

PREVISÃO DE DEMANDA COM ANÁLISE DE SÉRIES TEMPORAIS: UMA APLICAÇÃO EM UMA INDÚSTRIA MOVELEIRA

Arthur Harry Frederico Ribeiro Kramer, Erivaldo Lopes de Souza, Anand Subramanian

Departamento de Engenharia de Produção - Universidade Federal da Paraíba
Centro de Tecnologia, Campus I - Bloco G, Cidade Universitária, 58051-970, João Pessoa, PB
{arthurhfrk, elopesouza}@gmail.com, anand@ct.ufpb.br

RESUMO

Este artigo trata de uma aplicação envolvendo Previsão de Demanda (PD) em uma indústria moveleira. O objetivo é calcular os valores previstos da demanda com o intuito de gerar informações importantes para a tomada de decisões. Para o cálculo da demanda prevista existem várias técnicas que podem ser aplicadas. Dentre estas decidiu-se pela combinação da MMS com um método proposto de dessazonalização das séries temporais da demanda. Para obter um indicador da qualidade do modelo, foram feitas comparações com alguns métodos de previsão existentes na literatura, como a própria MMS, aplicada nas séries não dessazonalizadas, e os modelos de Holt-Winters e de Box-Jenkins (ARIMA). As comparações foram feitas considerando o desvio absoluto médio das previsões. Os resultados obtidos pelo modelo proposto se mostraram satisfatórios e, em geral, superiores àqueles alcançados pela aplicação dos outros modelos.

PALAVRAS CHAVE. Previsão de demanda, Séries Temporais, Dessazonalização, Média Móvel Simples.

Áreas Principais: Estatística.

ABSTRACT

This paper deals with an application in a furniture industry concerning the Demand Forecasting (DF). The objective is to compute the expected values of the demands in order to generate important information for decision making. There are many techniques that can be applied for estimating the demands. Among them it was decided to combine the Simple Moving Average (SMA) with a proposed method for seasonal adjustment of the demand time series. To obtain an indicator of the quality of the model, comparisons were performed with forecasting methods from the literature such as SMA itself, applied over the real demand, and the models of Holt-Winters and Box-Jenkins (ARIMA). The comparisons were performed considering the mean absolute deviation of the forecastings. The results obtained by the proposed model are satisfactory and, in general, superior when compared with those obtained by applying other models.

KEY WORDS. Demand forecasting, Time series, Seasonal adjustment, Simple Moving Average.

Main areas: Statistics.

1 Introdução

A previsão de demanda (PD) consiste na utilização de técnicas quantitativas ou qualitativas para a estimativa da demanda nos períodos futuros, sendo uma etapa importante para o desenvolvimento dos planos de capacidade, estocagem, mão-de-obra, compras e vendas.

Um conjunto de observações sequenciadas de uma variável ao longo do tempo é chamado de série temporal. Segundo Cryer e Chan (2008), a sequência de variáveis aleatórias $\{X_t : t = 0, \pm 1, \pm 2, \pm 3, \dots\}$ é chamada de processo estocástico e serve como um modelo para uma série temporal. Para Cordeau (2007), o estudo de séries temporais consiste em analisar dados históricos com a finalidade de identificar padrões que em seguida serão estendidos ao futuro para a obtenção de previsões. Uma série temporal $\{X_t : t \in T\}$, onde $T = \{0, 1, 2, 3, \dots, n\}$ e t representa o tempo, pode ser, de acordo com Brockwell e Davis (2002), decomposta em componentes e ser escrita em sua forma clássica: $X_t = T_t + S_t + Y_t$ onde T_t é a componente de tendência, S_t a componente de sazonalidade e Y_t a componente de ruído aleatório.

Para Gorini (2000), a indústria moveleira é caracterizada pela reunião de diversos processos produtivos, envolvendo diferentes matérias-primas e uma diversidade de produtos finais. Este trabalho trata da proposição e aplicação de um modelo de PD em uma empresa fabricante de móveis sob medida para escritórios, bem como a comparação dos resultados do modelo proposto com os de outros modelos da literatura. A empresa, que tem sua sede localizada em Paris, na França, possui três unidades de produção responsáveis pela fabricação de diversas linhas de produtos.

O processo atual de PD da empresa envolve a utilização de dados de várias fontes. Estes dados são obtidos principalmente de seu sistema de informações (SI) que alimenta várias aplicações desenvolvidas pela própria empresa. Em seguida os resultados destas aplicações servem como entrada de uma outra aplicação principal que gera resultados em termos de PD para as linhas de produtos e para as unidades de produção.

Para Box *et al.* (1994), a previsão de séries temporais pode oferecer uma base para o planejamento econômico e de negócios, planejamento da produção, controle de estoques e da produção e para o controle e otimização de processos industriais. Os valores previstos da demanda podem ser utilizados para um melhor desenvolvimento de um planejamento estratégico de vendas, planejamento de capacidade, elaboração do plano de produção, planejamento de matéria-prima, mão-de-obra e estoques. Deste modo, previsões imprecisas impactarão diretamente na qualidade das decisões tomadas.

A PD representa um papel fundamental tanto no setor industrial quanto no setor de serviços, possuindo aplicações em diversas atividades, como previsão de demanda de: energia elétrica, turistas, transporte, alimentos, combustíveis (Fogliatto *et al.*, 2005; Burger *et al.*, 2001; Pacheco e Silva, 2003; Adebanjo, 2009; Santiago *et al.*, 2011).

Jain (2008) *apud* Noble (2009) diz em seu estudo sobre modelos de previsão, que os mais utilizados atualmente pelas indústrias são os modelos de previsão de séries temporais, representando 61% dos modelos usados.

O processo de PD da empresa é atualmente feito por meio de uma aplicação implementada com o auxílio do Excel. Esta aplicação é alimentada por diversas fontes de dados a fim de constituir automaticamente as previsões por linha de produto e a capacidades das usinas. A empresa acredita que a qualidade da previsão atual não é suficiente para estabilizar a gestão da capacidade nem para assegurar o serviço ao cliente. No início do ano 2012 novas necessidades foram identificadas, colocando em dúvida este modelo de previsão.

Em 2011, empresa objeto deste estudo apresentou um volume de negócios de 114 milhões de euros, representando assim um valor bastante significativo. Este valor aliado ao objetivo de crescimento anual de 10% reforça ainda mais a necessidade de um bom planejamento de suas atividades futuras. Para atingir o crescimento desejado, a empresa enfatiza a necessidade de um bom processo de PD.

O trabalho está organizado como se segue. Na Seção 2 são apresentados alguns métodos de PD existentes na literatura, enfatizando os métodos abordados neste trabalho. Posteriormente, na Seção 3, é apresentado o modelo proposto. Os resultados obtidos a partir da aplicação dos métodos propostos são apresentados na Seção 4. Por fim, a Seção 5 traz as considerações finais e sugestões para trabalhos futuros.

2 Métodos quantitativos de previsão de demanda

Os métodos quantitativos de PD se apoiam em dados históricos relacionados com o que será previsto. Portanto, estes métodos exigem dados quantitativos sobre a demanda. Uma premissa destes métodos é que fenômenos identificados nos dados do passado se repetirão no futuro. Segundo a classificação de alguns autores (Cordeau, 2007; Moreira, 1996; Bowersox *et al.*, 2007), neste grupo é possível encontrar os métodos causais e os métodos baseados em séries temporais.

Os métodos causais procuram identificar fatores que possam explicar a variação da demanda e utilizar modelos estatísticos para descrever a ligação entre estes fatores e a demanda a fim de prever a demanda futura. Os métodos causais são aqueles que, através de uma ou mais variáveis, tentam explicar o comportamento da variável desejada, por exemplo, explicar variável demanda através da variável preço de venda. Em outras palavras, a variável a ser explicada Y pode ser representada em função de outras variáveis: $Y = f(X_1, X_2, \dots, X_m, \varepsilon)$, onde X_1, X_2, \dots, X_m são as variáveis explicativas e ε representa o erro. Dentre os métodos causais podem-se encontrar as técnicas de regressão linear e de regressão não-linear.

O princípio dos métodos baseados em séries temporais é que a demanda futura será uma projeção da demanda passada. Estes métodos utilizam o histórico de demanda de uma determinada variável para a predição dela mesma. Dentro dos métodos de séries temporais, podemos citar os métodos de suavização exponencial simples, das médias, de Holt-Winters e *Autoregressive Integrated Moving Average* (ARIMA). Dentre os métodos citados anteriormente, será dada uma ênfase aos modelos da média móvel simples (MMS), Holt-Winters e ARIMA.

2.1 Média móvel simples

Na MMS, o valor previsto é calculado através da média aritmética, porém o número de observações consideradas é fixo. Apenas as n observações mais recentes são consideradas, ou seja, este método consiste em calcular a média aritmética das n observações mais atuais, conforme apresentado na Equação (1). Os dados anteriores aos n períodos não têm influência na previsão.

$$X_{t+1} = \frac{\sum_{i=1}^n X_{t-i+1}}{n} \quad (1)$$

O nome MMS é utilizado porque, a cada período, a observação mais antiga é substituída pela mais recente, calculando-se uma média nova (Morettin e Toloi, 2006). Neste método, todas as observações consideradas pelo modelo possuem importância igual na previsão.

As principais vantagens da MMS são: sua fácil aplicação, já que podem ser aplicados em casos de número pequeno de observações e, são flexíveis devido à variação do número de observações consideradas. A dificuldade na determinação do número de observações consideradas pelo modelo pode ser vista como uma desvantagem. Este método é mais apropriado para a aplicação em séries que não apresentem nem tendência nem sazonalidade e para a obtenção de previsões de curto prazo.

2.2 Holt-Winters

Para Morettin e Toloi (2006), os métodos de médias móveis e suavização exponencial simples são adequados para séries que não apresentam tendência. Esses métodos são usados para estimar modelos de séries denominados de localmente constantes.

De acordo com eles, quando a série apresenta tendência ou sazonalidade o modelo da série localmente constante não é adequado. O método da suavização exponencial simples, por exemplo, tenderá a subestimar sempre as observações em uma série que apresenta apenas tendência. Os autores acrescentam que o método mais adequado para estimar um modelo para uma série que possui apenas tendência é o método de suavização exponencial de Holt. O método requer que duas constantes (α, β) sejam determinadas para realizar as previsões. Estimadas as constantes, utilizam-se as estimativas da tendência e o valor real da série em períodos anteriores para obter as previsões. Essas previsões são calculadas a partir das Equações (2) e (3).

$$\bar{Z}_t = \alpha Z_t + (1 - \alpha)(\bar{Z}_{t-1} + \hat{T}_{t-1}) \quad (2)$$

$$\hat{T} = \beta(Z_t - \bar{Z}_{t-1}) + (1 - \beta)\hat{T}_{t-1} \quad (3)$$

sendo Z_t o valor observado da série no período t , \bar{Z}_{t-1} o valor previsto no período anterior, e \hat{T}_t o valor previsto da componente de tendência da série.

Ainda de acordo com Morettin e Toloi (2006), se uma série apresenta sazonalidade o método de suavização de Holt não apresentará um bom desempenho nas previsões. Um método mais adequado para essas séries é a suavização exponencial geral de Holt-Winters. Esse método requer a estimação de três constantes (α, β, γ) para realizar as previsões. Um modelo para uma série desse tipo pode ser representada pelo modelo abaixo.

$$Z_t = \mu_t + T_t + S_t + a_t \quad (4)$$

$$S_t = \alpha(Z_t - \bar{Z}_t) + (1 - \alpha)\hat{S}_{t-s} \quad (5)$$

$$\bar{Z}_t = \beta(Z_t - S_{t-s}) + (1 - \beta)(Z_t - \hat{S}_{t-s}) \quad (6)$$

$$T_t = \gamma(\bar{Z}_t - \bar{Z}_{t-1}) + (1 - \gamma)\hat{T}_{t-1} \quad (7)$$

sendo S_t o valor da componente de sazonalidade no período t , e \hat{S}_{t-s} o valor dessa componente s períodos antes de t .

2.3 ARIMA

De acordo com Chatfield (1984), o modelo apresenta apenas componentes auto-regressivas quando apresenta a previsão do período atual como sendo uma combinação linear dos períodos anteriores, sendo o valor da série em cada período independente do ruído branco. Nesse modelo as previsões são determinadas pela Equação (8), considerando que há q componentes auto-regressivas, ou seja, um processo AR(q).

$$Z_t = \phi_1 Z_1 + \phi_2 Z_2 + \dots + \phi_p Z_p + a_t \quad (8)$$

onde Z_t é o valor previsto da série no período t , Z_i o i -ésimo período anterior a t , ϕ_i o peso atribuído ao valor da série no período i para determinação da previsão e a_t um choque aleatório no período t .

Gujarati (2006) compartilha a mesma ideia ao afirmar que um processo que apresenta apenas componentes auto-regressivas (AR) o valor Y da série em um período t depende de seu valor nos períodos anteriores e de um termo aleatório não correlacionado com média zero e variância constante (ruído branco), ou seja, o valor da série no período t é resultado da soma de proporções do valor da previsão em períodos anteriores somado a um distúrbio aleatório. Para esse autor, um processo que apresenta apenas componentes de médias móveis (MA), por sua vez, é resultante da

soma de uma média constante com médias móveis de termos de erro estocásticos de ruído branco. Sendo assim em um processo MA(p), as previsões são feitas a partir da Equação (9).

$$Z_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} + \dots + \theta_q a_{t-q} \quad (9)$$

sendo θ_i o peso atribuído ao choque aleatório no período i anterior para determinação da previsão.

Gujarati (2006) acrescenta ainda que um processo ARMA consiste naquele que possui tanto características de AR quanto de MA. Esses três tipos de processos estocásticos são adequados para o ajuste a séries temporais estacionárias. As previsões em um processo ARMA com q componentes autoregressivas e p componentes de médias móveis são feitas a partir da Equação (10).

$$Z_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} + \dots + \theta_q a_{t-q} + \phi_1 Z_1 + \phi_2 Z_2 + \dots + \phi_p Z_p \quad (10)$$

Chatfield (1984) afirma que os modelos mostrados anteriormente são adequados para séries estacionárias, ou que apresentam um média constante. Porém, na prática as séries geralmente não são estacionárias. Para tornar estacionária uma série desse tipo é requerido que sejam tomadas diferenças quantas vezes for necessário até que a estacionariedade seja atingida. Box *et al.* (1994) apresentam um modelo que toma como uma de suas bases essa diferenciação para obter previsões adequadas para séries não-estacionárias.

Os modelos ARIMA propostos pelos autores são adequados para previsões de séries não-estacionárias homogêneas. Uma série é considerada não-estacionária homogênea se for possível torná-la estacionária após um número finito de diferenças (d). Após tornar uma série não-estacionária em uma série estacionária por meio de d diferenças, obtém-se um modelo ARMA(p, q) para essa última. Têm-se p e q como as ordens de $\phi(X)$ e $\theta(X)$. As previsões são feitas nesse modelo com base na equação a seguir.

$$\phi(X)\Delta^d Z_t = \theta(X)a_t \quad (11)$$

sendo $\Delta^d Z_t$ uma diferença de Z_t , logo, Z_t é uma integral de $\Delta^d Z_t$. Desta forma, dizemos que Z_t é um modelo autoregressivo-integrado-médias móveis com d diferenças, ou seja, é um modelo ARIMA(p, d, q).

3 Modelo proposto

O modelo proposto para a previsão da demanda da empresa de móveis em questão consiste em três etapas principais. Inicialmente, é realizada a dessazonalização das séries temporais, após a verificação de existência ou não de sazonalidade nestas séries. Em seguida, aplica-se a MMS sobre os dados dessazonalizados. Por fim, o fator de sazonalidade é reaplicado nos valores previstos, obtendo assim a previsão. Estas etapas são detalhadas nas Subseções 3.1, 3.2. A Subseção 3.3 apresenta o método utilizado para a avaliação do desempenho do modelo.

3.1 Dessazonalização

A etapa de dessazonalização das séries temporais consiste em identificar e remover a componente sazonal das séries que apresentem sazonalidade. Desta forma, apenas a componente correspondente ao ruído aleatório estará presente no momento da aplicação da técnica de previsão escolhida, que visa justamente prever os valores futuros da componente aleatória.

Para identificar se a série apresenta sazonalidade ou não, foi utilizada a ferramenta *Atomium* desenvolvida pela empresa *MÖBIUS Business Redesign*. Tal ferramenta possui, entre outras funcionalidades, a capacidade de analisar e informar se uma determinada série temporal apresenta sazonalidade ou não.

A seguir é apresentada a formulação desenvolvida para a obtenção dos fatores de sazonalidade. Tal formulação foi obtida de maneira empírica.

A partir da identificação das séries sazonais, é necessário calcular os fatores de sazonalidade sobre o número de períodos que caracteriza um ciclo de sazonalidade. Este procedimento será realizado para cada série, com a finalidade de obter as séries dessazonalizadas.

Para a obtenção dos fatores de sazonalidade de cada série é preciso calcular, para cada período, a sua proporção em relação à média dos valores das s observações adjacentes ao período analisado (Equação (13)), ou seja, em relação à média dos valores do intervalo $[t - \lfloor s/2 \rfloor; t + \lfloor s/2 \rfloor - 1]$ de modo que:

$$M_t = \frac{\sum_{n=1}^s X_{(t+n-\lfloor s/2 \rfloor)}}{s}, t = 1, 2, 3, \dots, p \quad (12)$$

$$P_t = \frac{X_t}{M_t}, t = 1, 2, 3, \dots, p \quad (13)$$

onde s corresponde ao número de períodos que caracteriza um ciclo de sazonalidade, p o número de observações disponíveis e P_t o fator de proporcionalidade para cada instante t .

Em seguida, após a obtenção dos fatores de proporcionalidade P_t de cada observação, deve-se calcular a média destes fatores das observações, cujo período t esteja relacionado com o período do ciclo m do fator de sazonalidade a ser obtido, logo:

$$Y_m = \frac{\sum_{i=1}^a P_{s(i-1)+m}}{a}, m = 1, 2, 3, \dots, s \quad (14)$$

tal que a se refere ao número de ciclos disponíveis nos dados.

A partir da relação entre a média dos fatores de proporcionalidade relacionados com o período de ciclo analisado e a média de todos os fatores de proporcionalidade de cada série (Equação (15)), obtém-se, para cada período do ciclo, seu fator de sazonalidade (Equação (16)). Desta forma:

$$Z = \frac{\sum_{t=1}^p P_t}{p} \quad (15)$$

$$F_m = \frac{Y_m}{Z}, m = 1, 2, 3, \dots, s \quad (16)$$

Em seguida, de posse dos fatores de sazonalidade para cada série, elas são dessazonalizadas. Caso a série a ser dessazonalizada apresente uma sazonalidade própria, ela será dessazonalizada em função do seu próprio fator de sazonalidade, caso contrário, ela será dessazonalizada em função do fator de sazonalidade da série global. Os valores observados X_t da série global correspondem à soma dos valores X_t de todas as outras séries. A obtenção das séries dessazonalizadas será feito de acordo com a equação a seguir:

$$X_t^d = \frac{X_t}{F_m}, t = 1, 2, 3, \dots, p \quad (17)$$

onde X_t^d representam os valores dessazonalizados.

3.2 Aplicação do modelo de previsão proposto

Após as etapas de análise e tratamento dos dados e da obtenção das séries dessazonalizadas, foi decidida a utilização da técnica da MMS nas séries temporais dessazonalizadas para a obtenção dos valores previstos da demanda. Tal técnica foi escolhida, também, por sua baixa complexidade, fácil aplicação e entendimento e por ser indicada para a obtenção de previsões de curto prazo.

A aplicação da técnica da MMS nas séries dessazonalizadas se dá de acordo a equação a seguir:

$$X_{t+1}^d = \frac{\sum_{i=1}^n X_{(t-i+1)}^d}{n} \quad (18)$$

onde n corresponde ao número de observações passadas consideradas pelo modelo.

Após a aplicação do modelo de previsão baseado na MMS nas séries dessazonalizadas, deve-se então reaplicar os fatores de sazonalidade, calculados de acordo com a Equação (16). Essa ressazonalização será feita através da multiplicação deste fator pelo valor previsto, calculado através da MMS, obtendo assim o valor previsto final para o período $t + 1$, logo:

$$X_{t+1}^r = F_m X_{t+1}^d \quad (19)$$

3.3 Avaliação do desempenho

Para a análise do desempenho dos modelos empregados, foi utilizada uma abordagem baseada no desvio absoluto médio da previsão. O método empregado consiste em calcular o erro relativo, ou seja, o erro será calculado pela divisão do erro absoluto médio de n períodos, pela média dos valores observados nos mesmos n períodos, tal que:

$$e_t = \frac{\sum_{i=0}^{n-1} |X_{t-i} - \bar{X}_{t-i}|}{\sum_{i=0}^{n-1} X_{t-i}} \quad (20)$$

4 Resultados

Esta seção apresenta os resultados obtidos pela aplicação do modelo proposto apresentado na Seção 3, bem como os resultados da aplicação da MMS nos dados não dessazonalizados, do modelo Holt-Winters (sazonalidade aditiva e multiplicativa) e do modelo ARIMA (não-sazonal). Inicialmente é mostrada uma descrição dos dados considerados no estudo. Em seguida são apresentados os resultados obtidos, bem como uma análise dos mesmos.

4.1 Descrição dos dados

Os dados disponibilizados pela empresa objeto deste estudo, para a realização da previsão da demanda, corresponde ao histórico de pedidos dos diversos produtos, além de tabelas com as correspondências entre algumas informações. O histórico abrange os pedidos de janeiro de 2007 à agosto de 2012. Os dados são compostos por 26 tipos de informações para cada pedido. As informações contidas no arquivo disponibilizado são basicamente:

(1) O estado do pedido: se o pedido foi faturado ou não; (2) documento: número da fatura no caso de um pedido faturado; (3) datas: de criação, de faturamento e de entrega do pedido; (4) código: identificador do pedido; (5) tipo: tipo do pedido; (6) código vendedor: identificador do vendedor; (7) número do grupo: identificador do grupo ao qual pertence o cliente; (8) nome do grupo: nome do grupo ao qual pertence o cliente; (9) endereço: endereço de entrega do pedido; (10)

agência: agência onde o pedido foi efetuado; (11) produto: código, linha e descrição do produto; (12) quantidade: quantidade pedida; (13) valores: valor do pedido e da margem obtida; (14) código contábil: contém informações de onde o produto é fabricado.

Devido à grande quantidade de dados disponibilizados, aproximadamente 2860000 linhas de dados, se faz necessária a análise e o tratamento dos dados. A análise dos dados tem como função, além de fornecer uma visão geral da demanda, a identificação de informações importantes. Tais informações (por exemplo, o número de linhas de produtos, de centros de fabricação, de vendedores, o volume de negócios) auxiliarão na delimitação do perímetro das previsões e possibilitarão a eliminação ou contorno de possíveis anomalias encontradas no histórico da demanda. O tratamento dos dados consiste, principalmente, na agregação deste dados, de acordo com características em comum, formando assim, as séries temporais.

O tratamento dos dados permitiu o contorno de uma falta de dados, no período de janeiro à março de 2009, que foi previamente informada pela empresa, além da remoção dos chamados grandes projetos identificados pela empresa. Os grandes projetos se referem aos pedidos de valor mais elevados. Convencionalmente, são os pedidos feitos na região Île-de-France que ultrapassem 200 mil euros e os pedidos que ultrapassem 100 mil euros nas demais regiões. Estes pedidos, segundo a própria empresa, são imprevisíveis e devem ser removidos das séries temporais, de forma que apenas a demanda regular deve ser prevista.

Tabela 1: Volume de negócios e quantidade de pedidos por ano de criação do pedido

Data de criação do pedido	Volume de negócios (€)	Quantidade de pedidos
2007	91.194.470	463.718
2008	100.172.567	440.978
2009 *	92.819.272	412.279
2010	103.147.743	494.289
2011	114.504.828	498.126
2012 **	72.538.777	256.773
TOTAL	574.377.657	2.575.163

*Problema de dados nos primeiros meses.

**Dados até agosto.

De posse destas informações e através da análise destes dados, foi feito o agrupamento das informações, de modo que foram obtidas as séries temporais correspondentes às linhas de produtos, centros de fabricação, agência regional e direção regional.

Tabela 2: Informações sobre as séries temporais obtidas

Série temporal	Qtd. de séries	Nº períodos (t)	Nº ciclos (a)	Tamanho ciclo (s)	Intervalo entre observações
Linha de produto	33*	68	6	12 meses	1 mês
Centro fabricação	9	68	6	12 meses	1 mês
Agência regional	25**	68	6	12 meses	1 mês
Direção regional	5	68	6	12 meses	1 mês

*número de séries temporais consideradas no modelo, referente à 80% da demanda das linhas de produtos nos últimos 12 meses.

**número de séries temporais consideradas no modelo, correspondente às séries em que todos os modelos puderam ser aplicados.

Os valores das observações são expressos em termos do valor agrupado dos pedidos, em euros. As séries temporais compostas pelos pedidos agrupados por linhas de produto e por

centros de fabricação, consideram as datas de faturamento de pedido para a definição do período da observação, enquanto as outras séries baseiam-se nas datas de criação dos pedidos. O intervalo entre estas datas é de aproximadamente um mês.

4.2 Apresentação e análise dos resultados

Esta seção apresenta os resultados das previsões para as linhas de produtos, centros de fabricação, agências e direções regionais, obtidos através dos modelos: (1) Proposto, (2) MMS (ambos sobre 6 meses), (3) Holt-Winters (considerando sazonalidade aditiva e multiplicativa) e (4) ARIMA (não-sazonal). Os resultados modelos (1) e (2) foram obtidos pelo uso de uma ferramenta de apoio à decisão desenvolvida, em linguagem *Visual Basic for Applications* (VBA) para Microsoft Excel, especialmente desenvolvido para a empresa objeto deste estudo. Os modelos (3) e (4), por sua vez, foram aplicados com o auxílio do *software* estatístico *R project*, devido o fato de ser um *software* livre, que possui as funções necessárias para a aplicação destes modelos e que proporciona ótimos resultados.

As tabelas a seguir mostram os erros médios de previsão para cada modelo, assim como a comparação entre o modelo proposto e os demais modelos.

Tabela 3: Resultados por linha de produto

Linha de produto	Erro médio					Comparação				Melhor resultado
	MP	MMS	HWA	HWM	ARIMA	MP-MMS	MP-HWA	MP-HWM	MP-ARIMA	
LP1	8%	20%	10%	11%	10%	-12%	-2%	-3%	-2%	MP
LP2	25%	32%	17%	14%	22%	-7%	7%	11%	3%	HWM
LP3	28%	35%	33%	33%	36%	-7%	-5%	-4%	-8%	MP
LP4	11%	21%	13%	13%	16%	-10%	-2%	-2%	-5%	MP
LP5	14%	25%	17%	13%	15%	-11%	-3%	0%	-1%	HWM
LP6	10%	23%	13%	16%	13%	-13%	-3%	-5%	-2%	MP
LP7	14%	19%	20%	20%	21%	-5%	-7%	-7%	-7%	MP
LP8	13%	25%	14%	20%	15%	-12%	-2%	-7%	-3%	MP
LP9	58%	61%	85%	88%	>100%	-3%	-27%	-30%	-78%	MP
LP10	23%	27%	25%	30%	24%	-4%	-1%	-6%	0%	MP
LP11	14%	23%	18%	16%	17%	-9%	-4%	-3%	-3%	MP
LP12	15%	22%	17%	15%	17%	-7%	-2%	0%	-3%	MP
LP13	31%	38%	33%	35%	47%	-7%	-2%	-4%	-16%	MP
LP14	34%	37%	38%	46%	52%	-3%	-4%	-12%	-18%	MP
LP15	20%	29%	24%	25%	29%	-9%	-4%	-5%	-9%	MP
LP16	32%	34%	27%	27%	37%	-2%	6%	5%	-4%	HWA
LP17	40%	52%	>100%	95%	>100%	-12%	<-100%	-55%	-80%	MP
LP18	37%	43%	18%	18%	48%	-6%	19%	19%	-11%	HWM
LP19	27%	28%	27%	28%	>100%	-1%	0%	-1%	<-100%	HWA
LP20	56%	64%	72%	64%	98%	-8%	-16%	-9%	-43%	MP
LP21	11%	19%	15%	12%	17%	-8%	-4%	-1%	-6%	MP
LP22	12%	22%	15%	15%	19%	-10%	-3%	-3%	-6%	MP
LP23	26%	31%	28%	26%	33%	-5%	-2%	1%	-7%	HWM
LP24	15%	20%	18%	15%	16%	-5%	-3%	0%	-2%	MP
LP25	24%	33%	30%	31%	34%	-9%	-5%	-7%	-10%	MP
LP26	30%	36%	40%	37%	48%	-6%	-10%	-7%	-18%	MP
LP27	28%	33%	60%	85%	45%	-5%	-33%	-57%	-17%	MP
LP28	39%	38%	38%	43%	43%	1%	1%	-4%	-5%	MMS
LP29	37%	34%	44%	55%	43%	3%	-7%	-18%	-6%	MMS
LP30	47%	48%	60%	63%	71%	-1%	-13%	-16%	-24%	MP
LP31	8%	19%	11%	11%	11%	-11%	-2%	-2%	-2%	MP
LP32	32%	30%	40%	44%	39%	2%	-8%	-13%	-7%	MMS
LP33	31%	35%	39%	41%	40%	-4%	-8%	-10%	-9%	MP
TOTAL	5%	17%	7%	7%	7%	-12%	-1%	-2%	-1%	MP

A Tabela 3 mostra os resultados da aplicação dos modelos: Proposto (MP); MMS; Holt-Winters Aditivo (HWA) e Multiplicativo (HWM); e ARIMA. Os resultados são mostrados em termos do erro de previsão, para as 33 linhas de produtos mais importantes. Estas 33 linhas de produto correspondem a cerca de 80% da demanda total observada nos últimos 12 meses. É apresentado também os resultados para a série total, composta pela demanda agregada de todos os produtos.

Observa-se que das 33 linhas de produtos previstas, o modelo proposto obteve resultados superiores em 24 delas e na série total, onde o erro calculado foi de 5%. A diferença entre os resultados do melhor método e o segundo melhor, para cada série, varia, em geral, entre -5% e 5%. Nota-se também, que o erro médio dos melhores resultados variam entre 8% e 56%. Desta forma, o modelo proposto mostrou-se mais adequado para a previsão das linhas de produtos. Os modelos de Holt-Winters apresentaram resultados próximos aos do modelo proposto.



Figura 1: Resultados para a série total das linhas de produtos

A Figura 1 apresenta graficamente os resultados obtidos pela aplicação dos modelos na série total das linhas de produtos, sendo possível observar uma boa adequação dos modelos proposto, Holt-Winters (aditivo e multiplicativo) e ARIMA.

Tabela 4: Resultados por agência regional

Agência regional	Erro médio					Comparação				Melhor resultado
	MP	MMS	HWA	HWM	ARIMA	MP-MMS	MP-HWA	MP-HWM	MP-ARIMA	
A1	20%	34%	31%	31%	29%	-14%	-10%	-11%	-9%	MP
A2	30%	47%	49%	48%	53%	-16%	-19%	-18%	-22%	MP
A3	33%	45%	50%	52%	61%	-12%	-16%	-19%	-28%	MP
A4	24%	40%	32%	35%	33%	-16%	-9%	-11%	-9%	MP
A5	24%	39%	56%	53%	54%	-15%	-32%	-29%	-30%	MP
A6	50%	55%	85%	102%	68%	-6%	-35%	-52%	-18%	MP
A7	22%	37%	26%	28%	29%	-15%	-4%	-6%	-7%	MP
A8	40%	52%	41%	42%	49%	-12%	-1%	-2%	-9%	MP
A9	60%	59%	>100%	>100%	>100%	1%	<-100%	<-100%	<-100%	MMS
A10	44%	57%	70%	77%	72%	-13%	-26%	-33%	-28%	MP
A11	24%	41%	33%	34%	33%	-17%	-9%	-10%	-9%	MP
A12	21%	34%	33%	29%	31%	-13%	-12%	-8%	-11%	MP
A13	25%	39%	38%	42%	32%	-14%	-13%	-17%	-7%	MP
A14	26%	39%	32%	28%	33%	-14%	-7%	-2%	-7%	MP
A15	26%	49%	32%	33%	33%	-23%	-6%	-7%	-7%	MP
A16	26%	42%	49%	52%	54%	-16%	-23%	-26%	-28%	MP
A17	50%	56%	97%	77%	>100%	-6%	-47%	-27%	<-100%	MP
A18	67%	64%	>100%	>100%	>100%	3%	<-100%	<-100%	<-100%	MMS
A19	42%	51%	50%	70%	61%	-9%	-8%	-28%	-19%	MP
A20	49%	59%	>100%	>100%	>100%	-9%	<-100%	<-100%	<-100%	MP
A21	27%	42%	31%	32%	38%	-14%	-3%	-4%	-10%	MP
A22	24%	41%	66%	68%	51%	-17%	-42%	-44%	-27%	MP
A23	40%	49%	>100%	>100%	>100%	-9%	<-100%	<-100%	-86%	MP
A24	84%	90%	>100%	>100%	>100%	-7%	<-100%	<-100%	<-100%	MP
A25	60%	62%	69%	89%	67%	-2%	-9%	-29%	-7%	MP
TOTAL	7%	29%	11%	11%	11%	-22%	-4%	-4%	-4%	MP

Os resultados, para cada agência regional identificada, são apresentados na Tabela 4. Os

resultados mostram um melhor desempenho do modelo proposto em 23 das 25 agências regionais, além de um resultado melhor na série total. Analisando os melhores resultados é possível ver que para as agências regionais os resultados não são expressivos, porém, para a série total, que é naturalmente mais previsível, o resultado é bastante satisfatório, apresentando um erro de 7% é uma diferença razoável para os outros métodos. Considerando os outros modelos, percebem-se resultados equivalentes entre o modelo de Holt-Winters Aditivo e o modelo ARIMA.

Em seguida, na Tabela 5, são apresentados os resultados por centro de fabricação, 9 no total. Os resultados mostram que os modelos proposto e Holt-Winters aditivo obtiveram os melhores resultados em 5 e 4 oportunidades respectivamente. Apesar disto, percebe-se que os resultados obtidos por todos os métodos testados, com exceção da MMS, são bastante similares, variando, nestes casos, entre 6% e 9%.

Tabela 5: Resultados por centro de fabricação

Centro de fabricação	Erro médio					Comparação				Melhor resultado
	MP	MMS	HWA	HWM	ARIMA	MP-MMS	MP-HWA	MP-HWM	MP-ARIMA	
CF1	28%	33%	22%	24%	51%	-5%	5%	4%	-23%	HWA
CF2	8%	31%	7%	7%	10%	-23%	1%	1%	-2%	HWA
CF3	22%	33%	24%	29%	27%	-11%	-2%	-6%	-5%	MP
CF4	7%	30%	9%	10%	12%	-24%	-3%	-3%	-5%	MP
CF5	15%	35%	17%	17%	20%	-20%	-2%	-2%	-5%	MP
CF6	14%	31%	16%	16%	15%	-18%	-2%	-2%	-2%	MP
CF7	7%	31%	6%	6%	12%	-25%	1%	1%	-5%	HWA
CF8	13%	33%	11%	11%	16%	-20%	2%	2%	-3%	HWA
CF9	47%	51%	75%	81%	>100%	-3%	-28%	-33%	<-100%	MP
TOTAL	6%	29%	7%	7%	9%	-24%	-1%	-1%	-3%	MP

Por fim, os resultados por direção regional são apresentados na Tabela (6). O método proposto mais uma vez apresenta os melhores resultados. No geral, assim como nos resultados por centro de fabricação, os modelos proposto, Holt-Winters (aditivo e multiplicativo) e ARIMA mostraram resultados próximos.

Tabela 6: Resultados por direção regional

Direção regional	Erro médio					Comparação				Melhor resultado
	MP	MMS	HWA	HWM	ARIMA	MP-MMS	MP-HWA	MP-HWM	MP-ARIMA	
D1	57%	62%	80%	81%	73%	-4%	-23%	-24%	-15%	MP
D2	12%	31%	16%	17%	16%	-19%	-4%	-5%	-3%	MP
D3	16%	37%	22%	23%	24%	-21%	-6%	-7%	-8%	MP
D4	14%	34%	13%	13%	17%	-20%	0%	0%	-3%	HWM
D5	12%	30%	13%	13%	14%	-18%	-1%	-1%	-2%	MP
TOTAL	7%	29%	9%	9%	11%	-22%	-2%	-2%	-4%	MP

5 Conclusões e trabalhos futuros

Este trabalho tratou do problema de previsão da demanda (PD), por meio da proposição de uma técnica de previsão de séries temporais, aplicada ao caso de uma indústria fabricante de móveis para escritórios. A combinação de um tratamento prévio dos dados, da dessazonalização das séries temporais e utilização de princípios da MMS, etapas que caracterizam o modelo proposto, mostrou resultados eficientes, para o caso analisado, quando comparados com alguns métodos da literatura.

Os resultados obtidos pelo modelo de PD proposto, que incluem uma etapa de dessazonalização, quando comparados com aqueles obtidos pela aplicação direta da MMS, evidenciam a contribuição da dessazonalização no processo de PD realizado. Por outro lado, quando comparado com os modelos de Holt-Winters e ARIMA, os resultados, apesar de melhores, permanecem próximos aos destes modelos. De forma global, os resultados por centro de fabricação, que servirão para direcionar a produção da empresa, são, assim como os resultados por direção regional, que permitirão um planejamento comercial de médio prazo, satisfatórios quando aplicado o método proposto.

Como trabalho futuro, sugere-se uma maior investigação do método proposto, com a finalidade de identificar suas vantagens, desvantagens e situações em que sua aplicação é adequada. Sugere-se ainda a aplicação do método a outros casos e uma generalização do mesmo.

Referências

- Adebanjo, D.** (2009), Understanding demand management challenges in intermediary food trading: a case study. *Supply Chain Management: An International Journal*, v. 14, n. 3, p. 224–233.
- Bowersox, D., Coloss, D. e Cooper, M.** *Gestão da cadeia de suprimentos e logística*. Elsevier, Rio de Janeiro, 2007.
- Box, G., Jenkins, G. e Reinsel, G.** *Time series analysis: forecasting and control*. Forecasting and Control Series. Prentice Hall, 1994.
- Brockwell, P. e Davis, R.** *Introduction to Time Series and Forecasting*. Springer Texts in Statistics. Springer, 2002.
- Burger, C., Dohnal, M., Kathrada, M. e Law, R.** (2001), A practitioners guide to time-series methods for tourism demand forecasting - a case study of durban, south africa. *Tourism Management*, v. 22, n. 4, p. 403–409.
- Chatfield, C.** *The analysis of time series: an introduction*. Chapman & Hall, 1984.
- Cordeau, J. F.** La prévision de la demande. Notas de Aula. URL <http://zonecours.hec.ca/documents/H2010-1-2307617.article-prevision.pdf>, 2007.
- Cryer, J. D. e Chan, K.-S.** *Time Series Analysis With Applications in R*. Springer, 2008.
- Fogliatto, F. S., Ribeiro, J. L. D., Werner, L., de Oliveira Lemos, F. e de Brum, M. P.** Previsão de demanda por energia elétrica - método e aplicação. *Anais do XXV ENEGEP, Porto Alegre, RS*, 2005.
- Gorini, A.** (2000), A indústria de móveis no brasil. *Leitura Moveleira*, v. 2.
- Gujarati, D.** *Econometria Basica*. Elsevier, 2006.
- Moreira, D.** *Administração da produção e operações*. Pioneira, Sao Paulo, 1996.
- Morettin, P. e Toloi, C.** *Análise de séries temporais*. ABE - Projeto Fisher. Edgard Blucher, 2006.
- Noble, G. D.** Application of modern principles to demand forecasting for eletrronics, domestic appliances and accessories. Master of science, Departament of Biomedical, Industrial, and Human Factors Engineering, Wright State University, 2009.
- Pacheco, R. F. e Silva, A. V. F.** Aplicação de modelos quantitativos de previsão em uma empresa de transporte ferroviário. *Anais do XXIII ENEGEP, Ouro Preto, MG*, 2003.
- Santiago, F. S., de Mattos, R. S. e Perobelli, F. S.** (2011), Um modelo integrado econométrico+insumo-produto para previsão de longo prazo da demanda de combustíveis no brasil. *Nova economia*, v. 21, n. 3, p. 423 – 455.