor método. De um modo geral o MA de $n = 2$ é o que possui menor erro, portanto o mais indicado para prever os dados estudados.

5.3. Aplicação do método de suavização exponencial

Foi realizado uma comparação gráfica e analítica (equações 4 e 5). Para a previsão foram utilizadas as equações 1 e 2 comparando cada uma delas junto com uma otimização da constante de suavização α . O erro utilizado foi o MAE.

Para o gráfico de consumo de abraçadeira o valor de α ótimo é de 0,44 e como pode ser observado na Figura 11 , é destacado que o método do tipo 2 descreve muito melhor os dados reais, o que não confirma o resultado da análise quantitativa de erro, já que o erro de tipo 1 é melhor (valor de erro 29,83 para 30,43 de erro do tipo 2). Esse caso assim como os do método MA, fica a critério do pesquisador qual o método indicador será levado em consideração para a decisão do melhor método.

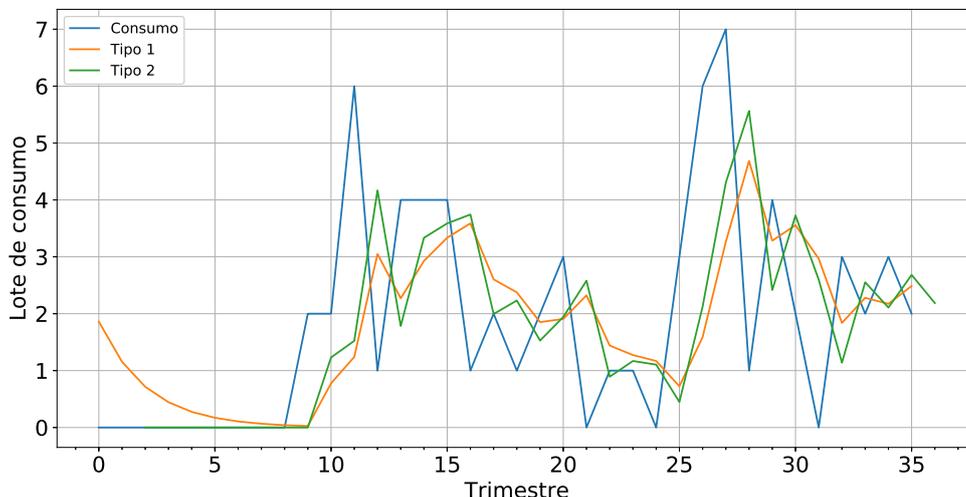
Figura 11. Gráfico comparativo Suavização exponencial consumo de abraçadeira por trimestre



Fonte:Própria

O consumo do item pasta lubrificante foi comparado utilizando o α ótimo de 0,38, o método gráfico (Figura 12) e o indicador de erro. Foram obtidos os mesmos resultados confirmando que o modelo de tipo 1 é o de menor erro. Apesar da Tabela 2 mostrar erros bem próximos entre si (Erros de 1,39 e 1,38 respectivamente) o método gráfico que pode ser visto na Figura 11 reconhece a suavização exponencial de tipo 1 com o menor erro. Como mostrado na Tabela 2 (Erro igual a 1,38).

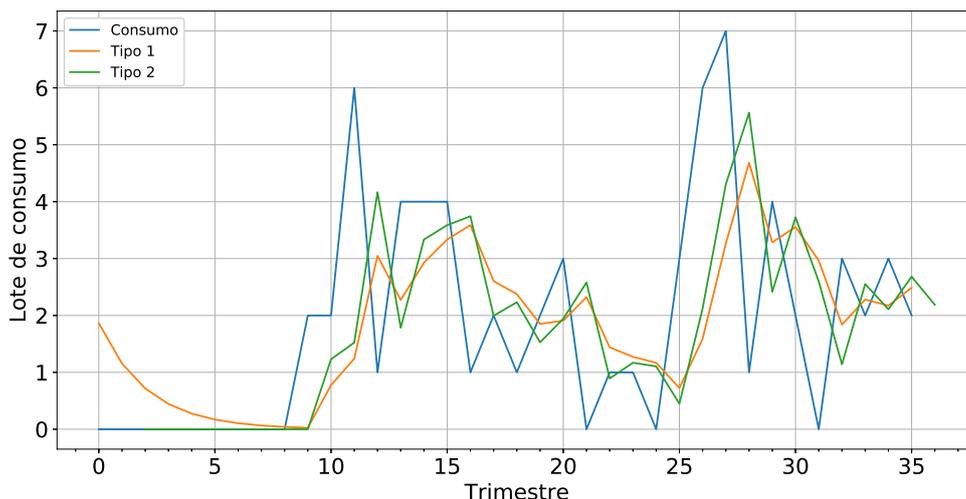
Figura 12. Gráfico comparativo Suavização exponencial consumo de pasta lubrificante por trimestre



Fonte:Própria

A próxima comparação foi feita utilizando os dados fornecidos do item gaxeta com α ótimo de 0,11 apontado pelo método gráfico (Figura 13) que nítidamente a suavização de tipo 2 é a que melhor descreve os dados de consumo real, embora a Tabela 2 indique que o menor erro é o da suavização do tipo 1 (Erro de 2,93 e para o tipo 2 de 3,53).

Figura 13. Gráfico comparativo Suavização exponencial consumo de gaxeta por trimestre

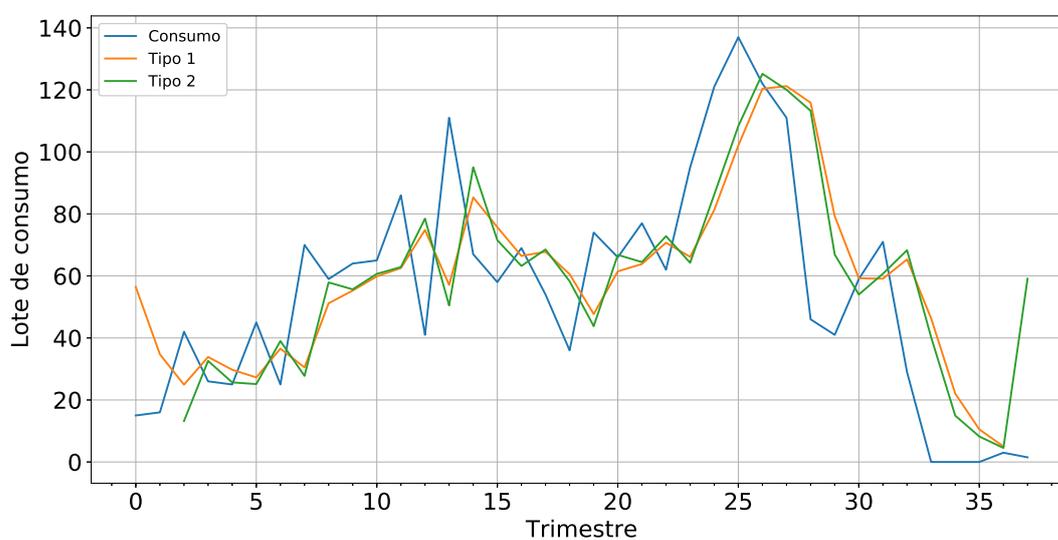


Fonte:Própria

Para a avaliação do consumo do item selante (Conforme Figura 14) foi encontrado um α ótimo

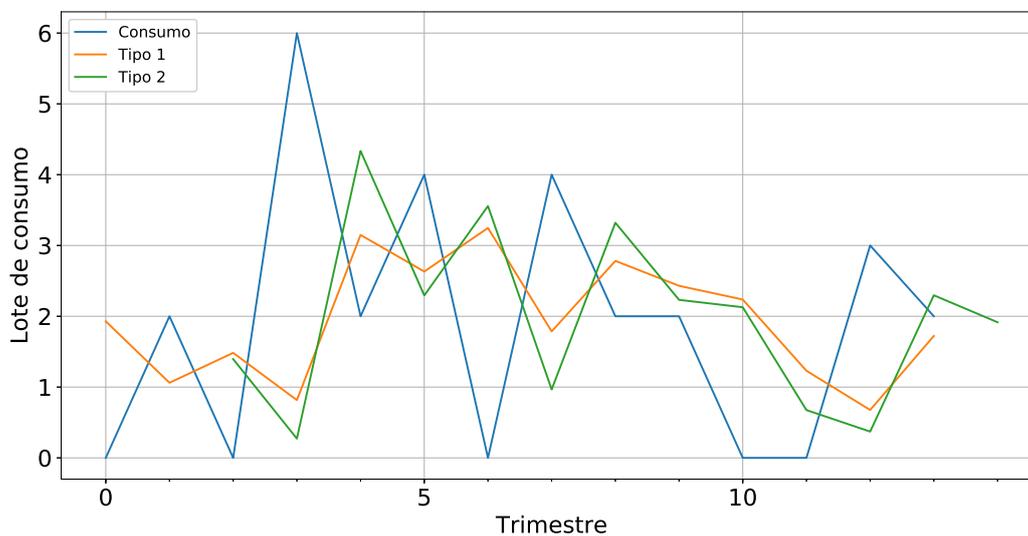
de 0,52. A análise mostra que os dados previstos tanto da suavização exponencial de tipo 1 quanto do 2 são bem parecidos entre si (Valores de 25,07 e 24,96 respectivamente). Faz-se necessário uma análise direta dos erros da Tabela 2. Note que os erros de cada tipo são bem próximos. Outro fato parecido pode ser observado na Figura 14 e com α ótimo 0,45 que descreve o comparativo do item rolamento. Os erros descritos na Tabela 2 são bem próximos um do outro (5,64 e 5,70 respectivamente), sendo o de menor erro o de tipo 1, porém graficamente o do tipo 2 é mais parecido com o consumo real, evidenciado no gráfico da Figura 14.

Figura 14. Gráfico comparativo Suavização exponencial consumo de selante por trimestre



Fonte:Própria

Figura 15. Gráfico comparativo Suavização exponencial consumo de rolamento por trimestre



Fonte:Própria

Tabela 3. Comparativo de erros por itens suavização exponencial

Item	α	Erro Tipo 1	Erro Tipo 2
Abraçadeira	0,44	29,83	30,43
Pasta lubrificante	0,38	1,39	1,38
Gaxeta	0,11	2,93	3,53
Cabo instrumentação	0,12	176,26	205,94
Selante	0,52	25,07	24,96
Rolamento	0,45	5,64	5,70
Bucha	0,45	16,12	16,85
Barra de aço	0,45	228,02	237,16

Como pode ser visto na Tabela 2, o método de suavização exponencial do Tipo 1 descrito pela Equação 1 é o que apresenta o menor erro, em média, para cada item analisado. Porém se analisado de forma gráfica é possível verificar uma melhor adaptação dos dados previstos pelo tipo 2 (equação 2). Isso pode ser visto revendo os gráficos gerados pela suavização exponencial, para uma possível decisão o fato dos dados descreverem melhor o comportamento dos dados reais teria um peso maior na determinação do valor futuro.

6. Aplicação dos métodos de controle de estoque

Nesta etapa do trabalho foi utilizado o método de parametrização de níveis de estoque levando em consideração o lote médio de consumo, o tempo médio entre consumos, o *lead time* médio.

Usando essas variáveis em consideração foi traçado um plano favorável ao ressuprimento de estoque baseado em consumo histórico. Os mesmos itens utilizados para previsão de dados na seção anterior foram utilizados para essa nova aplicação. O *lead time* adotado foi o de 90 dias (15 semanas), que é a média adotada na empresa. Após isso, com a ajuda das previsões feitas com os modelos utilizados nas seções passadas foi feita uma comparação entre o método de controle de estoque e o método de previsão. A Tabela 4 a seguir apresenta todas as variáveis utilizadas para parametrização dos níveis máximos e mínimos e o ponto de ressuprimento, o lote de consumo e o valor previsto:

Tabela 4. Parametrização dos níveis de consumo para ressuprimento de estoque vs Previsão de demanda futura.

Item	Lote médio	Máximo	Mínimo	Nível Rea-bast.	Previsão
Abraçadeira	7	30	21	25	0
Pasta lubrificante	1	21	14	17	3
Gaxeta	2	12	6	9	4
Cabo instrumentação	48	250	144	197	57
Selante	6	390	150	270	2
Rolamento	2	10	2	6	2
Bucha	27	100	55	78	124

A Tabela 4 aponta todos os níveis baseados no histórico de cada item proposto. O lote médio de cabo de instrumentação é em metro e o da barra de aço em kg, os demais estão em unidade. Essa é uma outra metodologia adotada tendo como objetivo primário evitar que falte material, metodologia essa que é diferente da previsão de demanda que visa a demanda em si, ou seja, só se preocupa com a quantidade requisitada. É importante lembrar que em outras ocasiões o *lead time* pode variar de várias formas que não foram abordadas no trabalho em questão.

7. Conclusão

Muitas fontes apontam a suavização exponencial como uma ferramenta eficiente e eficaz na maioria dos casos de previsão de demanda frequentemente citado principalmente por Croston e Johnston em seus trabalhos. Com base nos exemplos adotados na pesquisa, o modelo de suavização exponencial prova que é proveitoso em seu trabalho de prever dados futuros. Por outro lado, o modelo MA, é da mesma maneira bastante eficiente se igualando ao método de suavização. O MA ganha destaque por sua fácil aplicação, pois é bastante simples de usar, necessitando de pouca base teórica para implementação. A exatidão dos dois métodos de previsão verificados nas demandas disponibilizadas foi igualitária (No total de experimentos feitos). A técnica de suavização exponencial do tipo 1 e MA são melhor aplicados em séries cuja tendência é quase nula. Quanto maior a tendência o emprego da suavização do tipo 2 é o mais indicado, podendo ser empregados outros tipos de suavização exponencial como por exemplo o de *HoltWinters*.

Outro fato que não se pode deixar de notar é a qualidade dos dados disponibilizados. A exatidão das previsões depende primariamente do apontamento do consumo durante o tempo feito pela organização. Sendo assim suscetível a erros devido ao mal gerenciamento dos dados.

Na etapa de comparação dos métodos de previsão juntamente com o método de gerenciamento de estoque adotado, notou-se uma divergência nos níveis de estoque quando comparada à metodologia de previsão de demanda. As ferramentas de previsão são muito mais dinâmicas se comparadas com a parametrização de níveis. Isso é óbvio já que a única preocupação do estoque é a garantia de utilização é não o consumo em si. É simplesmente uma garantia de utilização.

Uma metodologia de controle de estoque baseada em parametrização de níveis é mais fácil de ser elaborada, porém em muitos casos pode ocasionar transtornos de gerenciamento. Isso foi visível analisando o perfil de consumo no decorrer do tempo. Existem épocas em que o perfil de consumo funciona de forma correta juntamente com o nível de estoque, em outros o consumo excede e em mais outros casos o consumo é muito inferior ao estoque. Essas situações podem caracterizar perdas econômicas desnecessárias.

Referências

- R. K. Adhikari, Ratnadip e Agrawal. **An Introductory Study on Time Series Modeling and Forecasting**. feb 2013. URL <http://arxiv.org/abs/1302.6613>.
- J D Croston. **Forecasting and Stock Control for Intermittent Demands**. Technical Report 3, 1970.
- Michele de Ruiter. **Using Exponential Smoothing Methods for Modelling and Forecasting Short-Term Electricity Demand**. Technical report.
- Boylan et al. **Classification for forecasting and stock control: A case study**. *Journal of the Operational Research Society*, 59(4):473–481, 2008. ISSN 01605682. doi: 10.1057/palgrave.jors.2602312.
- Rego et al. **Controle de estoque de peças de reposição em local único: uma revisão da literatura**. *Production*, 21(4):645–666, 2011. ISSN 0103-6513. doi: 10.1590/s0103-65132011005000002.
- Chris H. Ghobbar, Adel A. e Friend. **Evaluation of forecasting methods for intermittent parts demand in the field of aviation: A predictive model**. *Computers and Operations Research*, 30(14):2097–2114, 2003. ISSN 03050548. doi: 10.1016/S0305-0548(02)00125-9.
- Lina e Arafeh Mazen e Masoud Shadi Hemeimat, Raghad e Al-Qatawneh. **Forecasting Spare Parts Demand Using Statistical Analysis**. *American Journal of Operations Research*, 06(02):113–120, mar 2016. ISSN 2160-8830. doi: 10.4236/ajor.2016.62014.
- George Hyndman, Rob J e Athanasopoulos. **Forecasting: Principles and Practice**, volume 1 of 1. Monash University, Australia, <https://otexts.com/fpp2/>, 1 edition, 2013.
- Sofia e Tagaras George Nenes, George e Panagiotidou. **Inventory management of multiple items with irregular demand: A case study**. *European Journal of Operational Research*, 205(2):313–324, 2010. ISSN 03772217. doi: 10.1016/j.ejor.2009.12.022. URL <http://dx.doi.org/10.1016/j.ejor.2009.12.022>.
- Ralph e Beaumont Adrian Ord, Keith e D. Snyder. **Forecasting the Intermittent Demand for Slow-Moving Items**. *The George Washington University, Department of Economics, Research Program on Forecasting, Working Papers*, 01 2010.
- Chaves e Gisele De Lorena Diniz Póvoa e Bárbara, Batista. **Ponto de ressuprimento para materiais com demanda sazonal aleatória o caso de uma empresa de grande porte**. *Revista Gestão Industrial*, 10(3), aug 2015. doi: 10.3895/s1808-04482014000300007.
- David S Shumwai, Robert H e Stoffer. **Time series analysis and its applications**. 3(3), 2003.
- S e Johnston R Slack, N e Chambers. **Administração da Produção**., volume 1. Editora Atlas, 3 edition. ISBN 1584883170.
- Chris Smith, Peter J e Chatfield. **Chris Chatfield The Analysis Of Time Series**. 2009. ISBN 1584883170.
- J. E. e Croston J. D. Syntetos, A. A. e Boylan. **On the categorization of demand patterns**. *Journal of the Operational Research Society*, 56(5):495–503, may 2005. ISSN 01605682. doi: 10.1057/palgrave.jors.2601841.

R. H. Teunter and L. Duncan. **Forecasting intermittent demand: A comparative study.** *Journal of the Operational Research Society*, 60(3):321–329, 2009. ISSN 01605682. doi: 10.1057/palgrave.jors.2602569.