

PREVISÃO DE DEMANDA PARA ITENS SOBRESSALENTES DE EMPRESA SIDERÚRGICA COM MODELOS PARA SÉRIES TEMPORAIS

Leandro Fernandes da Silva (USP) Leandro.fernandes@csn.com.br
Igor Pinheiro de Araújo Costa (CASNAV/UFF) costa_igor@id.uff.br
Marcos dos Santos (IME/UFF) marcosdossantos_doutorado_uff@yahoo.com.br

Resumo

A rápida globalização da economia mundial tem exigido que as empresas se tornem cada vez mais competitivas. Um dos fatores que contribui para redução de custo operacional e, consequentemente, ajuda a melhorar o desempenho das empresas é a administração do estoque e se baseia principalmente na previsão de demanda. Isso representa um fator chave na gestão das diversas áreas das organizações sendo fundamental no gerenciamento da cadeia logística, especialmente na gestão de estoques, níveis de serviço ao cliente e planejamento de compras. Este projeto de pesquisa tem por objetivo testar a aplicabilidade dos modelos ARIMA, suavização exponencial e “holt-winters” para previsão de demanda dos itens sobressalentes de uma empresa do setor siderúrgico. Os dados utilizados neste trabalho foram extraídos do “software” SAP R/3 módulo de gestão de materiais MM. A base total disponível foi de 327.924 itens cadastrados e foram analisados 42.548 por terem histórico de consumo no período de jan/2012 a dez/2022. Foi realizado um processo de classificação do histórico de consumo em regular, errático, intermitente e irregular. Para executar os modelos de previsão foi utilizado o “software” RStudio. Para medir o desempenho dos modelos de previsão foi usado a métrica “Mean Absolut Error” [MAE]. O objetivo do trabalho foi atingido e identificado que o melhor modelo de previsão de demanda foi o modelo “Hot winter” com tendência e sazonalidade (aditivo).

Palavras-Chaves: *Previsão de demanda; sobressalentes; ARIMA; siderurgia.*

1. Introdução

O A rápida globalização da economia mundial tem exigido das empresas uma busca constante para aumento da competitividade das operações. O crescimento do desenvolvimento da tecnologia tem permitido que as empresas participem de mercados mundiais da mesma forma,

permite que empresa de outros países venham participar de mercados que antes eram regionais (Tavares, 2014).

Um dos fatores que contribui para redução de custo operacional e consequentemente ajuda a melhorar o desempenho das empresas é a administração do estoque. Que são acumulações de matérias-primas, suprimentos, componentes, materiais em processo e produtos acabados que surgem em numerosos pontos do canal de produção e logística das empresas. Os custos de manutenção dos estoques podem representar de 20 a 40% do seu valor por ano. Por isso administrar cuidadosamente os níveis de estoque é economicamente sensato. Os estoques representam um nível de disponibilidade de produtos aos clientes e essa disponibilidade muitas vezes acaba resultando não apenas a manutenção como o aumento de vendas (Bookman, 2006).

O gerenciamento dos estoques possui um papel fundamental para garantia de competitividade da empresa, permitindo a disponibilidade dos produtos no local certo, ao custo correto, contribuindo para o crescimento das vendas e o desenvolvimento sustentável (Tavares, 2014).

A estocagem de peças sobressalentes tem a finalidade de atender os processos produtivos e equipamentos, a gestão de peças sobressalentes é complexa e envolve grande quantidade de materiais o que torna seu gerencialmente difícil (Muniz, 2020).

A previsão dos níveis de demanda é vital para empresa como um todo, à medida que proporciona a entrada básica para o planejamento e controle de todas as áreas funcionais entre as quais logística, marketing, produção e finanças (Bookman, 2006).

A necessidade de previsões de demanda é comum no processo de planejamento e controle. As previsões representam fator chave na gestão das diversas áreas das organizações e são fundamentais no gerenciamento da cadeia logística, especialmente, na gestão de estoques, níveis de serviço ao cliente e planejamento de compras (Carvalho, 2018).

O dimensionamento dos níveis de estoque se baseia na previsão de demanda, que é a atividade inicial do processo logístico. É a fase responsável pela análise preditiva do consumo, tendo importância crucial para a execução das atividades subsequentes na cadeia logística. O conhecimento da oscilação da demanda, permite que os estoques estejam sempre abastecidos, evitando custos desnecessários decorrentes da oferta em demasia ou da falta de produto. Embora nenhum modelo de previsão seja infalível, a utilização da ferramenta adequada permite que a unidade gestora esteja melhor preparada para atender as demandas reais de seus clientes

(Carvalho, 2018). Por isso a importância da escolha de modelos robustos, que tenham bom desempenho e baixo indicadores de erros das previsões.

Este projeto de pesquisa tem por objetivo testar a aplicabilidade dos modelos de previsão de demanda de séries temporais para previsão de demanda dos itens sobressalentes de uma empresa do setor siderúrgico. Os modelos utilizados serão ARIMA (Automático), Suavização exponencial (Simples e automático) e “holt-winters” (Tendência, amortecimento e sazonalidade).

2. Material e Métodos

2.1 Séries temporais

Série temporal pode ser definida como uma sequência ordenada de observações ao longo do tempo, as séries temporais ocorrem em uma variedade de áreas como agricultura, negócios, economia, engenharia, geofísica, medicina, ciências sociais e etc (Bahman, 2013). Alguns exemplos de séries temporais são níveis de produção anual, demanda mensal de peças de reposição, níveis de estoque semanais, índice IBOVESPA diário e retorno de ações mensais.

Para realizar melhores previsões para o futuro de uma série temporal Roxane (2023), comenta que é importante analisar as tendências e variações sazonais da série histórica.

Roxane (2023) cita três principais características das séries históricas.


Tendências: Referem-se ao movimento crescente ou decrescente de uma série temporal. Dependendo do período de tempo durante o qual a tendência é observada, o valor pode ser relativamente maior ou menor no longo ou curto prazo. Existem dois tipos principais de tendências: cíclicas e sazonal. As tendências cíclicas repetem-se, mas não necessariamente num determinado período de tempo, por exemplo, ciclos de negócios. Numa tendência cíclica, os dados não caem e sobem num determinado período de tempo. Por exemplo, pode-se esperar que a atividade humana aumente a cada ano durante os feriados. Isso que define uma tendência sazonal, também conhecida como periódica. Em outras palavras, a tendência sazonal envolve forças rítmicas que operam de forma periódica e maneira regular.

Flutuações aleatórias: Dizem respeito a eventos irregulares que ocorrem durante uma série temporal. Tais variações aleatórias são geralmente incontroláveis e imprevisíveis, mas pode ser determinado aplicando procedimentos matemáticos.

Estacionaridade: As previsões de séries temporais também pode ser estacionário se as propriedades estáticas não mudarem ao longo do tempo, o que significa que os valores dos dados são independentes do tempo. Isto pode ser visto como uma métrica constante, como variância e média. Em contrapartida, séries temporais não estacionárias são processos aleatórios que não possuem uma distribuição constante ao longo do tempo.


Nas figuras 1. a figura 4. temos um exemplo de decomposição que ilustras as características de uma de serie temporal.

Figura 1- Dados originais de uma série histórica




Fonte: Autor

Figura 2 - Série decomposta com os valores de tendência




Fonte: Autor

Figura 3 - Série decomposta com os valores sazonais



Fonte: Autor

Figura 4 - Série decomposta com os valores cíclicos


Fonte: Autor

2.2 Classificação de demanda

Os modelos de classificação de demanda de Williams (1984) e Syntetos e Boylan (2001) são intensamente discutidos na literatura, sendo os dois modelos principais. A metodologia proposta por Williams (1984) classifica a demanda por SKU's em categorias suaves, lentas e esporádicas, com base na partição de variância, cuja finalidade era a identificação dos métodos de previsão e controle de inventário mais adequado para as categorias resultantes. Syntetos e Boylan (2001) modificaram o método de classificação para quatro categorias errático, irregular, intermitente e regular, usando como base o intervalo médio entre demandas “Average inter-Demand Interval” [ADI] e o coeficiente quadrado de variação dos tamanhos da demanda “Coefficient of Variation” [CV^2] sendo o desvio padrão da demanda do item dividido pela demanda média (Muniz, 2020).

O intervalo médio entre demandas e coeficiente quadrado de variação dos tamanhos da demanda são representados por Muniz (2020) conforme eq. 1 e eq. 2.


$$ADI = \frac{\sum_{n=1}^{N_{pi}} t_i^n}{N_{pi}} \quad (1)$$

$$CV_i = \frac{\frac{\sum_{n=1}^{N_{pi}} (d_i^n - d_i)^2}{N_{pi}}}{\frac{\sum_{n=1}^{N_{pi}} d_i^n}{N_{pi}}} \quad (2)$$

Considera-se t_i^n intervalo de período sem demanda do item i , N_{pi} número de demandas não nulas no intervalo de tempo d_i^n , valor da demanda do item i no período n e d_i média das demandas não nulas do item i . Com o intuito de definir mais claramente os pontos de corte Muniz (2020) apresentam valores de corte para esta classificação $ADI = 1,32$ e $CV^2 = 0,49$.

A figura 5. Mostra como é o comportamento dos itens por regiões.

Figura 5 - Classificação de demanda



Fonte: Muniz (2020)

Essa classificação mostra quatro regiões, em que os itens regulares têm alto giro e baixa variação, a classificação intermitente apresenta diversos períodos sem demanda, baixo giro e baixa aleatoriedade no tamanho da demanda, a região de peças errático apresenta um alto giro com elevada variação no tamanho da demanda, já os materiais irregulares são de baixo giro com elevada variação no tamanho da demanda(Muniz, 2020).

2.3 Suavização exponencial simples

A Suavização exponencial simples que é também chamada de suavização exponencial única é um método de previsão de séries temporais para dados sem tendência ou padrão sazonal. As previsões são calculadas usando a média ponderada dos níveis anteriores e as observações atuais. A suavização exponencial simples associa maior peso as observações recentes e menos pesos para as mais antigas (Roxane, 2023).

Wu Xi (2019) explica que o modelo de suavização exponencial simples realiza a previsão no período t baseando-se na ponderação de 12 observações no período t por um fator de suavização α , e a previsão mais recente por $(1 - \alpha)$. Comenta também que a suavização exponencial simples é adequada apenas para séries temporais estacionárias não sazonais, sem alteração estrutural e que se trata de um modelo mais simples de implementar em comparação a outros modelos de previsão para series temporais,

A suavização exponencial simples foi desenvolvida com base na técnica de usar valores ponderados de observações passadas, para gerar previsões com os pesos decaindo exponencialmente ao longo do tempo. Justificadas pela crença de que as informações recentes são consideradas mais influentes nas previsões do que as mais antigas (Wu Xi, 2019).

2.4 Suavização exponencial “Holt-Winters”

Charles C. Holt estendeu a suavização exponencial simples para permitir a previsão de dados com tendência Holt (2004). O método de Holt assume que os conjuntos de dados têm uma tendência e não têm sazonalidade, por isso utiliza dois componentes, nível e tendência. Este método é usado principalmente para tendências lineares com períodos de previsão curtos a médios. Os dois parâmetros de suavização para nível e tendência são alfa (α) e beta (β), respectivamente e variam entre 0 e 1. A eq. (3) é adicionada para lidar com o aspecto da tendência (Roxane, 2023).

$$b_t = B(S_t - S_{t-1}) + (1 - B)b_{t-1} \quad (3)$$

Onde B é a constante de refinamento para tendências b_{t-1} é a tendência para o período t .

Holt-Winters é uma extensão do método de Holt desenvolvida pelo aluno de Holt, Peter Winters que assume a existência de variações sazonais e de tendência para observação de dados Winters (1960). Considera nível, tendência e sazonalidade com o correspondente parâmetros alfa (α), beta (β) e gama (γ). Suavização Exponencial Tripla adiciona a eq. (4) para a suavização simples e dupla da seguinte forma (Roxane, 2023).

$$I_t = Yy_t + (1 - y)I_{t-1} + m \quad (4)$$

Y é a constante de suavização sazonal

I_t é o índice sazonal para o período t

I é o tamanho do período

Wu Xi (2019) comenta que algoritmos mais avançados como o método de “Holt-Winter”, que dividi-se em aditivos e sazonais multiplicativos (o modelo suavização exponencial simples de três parâmetros), pode refletir o nível L_t , tendência T_t e sazonalidade S_t e demonstra o modelo de suavização exponencial simples de três parâmetros na forma multiplicativa na eq.(5.1) a eq.(5.4) e a forma aditiva eq.(5.5) a eq.(5.7).

$$Y_{t+k} = (L_t + kT_t)S_{t+k-p} \quad (5.1)$$

$$L_t = \alpha \frac{y_t}{S_{t-p}} + (1 - \alpha)(L_{t-1} + L_{t-1}) \quad (5.2)$$

$$T_t = \gamma(L_t - L_{t-1}) + (1 - \gamma)T_{t-1} \quad (5.3)$$

$$S_t = \delta \frac{y_t}{L_t} + (1 - \delta)S_{t-p} \quad (5.4)$$

$$Y_{t+k} = (L_t + kT_t)S_{t+k-p} \quad (5.5)$$

$$L_t = \alpha(y_t - S_{t-p}) + (1 - \alpha)(L_{t-1} + L_{t-1}) \quad (5.6)$$

$$T_t = \gamma(L_t - L_{t-1}) + (1 - \gamma)T_{t-1} \quad (5.7)$$

$$S_t = \delta(y_t - L_t) + (1 - \delta)S_{t-p} \quad (5.7)$$

Onde Y_{t+k} é o valor da previsão do período k , p denota o número de temporadas por ano com $p = 4$ para dados sazonais e $p = 12$ para dados mensais, e α , γ e δ são os três parâmetros de suavização com valores constantes entre 0 e 1.

2.5 Auto regressivo integrado média móvel [ARIMA]

O modelo ARIMA foi apresentado por Box e Jenkins na década de 1970 e tornou-se o modelo com a técnica mais popular de série temporal. Desde então, é conhecido por sua ampla aplicabilidade, pois pode lidar com qualquer série temporal estacionária ou não estacionária, com ou sem sazonalidade. O modelo ARIMA integra o processo Auto regressivo [AR], que especifica que a variável dependente depende linearmente de seus valores passados e do processo de Média móveis [MA], o que significa que o valor atual da variável dependente é uma combinação linear decorrente e termos de erro de ruído branco anteriores (Wu Xi, 2019).

Wu Xi (2019), trás uma abordagem comparativa do modelo ARIMA e suavização exponencial explicando que a suavização exponencial e os modelos ARIMA são as duas abordagens mais utilizadas para previsão de séries temporais e fornecem abordagens complementares para o problema. Enquanto os modelos de suavização exponencial se baseiam na descrição da tendência e da sazonalidade dos dados, os modelos ARIMA visam descrever as autocorrelações nos dados.

Colin (2020) detalha os modelos autorregressivo, média móvel, ARMA e demonstra as fórmulas destes modelos da seguinte forma: Modelo autorregressivo [AR]: faz a suposição de que existe uma relação linear entre a variável de saída e os valores anteriores da série temporal. Os parâmetros podem ser aprendidos enquanto minimiza o erro dos mínimos quadrados. O modelo AR nem sempre é estacionário pois pode conter uma raiz unitária. A ordem de um modelo AR é notada p , tal como eq. (6).

$$y_t = c + \sum_{i=1}^p \phi_i Y_{t-i} + \varepsilon_t \quad (6)$$

onde $\phi_1, \dots, \phi_p$ são os parâmetros do modelo, c é uma constante e ε_t é o ruído branco. As

vantagens desses modelos são a simplicidade do modelo, a eficiência computacional durante a fase de treinamento e manejo do ruído. Os modelos AR também podem ser combinados usando-se uma soma de dois modelos AR para criação de previsões de dados que podem ser altamente sazonais. Observe que AR a previsão é mais precisa quando se trata de conjuntos de dados não sazonais.

Média Móvel [MA]: este método assume que pontos menos recentes podem ter menos importância que os mais recentes. A ordem de um modelo MA é anotada q , tal como eq. (7).

$$Y_t = \mu + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q} \quad (7)$$

onde μ é a média da série, $\theta_1, \dots, \theta_q$ são os parâmetros do modelo e $\varepsilon_t, \varepsilon_{t-1}, \dots, \varepsilon_{t-q}$ são termos de erro.

Auto regressivo com médias móveis [ARMA]: Um modelo ARMA é obtido combinando um modelo autoregressivo com um modelo de média móvel. Um modelo ARMA de ordem (p, q) é um processo temporal discreto $(Y_t, t \in \mathbb{N})$ tal como eq. (8).

$$Y_t = \varepsilon_t + \sum_{i=1}^p \varphi_i Y_{t-i} + \sum_{i=1}^q \theta_i \varepsilon_{t-i} \quad (8)$$

Onde φ_i e θ_i são os parâmetros do modelo e o erro ε_i e que um modelo AR $AR(p)$ é na verdade um $ARMA(p, 0)$, e um modelo MA $MA(q)$ é na verdade um $ARMA(0, q)$

Incluir uma parte integrada de um modelo ARMA resulta no modelo ARIMA. A parte integrada do modelo ARIMA visa transformar quaisquer dados não estacionários em dados estacionários. Existem três parâmetros a serem definidos para o modelo ARIMA: p , para a ordem do modelo autorregressivo, d para o grau de diferenciação e q para a ordem do modelo de média móvel. Esses parâmetros podem ser definidos seguindo a metodologia de Box e Jenkins. Os métodos de pesquisa em grade são capazes de encontrar a melhor combinação de parâmetros (p, d, q) em um intervalo definido (Colin, 2020).

2.6 Medidas de erro de previsão

A precisão da previsão dos modelos está relacionada a uma comparação entre os valores previstos e os valores reais. A medida de erro de previsão é aplicada para testar a acurácia de um método de previsão. Existem diversas medidas de precisão discutidas na literatura que podem ser usadas para medir o desempenho dos modelos (Bahman, 2013).

As medidas de erro de previsão é a forma usual para seleção de um modelo de previsão mais adequado. Algumas das medidas de erro utilizadas na literatura em previsão de demanda são: erro médio “Mean Error” [ME], erro absoluto médio “Mean Absolute Deviation” [MAE], erro quadrático médio “Mean Square Error” [MSE], e erro percentual absoluto médio “Mean Absolute Percentage Error” [MAPE] (Colin, 2020).

Os erros apresentados usam como base o erro da previsão por período e são apresentados nas eq. (9) a eq. (9.3).

$$ME = \frac{1}{N} \sum_{t=1}^N e_t \quad (9)$$

$$MAE = \frac{1}{N} \sum_{t=1}^N |e_t| \quad (9.1)$$

$$MSE = \frac{1}{N} \sum_{t=1}^N (e_t)^2 \quad (9.2)$$

$$MAPE = \frac{\sum_{t=1}^N \frac{|e_t|}{Z_t} \times 100\%}{N} \quad (9.3)$$

Para uma série temporal com N observações, denota-se Z_t como o valor observado no tempo t e $\bar{Z}_t$ a previsão no período. Assim, o erro de previsão no período t pode ser definido como $e_t = (Z_t - \bar{Z}_t)$ neste caso com variações positivas e negativas (Carvalho, 2018).

2.7 Metodologia utilizada

Em relação à metodologia trata-se de uma pesquisa aplicada, exploratória e quantitativa, pois possui como fim aplicar os conhecimentos adquiridos para aperfeiçoar a previsão de demanda na empresa siderúrgica. Foi realizado também os levantamentos bibliográficos e a extração da base de dados.

2.8 Levantamento dos dados

Esta pesquisa foi realizada em uma empresa siderúrgica de grande porte localizada no estado do Rio de Janeiro. Os dados foram extraídos do sistema “Enterprise Resource Planning” [ERP] do “software” SAP R/3 módulo de gestão de materiais. Essa empresa possui uma base de dados com um total de 327.924 itens sobressalentes cadastrados. Destes, foram analisados 42.548 por terem histórico de consumo no período de 132 meses, referente aos anos de 2012 a 2022.

2.9 Classificação de demanda

Realizou-se um processo de classificação, conforme metodologia de Syntetos e Boylan (2001) e foi segmentado em quatro categorias: Errático, Irregular, Intermitente e Regular. A premissa para classificação foi o intervalo médio entre as demandas e o coeficiente da variação dos tamanhos das demandas.

O total de itens que passaram pelo processo de classificação foi de 42.548, sendo que foram classificados da seguinte forma: 62 itens regular, 335 itens intermitente, 723 Irregular e 41.428 itens erráticos.

Depois da classificação dos dados, foi coletado uma amostra de dez itens de maior representatividade de valor de consumo histórico de cada segmentação: regular, intermitente, errático e irregular. Realizou-se a previsão de demanda pelos modelos para séries temporais: ARIMA (Automático), Suavização exponencial (Simples e automático) e “holt-winters” (tendência, amortecimento e sazonalidade).

2.10 Previsão de demanda

O objetivo desta pesquisa foi identificar o melhor modelo de previsão de demanda para itens sobressalentes, a principal métrica utilizada foi a medida de acurácia dos modelos de previsão. Por isso não foi detalhado os valores das previsões e somente relatado o passo a passo das execuções das previsões de demanda, para possibilitar futuros trabalhos de outros pesquisadores.

O processo de execução dos modelos de previsão foram realizados no “softwer” RStudio e utilizou-se os pacotes "readr", "readr", "readxl", "plotly", "tidyverse", "fable", "gridExtra", "forecast", "TTR", "smooth", "tsibble", "tsibbledata", "fpp3", "lubridate", "urca", "dygraphs",

"quantmod", "BETS", "tseries", "FinTS", "feasts", "gridExtra", "scales", "xtable", "tsutils", "GetBCBData", "quantmod", "dgof", "seasonal", "devtools", "transformr", "gganimate", "kableExtra".

A série histórica foi dividida em base treino (jan/2012 a dez/2021), base de teste

(jan/2022 a dez/2022) e o período de previsão foi definido em 12 passos a frente.

Na Tabela 1, foi apresentado os modelos de previsão de demanda e a lista de códigos utilizados para executar os modelos.

Tabela 1. Modelos e código utilizados no trabalho

Modelos de previsão	Código R	Estúdio
Suavização Exponencial Simples	modeloses=ses(base_CSN,h=12)	
	modeloses	
	modeloses	%>%
	kable()	%>%
	kable_styling(bootstrap_options	= "striped",
	full_width	= F,
	font_size	= 24)
	modeloses\$fitted	
	autoplot(modeloses)	
	summary(modeloses)	
“Hot-winter” com tendência	modeloholt	=holt(base_CSN,h=12)
	modeloholt	
	modeloholt\$model	
	modeloholt\$fitted	
	autoplot(modeloholt)	
	summary(modeloholt)	
“Hot-winter” com tendência e amortecimento	modholtamort =holt(base_CSN,damped = T, phi = 0.9, h=12)	
	modholtamort	
	modholtamort\$model	
	autoplot(modholtamort)	
	summary(modholtamort)	
	modeloholt	%>%
	kable()	%>%
	kable_styling(bootstrap_options	= "striped",
	full_width	= F,
	font_size = 24)	

(conclusão)

Modelos de previsão	Código R	Estúdio
“Hot-winter” com tendência sazonalidade (aditivo)	<pre>modholtsazonalad=hw(base_CSN,h=12,seasonal="additive") modholtsazonalad modholtsazonalad\$model autoplot(modholtsazonalad) modholtsazonalad summary(modholtsazonalad)</pre>	%>%
Auto Arima	<pre>modelo=auto.arima(s_base_CSN,trace = T) s_base_CSN=window(base_CSN, start=c(2012,1), end=c(2021,12)) summary(modelo)</pre>	
Auto Suavização Exponencial Simples	<pre>base_CSN <- read_excel("Base_CSN_ID_21.xlsx") base_CSN=ts(base_CSN[2], start = c(2012,1), end=c(2022,12), frequency = 12) base_CSN %>% autoplot s_base_CSN=window(base_CSN, start=c(2012,1), end=c(2021,12)) plot(s_base_CSN) reais=window(base_CSN, start=c(2022,1), end=c(2022,12)) plot(reais) length(reais) base_CSN.ets <- ets(base_CSN, model = "ZZZ") summary(base_CSN.ets) base_CSN.ets.forecasts <- forecast.ets(base_CSN.ets, h = 12) summary(base_CSN.ets.forecasts)</pre>	

Fonte: Autor

2.11 Medição de acurácia dos modelos

Posteriormente foi feito a tabulação das medidas de erro das previsões para identificar qual o modelo que apresenta o menor erro entre o valor previsto e o valor real.

A medida de erro utilizada para avaliar o desempenho dos modelos foi o MAE.

O MAE consiste na média dos erros absolutos entre as demandas observadas e as previsões calculadas ($0 \leq \text{MAE} \leq +\infty$). O MAE é um indicador apropriado para a medição da precisão dos dados: quanto mais próximo o seu valor for de zero, mais precisas são as previsões. Caso o MAE seja zero, significa que as previsões calculadas são iguais a demanda observada, nos períodos em análise. Contudo, se isto não se verificar, a sua interpretação torna-se mais difícil,


sendo certa apenas a informação do quanto as previsões consideradas se afastaram em média das demandas observadas, em termos absolutos (Carvalho, 2018).

Foi analisado a viabilidade de usar o MAPE como medida de erro de previsão. Mas como explica Hyndman e Koehler (2005), a utilização do MAPE em série histórica que possui característica intermitente, os vários períodos com demanda nula (zero) causam dificuldade aos denominadores das medidas de discrepância do MAPE. Por isso foi preciso contornar este inconveniente usando outra medida de erro para avaliar o desempenho dos modelos de previsão abordado neste trabalho.

3. Resultados e discussão

A base de dados total de itens sobressalentes da empresa siderúrgica que participou desta pesquisa é de 327.924 itens cadastrados. Destes, foram analisados 42.548 por terem histórico de consumo no período de 132 meses. O resultado do processo de classificação do histórico de consumo dos itens foi demonstrado na Figura 6.

Figura 6. Quantidade de itens por classificação de tipos de demanda



Fonte: Autor

Com base nas informações da Figura 6, temos 41.428 dos itens da base de dados que possui classificação do histórico de consumo Irregular. Isso mostra a importância da escolha de bons modelos de previsão de demanda. Pois estes itens tem alto intervalo médio entre as demandas

e elevado coeficiente da variação do tamanho das demandas, o que torna mais difícil as previsões.

Percebe-se que a minoria dos itens possui um histórico de consumo mais constante, sendo 723 itens classificados como intermitente, 335 errático e 62 regular. Uma boa previsão de demanda para estes itens com demanda mais constante será fundamental para um planejamento e dimensionamento de estoque e consequentemente um bom e nível de serviço de atendimento aos clientes.

Foi selecionado um total de 40 itens para identificação do melhor modelo de previsão de demanda, sendo que 10 itens por cada classificação. Por meio do “softwer” RStudio foi feito a previsão de demanda para cada um dos quarenta itens selecionados, utilizando os 6 modelos de previsão abordados nesta pesquisa: ARIMA Auto, Suavização exponencial Simples, SES Auto, “holt-winters” com Tendência e “holt-winters” com amortecimento e sazonalidade, posteriormente foi realizado a medição do erro das previsões para definição dos modelos mais robustos.

No total foi executado 240 previsões de demanda, ou seja, 6 previsões para cada um dos 40 itens selecionados para esta pesquisa.

A partir das previsões dos modelos e dos cálculos dos erros do valor previsto e real, foi possível fazer a tabulação das medidas de erro conforme Tabela 2, comparando os erros das previsões para avaliação do desempenho dos modelos.

Tabela 2. Ranking de vezes que os modelos apresentaram menor MAE

Modelo	Posição (Menor MAE)					
	1°	2°	3°	4°	5°	6°
1. SES - Suavização Exponencial Simples	4	10	10	12	12	6
2. Hot-winter com tendência	1	6	11	5	8	11
3. Hot-winter com tendência e amortecimento	4	4	10	16	3	3
4. Hot-winter com tendência e sazonalidade (aditivo)	14	11	2	3	2	8
5. Auto – Arima	15	3	2	2	7	11
6. Auto - SES - Suavização Exponencial Simples	2	6	5	2	8	1
Total (projeções realizadas)	240					

Fonte: Autor

Com base na Tabela 2, o modelo SES gerou um número baixo de previsões com maior assertividade em relação aos demais modelos, pois teve apenas quatro previsões com melhores acurácias. As maiores ocorrências se concentraram na faixa central da segunda até a quinta colocação. Como trata-se de modelo cujas previsões utilizam a média ponderada dos níveis anteriores em relação as observações atuais, dando maior peso as observações recentes e menos pesos para as mais antigas. Isso fez com que o modelo não conseguisse gerar um número maior de previsões com menores erros.

O modelo “hot-winters” com tendência teve pior desempenho em relação aos demais modelos. Apresentando apenas uma previsão com menor erro, no entanto teve onze previsões com maiores erros que todos os modelos. Um fator que contribuiu para este baixo desempenho é que este modelo foi parametrizado para fazer as previsões dando um peso maior para as tendências de consumo, no entanto o maior volume das séries históricas não apresenta este tipo de comportamento.

Percebe-se na Tabela 2, que o modelo “Hot-winter” com tendência e amortecimento teve um desempenho melhor em relação ao “hot-winters” com tendência. Este modelo gerou menor valor de erro para quatro e apresentou pior erro em apenas três previsões. Isso se deve ao fato de que o amortecimento do modelo contribui para gerar previsões mais assertivas.

O modelo “Hot-winter” com tendência e sazonalidade (aditivo), apresentou uma acurácia bem superior aos demais modelos. Teve menor erro em quatorze previsões e em onze casos foi o segundo melhor modelo que apresentou menores erros de previsão. Isso mostra que os modelos que levam em consideração o comportamento da série histórica como tendência e sazonalidade tendem a gerar previsões mais assertivas.

O modelo ARIMA também apresentou uma boa performance em relação aos demais modelos. Em quinze previsões ele teve menores erros, no entanto em sete previsões ele apresentou o quinto pior desempenho e em onze casos ele apresentou o pior resultado.

O pior desempenho foi observado no modelo Auto SES, pois teve menor erro de previsão de demanda em apenas três previsões e em oito previsões ele apresentou a quinto pior medidas de erro. Isso mostra que o modo automático do modelo SES não teve uma boa performance na identificação dos comportamentos da série histórica e consequentemente gerou previsões menos assertivas.

Enfim, as análises de performance dos modelos baseada na Tabela 2, indicam que o modelo mais robusto deste estudo com base no desempenho das previsões é o modelo “Hot-winter” com tendência e sazonalidade (aditivo), pois gerou um maior número de previsões com menores erros entre os valores reais e os previstos. Seguido pelo modelo ARIMA que apesar de ter superado o modelo mais robusto em uma previsão com menor MAE, ele não performou bem nas demais faixas do ranking.

No entanto, não se identificou um modelo ideal que gera previsões com menores erros para todos os tipos de série histórica, em alguns casos certos modelos erram menos que outros. Por isso a importância de ser utilizar o empirismo para avaliação de modelos para previsão de demanda sempre que tiver novos dados e novos cenários.

4. Limitações do artigo

Como limitações menciona-se à quantidade de itens utilizado para as simulações. Foi selecionado 40 itens para realizar as simulações de um total de 42.548 sendo que 10 itens por tipo classificação. Isso pode gerar um viés na interpretação dos resultados principalmente nos itens Irregulares que são 97% dos itens analisados.

Neste caso sugere-se num próximo estudo a aplicação de modelos mais aderente ao comportamento de demanda irregulares.

5. Considerações finais

Foi possível atender o objetivo deste trabalho que foi testar a aplicabilidade dos modelos de previsão de demanda de séries temporais para previsão de demanda dos itens sobressalentes de uma empresa do setor siderúrgico. Os modelos utilizados foram ARIMA (Automático), Suavização exponencial (Simples e automático) e “holt-winter” (Tendência, amortecimento e sazonalidade).

Para atingir o objetivo foi preciso fazer uma classificação da demanda dos itens analisados e classificá-los em errático, irregular, intermitente e regular. Identifica-se que 97% dos itens analisados possui uma demanda irregular, e que uma sugestão de uma próxima pesquisa pode ser feita direcionada para modelos específicos para itens com esta característica de comportamento.

No total foi analisado a previsão de demanda de 40 itens sobressalentes, e o modelo que apresentou menor erro nas previsões de demandas foi o “Hot winter” com tendência e sazonalidade (aditivo) e o modelo ARIMA foi o segundo melhor modelo.

Enfim, foi possível atender o objetivo deste trabalho e identificar os melhores modelos de previsão de demanda com base nos dados extraídos e nas medidas de acurácia das previsões.

7. REFERÊNCIAS

Bahman, Rostami Tabar. 2013. **Previsão de demanda ARIMA por agregação. Tese de doutorado.** Universidade Ciências e Tecnologia. Pey Berland, Bordeaux, França.

Bookman. 2006. **Gerenciamento da Cadeia de Suprimentos / Logística empresarial.** 5ªed. Artmed Editora S.A. Porto Alegre, RS, Brasil.

Carvalho. 2018. **Previsão de demanda de material de saúde na Marinha do Brasil.** Dissertação de mestrado, Pontifícia Universidade Católica, Rio de Janeiro, RJ, Brasil.

Colin, Leverger. 2020. **Investigação de uma estrutura para previsão de série temporal sazonal.** Tese de Doutorado. Matemática e Ciência e Tecnologia de Informação e Comunicação. Universidade de Rennes. Rennes, França.

Holt, C. C. (2004). **Previsão de sazonalidade e tendência por médias móveis ponderadas exponencialmente.** Revista internacional de previsão. 20(1):5–10.

Hyndman, R.J.; Koehler, A.B. 2005. **Outras análises das medidas de precisão das previsões.** Departamento de economia e estatística empresarial, Universidade Monash. Melbourne, Austrália.

Muniz, Leandro Reis. 2020. **Previsão de demanda classificação multicritério e otimização no planejamento de peças sobressalentes na indústria mineral.** Tese de doutorado em Engenharia de Produção, Universidade Federal de Minas Gerais, Belo Horizonte, MG, Brasil.

Roxane, Elias Mallouhy. 2023. **Análise preditiva de séries temporais em diversos contextos de aplicação.** Tese de doutorado. Universidade da Borgonha. Dijon, Borgonha, França.

Syntetos, A A and J E Boylan. 2001. **Sobre o viés das estimativas das demandas intermitentes.** Revista internacional da economia da produção. 71 (1–3): 457–466. doi:10.1016/S0925-5273(00)00143-2

Tavares. 2014. **Gestão Estratégicas de Estoques e Planejamento avançado de Demanda.** 1ªed. MAG Editora Ltda. Maringa, PR, Brasil.

Williams, T. M. 1984. **Controle de estoque com demanda esporádica e lenta.** Jornal da Sociedade da pesquisa operacional. 35 (10): 939–948. doi:10.1057/jors.1984.185

Winters, P. R. (1960). **Previsão de vendas por média móvel exponencialmente ponderada.** Gestão de ciência. 6(3):324–342.

Wu Xi. 2019. **A inclusão de variáveis climáticas melhora o desempenho da previsão da procura turística?** Tese de doutorado. Universidade de Bournemouth. Bournemouth, Dorset, Inglaterra.