



## Implementação de um Modelo de Previsão de Demanda em uma Empresa de Varejo da Serra Gaúcha

Lucas Tartarotti, Gabriel Vidor

### RESUMO

A previsão da demanda impacta em diferentes níveis do processo de planejamento e controle da produção. Neste sentido, buscou-se como objetivo implementar um modelo de previsão de demanda, baseado em séries temporais, em um ambiente de serviço. Identificou-se na empresa estudada uma previsão de demanda errônea. A partir da aquisição dos dados junto a empresa e posterior tratamento dos mesmos, testaram-se previsões com modelos de suavização exponencial e modelos ARIMA. Por meio de indicadores de acuracidade, os modelos de suavização exponencial apresentaram o melhor desempenho de previsão. Como resultado, observou-se que a curva da demanda organizacional segue uma tendência similar ano após ano, porém a curva do período mais recente está alocada acima no gráfico, indicando o crescimento da demanda. A relevância do estudo é decorrente das vantagens que um modelo de previsão de demanda proporcionam as organizações, como gestão mais eficiente do fluxo de caixa, gerenciamento do estoque, alocação dos recursos humanos, diminuição de custos e desperdícios, definição de investimentos, melhor atendimento ao cliente, entre outros benefícios.

**Palavras-Chave:** previsão de demanda, modelos de suavização exponencial, modelos ARIMA.

### 1 INTRODUÇÃO

Demanda é a disposição dos clientes ao consumo de determinados produtos ou serviços. A disponibilidade do bem ou serviço e o respectivo preço são apenas alguns dos fatores que influenciam a demanda (LUSTOSA *et al.*, 2008). A previsão de demanda permite reduzir a diferença entre a necessidade e disponibilidade de estoque, reduzindo assim custos e desperdícios (CRISOSTOMO *et al.*, 2016). Em encontro a isto, Ballou (2006) afirma que a previsão da demanda impacta em diferentes níveis do processo de planejamento e controle da produção, tais como controle de estoque, custos e tempo de resposta. Assim, as organizações empresariais devem prever e gerenciar a demanda, pois esta é a base do planejamento estratégico da produção (COUTO *et al.*, 2016).

A previsão da demanda identifica fatores que influenciam diretamente as vendas (BALLOU, 2006). Existem a disposição diversos métodos de previsão de demanda, conforme as necessidades específicas de cada organização. Pellegrini e Fogliatto (2001) dividem esses métodos de previsão como qualitativos e quantitativos. A previsão qualitativa está baseada no julgamento, na intuição, em pesquisas e técnicas de comparação para projetar a demanda (BALLOU, 2006). Por sua vez, os métodos quantitativos utilizam modelos matemáticos e estatísticos para prever a demanda (COUTO *et al.*, 2016).

A escolha do modelo de previsão deve considerar o potencial de acuracidade, assim como o horizonte de tempo das previsões. Observa-se que o nível de sofisticação quantitativa e a base de dados disponível são parâmetros importantes para a definição do modelo (BALLOU, 2006). Referente ao horizonte de tempo, Davis *et al.* (2001) citam que as previsões de longo prazo detectam, geralmente, as tendências. Estes modelos são úteis principalmente na identificação de pontos críticos. Já os modelos de médio prazo identificam



os efeitos sazonais. Por fim, as previsões de curto prazo contemplam as variações aleatórias, ajustando-se principalmente as mudanças no curto espaço de tempo.

Dessa forma, trabalhos de previsão de demanda permitem as organizações o entendimento acurado do comportamento de compra do seu cliente. Portanto, esse trabalho tem o objetivo de implementar um modelo de previsão de demanda, baseado em séries temporais, em um ambiente de serviço. Efetivamente espera-se avaliar o comportamento de vendas em uma loja que comercializa acessórios para o mercado de motociclistas.

## 2. MODELOS DE PREVISÃO

### 2.1 MODELOS DE SUAVIZAÇÃO EXPONENCIAL

Os modelos de suavização exponencial para previsão de demanda têm por características a simplicidade, facilidade de ajuste e grau de precisão adequado. Esta metodologia utiliza uma ponderação diferente para cada valor observado na série temporal, de modo que valores mais recentes recebam pesos maiores. Deste modo, a ponderação decai exponencialmente a partir de valores mais recentes (PELLEGRINI e FOGLIATTO, 2001). Apresentam-se diferentes modelos de suavização exponencial:

#### 2.1.1 Suavização Exponencial para um Processo Constante

Conforme Elsayed e Boucher (1994), em caso da série temporal manter-se constante sobre um nível médio, uma suavização exponencial simples é suficiente para a previsão de valores futuros da série. Apresenta-se a seguir sua representação matemática:

$$\hat{Z}_{t+1} = AZ_t + (1 - A) \hat{Z}_t$$

Nesta fórmula,  $Z_{t+1}$  é a previsão da demanda para o tempo  $t + 1$  realizada no período atual  $t$ ; "A" representa a constante de suavização, assumindo valores entre 0 e 1;  $Z_t$  é o valor observado na série temporal para o tempo  $t$ ;  $\hat{Z}_t$  é o valor da previsão feita para o tempo  $t$ . Um método para medir a precisão da previsão é calcular o erro, através da fórmula a seguir:

$$E_t = Z_t - \hat{Z}_t$$

De acordo com Montgomery *et al.* (1990), o valor da constante de suavização  $\infty$  é arbitrário; a determinação de seu melhor valor pode ser feita utilizando alguma forma de comparação, como a média do quadrado dos erros, MQE. Assim, seleciona-se aleatoriamente um valor inicial para a constante, a partir do qual as previsões serão geradas. Comparam-se os valores previstos com os reais, e então, calcula-se a média do quadrado das diferenças entre os mesmos; o parâmetro que minimiza essa média é utilizado no modelo final. Pacotes computacionais determinam automaticamente o melhor valor de "A". A magnitude da constante a determina a velocidade de resposta do modelo frente a mudanças na demanda. Baixos valores de "A" fazem com que o modelo demore a assumir mudanças no comportamento da série. Em contrapartida, com altos valores de "A" o modelo reage rapidamente. Observa-se que os modelos de suavização exponencial simples requerem uma estimativa inicial para  $\hat{Z}_t$ . Se os dados históricos estão disponíveis, pode-se usar uma média simples das  $N$  observações mais recentes como  $\hat{Z}_t$ . Caso contrário, pode-se utilizar a última observação, ou fazer uma estimativa subjetiva (PELLEGRINI e FOGLIATTO, 2001).



### 2.1.2 Modelo de Holt

Segundo Armstrong (1999), o modelo de Holt é adequado para séries temporais com tendência linear. Este modelo utiliza duas constantes de suavização, A e B (com valores entre 0 e 1), sendo representado por três equações:

- 1)  $L_t = Az_t + (1 - a)(L_{t-1} + T_{t-1})$
- 2)  $T_t = B(L_t - L_{t-1}) + (1 - B)T_{t-1}$
- 3)  $\hat{Z}_{t+k} = L_t + kT_t$

As equações 1 e 2 fazem uma estimativa do nível e da inclinação da série temporal, respectivamente. Já a equação 3 calcula a previsão da demanda para os próximos k períodos.

Assim como na suavização exponencial simples, o modelo de Holt requer valores iniciais, neste caso  $L_0$  e  $T_0$ . Uma alternativa para estes cálculos iniciais é igualar  $L_0$  ao último valor observado na série temporal e calcular uma média da declividade nas últimas observações para  $T_0$ . Outra maneira de calcular é a regressão linear simples aplicada aos dados da série temporal, onde se obtém o valor da declividade da série temporal e de  $L_0$  em sua origem. Os valores das constantes de suavização no modelo de Holt podem ser determinados de forma semelhante a utilizada na suavização exponencial simples; ou seja, uma combinação de valores para A e B que minimize a MQE (PELLEGRINI e FOGLIATTO, 2001).

### 2.1.3 Modelos de Winters

Os modelos de Winters descrevem dados de demanda que apresentam ocorrência de tendência linear, além de um componente de sazonalidade. Dados de demanda sazonal caracterizam-se pela ocorrência de padrões cíclicos de variação, que se repetem em intervalos relativamente constantes de tempo. A demanda sazonal pode ser observada em alguns ramos da indústria alimentícia, de cosméticos, de serviços, entre outros (PELLEGRINI e FOGLIATTO, 2001). Estes modelos de previsão dividem-se em dois grupos: aditivo e multiplicativo. No modelo aditivo, a amplitude da variação sazonal é constante ao longo do tempo. Em contrapartida, no modelo multiplicativo, a amplitude da variação sazonal aumenta ou diminui em função do tempo.

Segundo Fuller (1996), o modelo multiplicativo de Winters é utilizado na modelagem de dados sazonais, em que a amplitude do ciclo sazonal varia com o passar do tempo. Sua representação matemática:

- 4)  $L_t = A \frac{Z_t}{S_{T-s}} + (1 - A)(L_{T-1} + T_{T-1})$
- 5)  $T_t = B(L_t - L_{t-1}) + (1 - B)T_{t-1}$
- 6)  $S_T = Y \frac{Z_t}{L_t} + (1 - Y)S_{t-s}$
- 7)  $\hat{Z}_{t+k} = (L_t + kT_t)S_{t-s+k}$

Onde s é uma estação completa da sazonalidade (por exemplo, s é igual a 12 quando se tem dados mensais e sazonalidade anual);  $L_t$ ,  $T_t$ ,  $S_t$  representam o nível, a tendência e a sazonalidade da série, respectivamente.  $Z_{t+k}$  é a previsão para k períodos a frente, enquanto que y é a constante de suavização que controla o peso relativo a sazonalidade, variando entre



0 e 1. A equação 4 difere da equação que trata do nível da série no modelo de Holt, já que o primeiro termo é dividido por um componente sazonal, eliminando assim a flutuação sazonal de  $Z_t$ . Por sua vez, a equação 5 é exatamente igual à equação da tendência no método de Holt. Já a equação 6 faz um ajuste sazonal nas observações de  $Z_t$  (PELLEGRINI e FOGLIATTO, 2001).

Os modelos de Winters necessitam valores iniciais de componentes (neste caso, nível, tendência e sazonalidade) para dar início aos cálculos. Para a estimativa do componente sazonal, necessita-se de no mínimo uma estação completa de observações, ou seja,  $S$  períodos. As estimativas iniciais do nível e da tendência são feitas, então, no período  $S$  definido para o componente sazonal. Estimadores dos componentes nas equações 4 a 7 podem ser encontrados em Winters (1960), Johnson e Montgomery (1974), Hamilton (1994) e Elsayed e Boucher (1994). Os valores das constantes de suavização seguem a mesma lógica de determinação sugerida para os outros métodos de suavização exponencial.

Conforme Makridakis *et al.* (1998), o modelo aditivo de Winters é utilizado na modelagem de dados sazonais onde a amplitude do ciclo sazonal permanece constante com o passar do tempo. Suas equações matemáticas são:

$$8) L_t = A (Z_t - S_t - s) + (1 - A) (L_{t-1} + T_{t-1})$$

$$9) T_t = B (L_t - L_{t-1}) + (1 - B) T_{t-1}$$

$$10) S_t = Y (Z_t - L_t) + (1 - Y) S_{t-s}$$

$$11) \hat{Z}_t + k = L_t + kT_t + S_{t-s} + k$$

A equação da tendência permanece a mesma utilizada para o modelo multiplicativo (equação 5). Nas demais equações, a única diferença é que o componente sazonal está efetuando operações de soma e subtração, em vez de multiplicar e dividir.

## 2.2 MODELOS AUTOREGRESSIVOS INTEGRADOS A MÉDIA MÓVEL - MODELOS ARIMA

Os Modelos Autoregressivos Integrados a Média Móvel, ou simplesmente ARIMA (*Autoregressive Integrated Moving Average*), foram propostos por George Box e Gwilym Jenkins no início dos anos 70 (BOX *et al.*, 1994). Os modelos de Box-Jenkins partem da idéia de que os valores de uma série temporal são altamente dependentes, ou seja, cada valor pode ser explicado por valores prévios da série. Conforme Ross (1993), um processo estocástico é caracterizado por uma família de variáveis aleatórias que descrevem a evolução de algum fenômeno de interesse. Uma importante classe de modelos estocásticos utilizados na representação de séries temporais são os modelos estacionários, que pressupõem um processo sob equilíbrio, onde a família de variáveis se mantém a um nível constante médio.

Muitas séries temporais são melhores representadas por modelos não-estacionários. Séries estacionárias variam de maneira estável no tempo, sobre um valor de média fixo. Entretanto, uma série temporal não-estacionária não se desloca no tempo sobre uma média fixa. Já em uma série de ruído aleatório, as diferenças entre as observações e a média são estatisticamente independentes, seguindo alguma distribuição de probabilidade. A propriedade chave em uma série de ruído aleatório é que a ordem na qual as observações ocorrem não informa nada a respeito da série. Assim, valores passados da série não podem ser utilizados na previsão de valores futuros (BOX E LUCENO, 1997).

Em séries estacionárias, mas que apresentam ruídos autocorrelacionados, diferenças entre observações e a média não são estatisticamente independentes entre si. Dependência



estatística implica na probabilidade de uma diferença qualquer ser influenciada pela magnitude das demais diferenças na série. As variações não-estacionárias são encontradas com frequência em aplicações na indústria, bem como em estudos de economia e negócios (PELLEGRINI e FOGLIATTO, 2001).

Um modelo estocástico útil na representação de um grande número de séries temporais é o modelo autoregressivo. Neste modelo, o valor corrente do processo é expresso como uma combinação linear finita de valores prévios do processo e um ruído aleatório. Processos autoregressivos podem ser estacionários ou não-estacionários (BOX *et al.*, 1994). Algumas vezes, séries temporais são melhores modeladas com a inclusão de termos autoregressivos e de média móvel. Assim, caracteriza-se os modelos de média-móvel e modelos mistos autoregressivos– média-móvel.

Muitas séries temporais não possuem média constante. Isto significa que, em nenhum dado intervalo de tempo, as observações da série se comportam como as observações de um intervalo de tempo distinto. Tais séries são chamadas de não-estacionárias na média. Da mesma forma, é possível uma série temporal exibir não estacionariedade na média e na declividade. Séries temporais não-estacionárias podem apresentar, independente da média local (ou média e declividade locais), um comportamento geral homogêneo, com a ocorrência de tendências que se repetem (PELLEGRINI e FOGLIATTO, 2001).

### 3 MATERIAIS E MÉTODOS

O procedimento de previsão de demanda foi aplicado em uma loja de varejo especializada em produtos para motociclistas. Esta loja está localizada na Serra Gaúcha e tem por característica ser uma microempresa familiar. A demanda da empresa apresenta sazonalidade, variando de acordo com as estações. O inverno, por exemplo, é o período em que as vendas atingem o ápice, tendo em vista a necessidade dos motociclistas de proteção térmica. A empresa ainda não possui um sistema de previsão de demanda, o que ocasiona inúmeras falhas e atrasos no atendimento ao cliente. Assim, apresentam-se a seguir as etapas para implementação do modelo de previsão de demanda.

#### 3.1 DEFINIÇÃO DO PROBLEMA

O estudo de caso parte do contexto e necessidades da empresa estudada, porém tem como objetivo utilizar um modelo de previsão aplicável em outros contextos. A empresa estudada não apresenta metodologia de previsão de demanda. Os produtos são adquiridos pelo instinto e experiência dos proprietários. Porém, nem sempre as previsões estão de acordo com o que acontece na prática, ocasionado diversos problemas como falta de estoque e desperdícios. A partir disto, definiu-se o procedimento de previsão de demanda a ser implantado. O período de previsão definido é semanal, para melhor adequação com a realidade da empresa.

#### 3.2 OBJETIVOS

O objetivo da implementação do modelo de previsão de demanda é auxiliar a organização a diminuir as perdas, melhorar a gestão do estoque, reduzir o risco nos processos decisórios, auxiliar na alocação dos recursos organizacionais e na definição de investimentos, melhorar o desempenho do setor de compras e definir indicadores para a área comercial da empresa.



### 3.3 AQUISIÇÃO E TRATAMENTO DOS DADOS

A aquisição dos dados foi realizada através de um relatório do faturamento semanal, no período de janeiro de 2015 até dezembro de 2016. Este relatório foi disponibilizado pelo proprietário da organização para desenvolvimento e aplicação prática do modelo de previsão de demanda na organização. Os dados presentes no relatório foram transcritos para uma planilha, sendo esta a base para a utilização do software.

### 3.4 DEFINIÇÃO E APLICAÇÃO DE MÉTODOS QUANTITATIVOS

A partir da análise dos dados, testaram-se previsões com modelos de suavização exponencial e modelos ARIMA. Como a definição do melhor método quantitativo provém da análise dos erros de previsão, a base de dados utilizada corresponde aos anos de 2015 e 2016, para previsões de janeiro de 2017 até dezembro de 2017.

### 3.5 MONITORAMENTO

Após a implementação do sistema de previsão de demanda na empresa, a metodologia permanece a mesma, o monitoramento deverá ser realizado pelas mesmas medidas estipuladas.

### 3.6 INDICADORES DE ACURACIDADE

Quando se trata da utilização de métodos quantitativos de previsão, deve-se mensurar o desempenho das modelagens, com o intuito de identificar quão acurada é esta previsão. A precisão da previsão refere-se ao quão perto as previsões chegam da realidade dos dados. Os indicadores de acuracidade são utilizados para verificar o nível de precisão que o modelo de previsão possui. Previsões muito próximas dos dados reais representam erros de precisão baixos. Quando os erros de precisão são maiores é sinal que o modelo de previsão deve ser alterado ou ajustado. Apresentam-se a seguir os indicadores de acuracidade utilizados no método de estudo:

- a) erro percentual absoluto médio – MAPE: o erro percentual absoluto médio é a média de todos os erros absolutos percentuais, fornecendo uma indicação do tamanho médio do erro, expresso como uma porcentagem do valor observado, independentemente do erro ser positivo ou negativo. O MAPE (*mean absolute percentage error*) é considerado como uma das medidas de erro mais usadas para se avaliar os métodos de previsão (LEWIS, 1997). O erro percentual absoluto médio pode ser calculado mediante a utilização da equação:  $MAPE = \sum[(A(t) - F(t)) / A(t)] / N$   
Onde  $A(t)$  = demanda real no período;  $F(t)$  = previsão para o período  $t$ ;  $N$  = números de períodos de previsão  $t$ .
- b) erro do quadrado médio da raiz – RMSE: de acordo com Barnston (1992), o RMSE (*Root Mean Square Error*) é o desvio padrão dos resíduos (erros de predição). Os resíduos são uma medida de quão longe estão os pontos de dados da linha de regressão. O RMSE é uma medida de como se espalham esses resíduos. Em outras palavras, ele diz como a concentração dos dados está em



torno da linha de melhor ajuste. O erro quadrático médio da raiz é comumente usado na climatologia, previsão e análise de regressão para verificar os resultados experimentais. O RMSE pode ser representado pela fórmula a seguir:

$$\text{RMSE}_{f0} = \left[ \sum_{i=1}^N (Z_{fi} - Z_{oi})^2 / N \right]^{1/2}$$

Onde  $\Sigma$  = soma; N = tamanho da amostra;  $(Z_{fi} - Z_{oi})^2$  = diferenças ao quadrado.

- c) erro absoluto médio – MAE: O MAE (*Mean Absolute Error*) ou Erro Absoluto Médio (EAM) é a soma dos desvios absolutos dos n períodos dividida pelo número de períodos. Assim, quanto menor for o valor do erro absoluto médio, mais próximo o valor estimado é do valor observado. O MAE pode ser representado pela fórmula a seguir:

$$\frac{\sum_{i=1}^n |X - \hat{X}_i|}{n}$$

de acordo com Mentzer e Bienstock (1998), o MAE mede o afastamento médio das previsões em relação aos valores reais, constituindo na média dos erros da previsão. Assim, seu valor ideal seria igual a zero. O erro médio tende a ser baixo na medida em que os erros negativos e positivos se compensem.

## 4 RESULTADOS

Apresenta-se a seguir a descrição do estudo de caso da empresa Ditesta & Daihead, a análise dos resultados da previsão de demanda realizada e as aplicações gerenciais propostas para a organização com base na demanda prevista.

### 4.1 DESCRIÇÃO DO ESTUDO DE CASO

Os métodos de previsão de demanda foram aplicados a partir de um estudo de caso com a empresa Ditesta & Daihead. A Ditesta & Daihead foi fundada em 1990, em Caxias do Sul. Originalmente a empresa se chamava apenas Ditesta e atuava somente com peças de moda casual. Com o passar do tempo, percebeu-se a oportunidade de criar equipamentos de segurança para a prática do motociclismo. Atualmente, a Ditesta & Daihead atende o mercado de motociclismo, esportes, viagens e aventuras, além da moda casual. Os principais produtos da loja são jaquetas de couro e cordura para motociclismo e moda casual, calças de couro e cordura, macacões sob medida, protetor de coluna, segunda pele, raspadores, camisas dry, conjuntos térmicos, capacetes, calçados para motociclistas e casuais. Atualmente, a empresa conta com loja virtual, loja física e está presente em grandes lojas e *marketplaces* do Brasil.

Os três proprietários da empresa Ditesta & Daihead realizam a gestão e operação de toda a loja. O proprietário fundador é o responsável pela parte de compras de produtos e insumos, busca de fornecedores e lançamento de novos produtos. Este exerce suas funções com base na experiência adquirida nos inúmeros anos de trabalho neste ramo de negócio. Alguns produtos são adquiridos e revendidos, porém outros após a criação do projeto, são encaminhados para a fabricação terceirizada. O segundo proprietário é responsável pelo



financeiro, marketing e gestão, tanto da loja física, como das vendas pela internet. Este proprietário é bacharel em economia. A terceira é uma proprietária, sendo responsável pelo atendimento dos clientes, organização da loja, armazenamento e exposição dos produtos. Ela faz um curso superior em Psicologia. Pode-se perceber que as diferentes áreas de conhecimento dos proprietários se relacionam de forma harmoniosa. A Ditesta & Daihead é uma microempresa familiar. A empresa abriu sua loja física em dezembro de 2014, localizada em Caxias do Sul. Anteriormente a Ditesta & Daihead operava somente através da internet (loja virtual, mercado livre, etc).

A empresa não possui nenhuma técnica quantitativa de previsão da demanda. A previsão da demanda é realizada pelos proprietários de forma qualitativa, baseada nas suas experiências e observações do mercado. Porém, conforme relatado pelos próprios proprietários, a previsão realizada nem sempre é precisa. Conforme relatado, muitos produtos estão em estoque a algum tempo, sem previsão de demanda. Em contrapartida, corriqueiramente, a demanda de certos produtos não é atendida no prazo esperado, tendo em vista a falta de estoque, principalmente no período de alta demanda (inverno). A imprecisão da previsão da demanda, segundo os proprietários, acarreta em prejuízos significativos, principalmente referente a falta de estoque. Este fato motivou a presente pesquisa, buscando-se resultados que contribuam de forma teórica para a comunidade acadêmica e de forma prática para os proprietários da empresa Ditesta & Daihead.

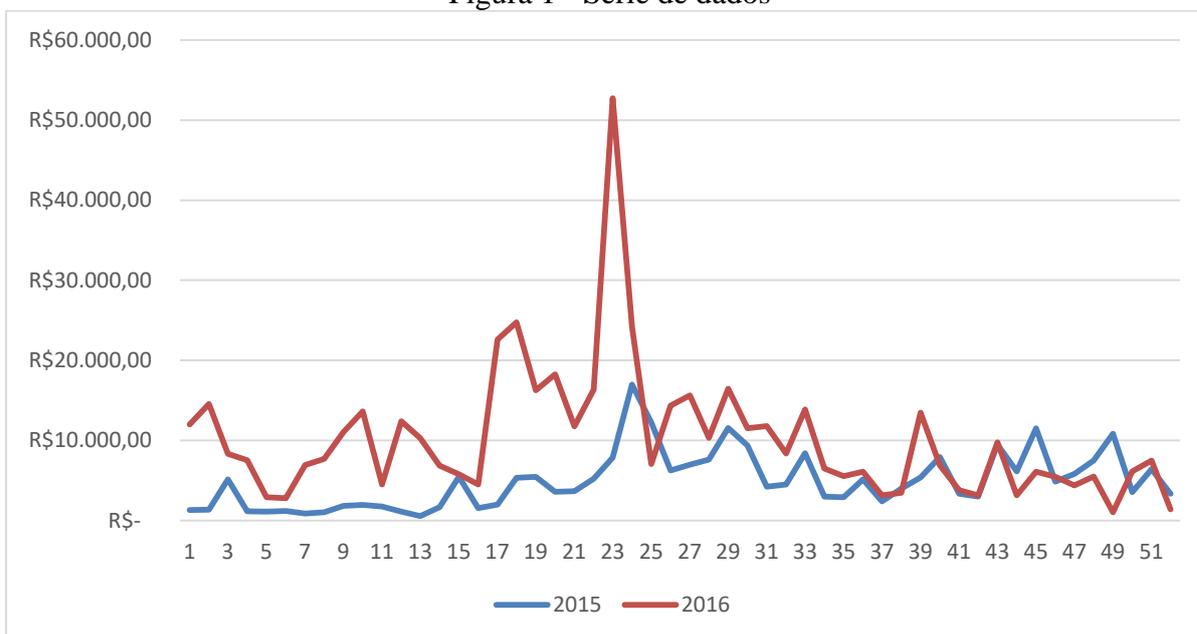
Os dados históricos das vendas são armazenados pela empresa de forma manual. As vendas, diariamente, são inseridas em planilhas eletrônicas no término do expediente. Nas planilhas constam o nome dos clientes com seus dados pessoais (data de nascimento, cidade, etc), contato (telefone, e-mail, etc), produtos adquiridos, a data e local da venda (loja física, virtual, etc) faturamento bruto e líquido, entre outras informações. Com base nesta planilha, foram extraídas as informações sobre as vendas e faturamento que possibilitaram a aplicação dos métodos de previsão de demanda. A previsão de demanda realizada no estudo é semanal, por ser o período de tempo mais apropriado para a necessidade da empresa.

## 4.2 ANÁLISE DOS RESULTADOS

O histórico de vendas da empresa Ditesta & Daihead, dos anos de 2015 e 2016, formaram a base de dados para a previsão de demanda realizada. Na planilha original, o faturamento estava organizado de forma mensal. Entretanto, conforme a necessidade de previsão da empresa, reorganizou-se o faturamento semanalmente. Assim, conforme o gráfico a seguir, demonstra-se o faturamento semanal dos anos de 2015 e 2016:



Figura 1 - Série de dados



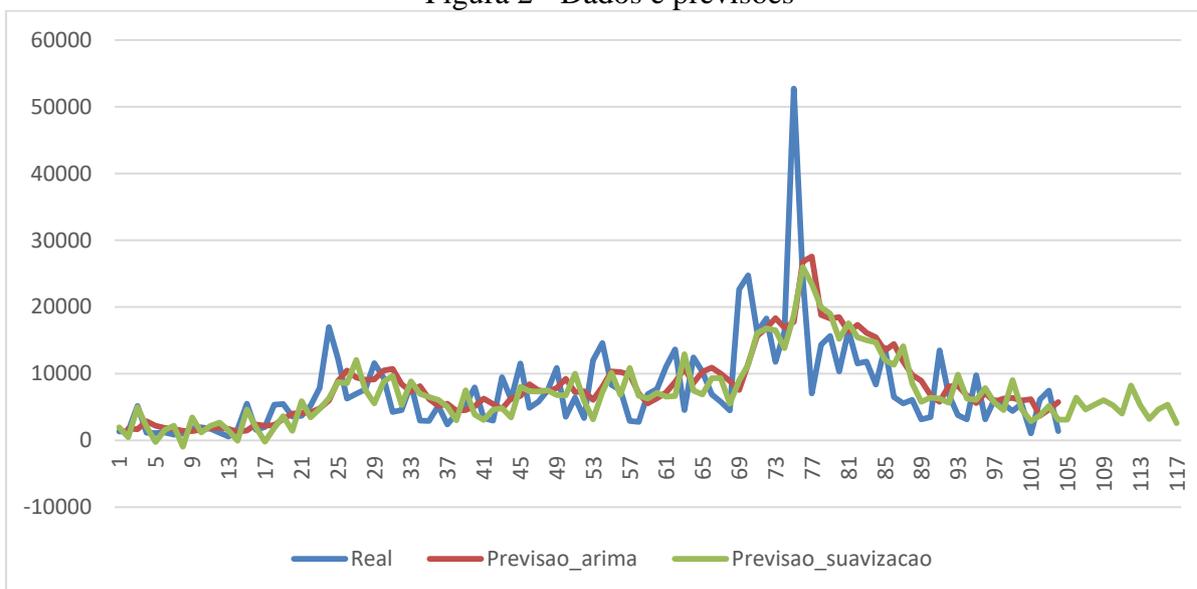
Fonte: Elaborado pelos autores (2017)

Analisando a figura anterior, pode-se notar que as frequências das linhas são semelhantes, ou seja, o comportamento semanal das vendas do ano de 2015 e 2016 são similares. Em ambos os anos, o pico do faturamento ocorreu entre as semanas 23 e 24, por exemplo. Porém, nota-se que a linha do faturamento de 2016 está alocada acima no gráfico, em comparação com a linha de 2015. Isto demonstra que o faturamento total de 2016 foi superior ao de 2015. O faturamento da empresa, apesar de seguir uma tendência similar ano após ano, está aumentando. Esta é uma informação relevante para a organização, pois oferece uma boa perspectiva futura para a empresa.

A partir do estudo de caso da empresa Ditesta & Daihead, optou-se pela aplicação de duas metodologias de previsão da demanda: a suavização exponencial e os modelos autoregressivos integrados a média móvel, ou simplesmente, modelos ARIMA. O gráfico a seguir demonstra as projeções das duas metodologias em comparação com os dados reais observados:



Figura 2 - Dados e previsões



Fonte: Elaborado pelos autores (2017)

Após o teste das duas metodologias com base nos indicadores de acuracidade, verificou-se que o método de suavização exponencial era o mais adequado para este caso.

## 5 CONSIDERAÇÕES FINAIS

A partir da análise dos resultados foi possível propor aplicações gerenciais práticas, a fim de contribuir para o planejamento da empresa estudada. Na área financeira, os resultados da pesquisa possibilitam uma gestão mais eficiente do fluxo de caixa. Se analisarmos a previsão da demanda, entre as semanas 23 e 24 espera-se um faturamento significativo. Com esta previsão em mãos, os gestores podem buscar alocar seus gastos e despesas para cobrança neste período, o que não prejudicaria o fluxo de caixa da empresa. Em contrapartida, com base na previsão, um cuidado que deve ser tomado é a reserva de recursos financeiros para as primeiras e as últimas semanas do ano, tendo em vista que estes são os períodos em que o faturamento previsto é baixo em comparação com o faturamento médio previsto. Assim, para se garantir o pagamento dos salários, a compra das mercadorias e insumos e a quitação dos demais gastos, sugere-se reservar recursos para esses períodos de baixa demanda. Esta medida possibilitaria a redução de gastos bancários, como por exemplo, os juros.

Na gestão dos recursos humanos, sugere-se definir as férias dos funcionários nos meses de dezembro, janeiro ou fevereiro, meses em que o atendimento de clientes e a realização de pedidos é baixo, ou seja, a demanda de trabalho dos funcionários cai. Em contrapartida, sugere-se a contratação de um funcionário temporário para atendimento no mês de junho, em que a necessidade de mão de obra deverá ser alta. Na área de marketing, uma opção a se analisar é a criação de promoções nos meses em que a previsão de vendas é baixa, além da possibilidade de investir em propagandas para atrair os clientes neste período. Na área de desenvolvimento de produtos, a proposta é pensar em produtos com demanda no verão, estação em que a procura dos produtos da loja cai.

Em relação a área de compras, a previsão da demanda realizada permite o gerenciamento inteligente do estoque. Problemas como falta de estoque ou produtos comprados/fabricados em excesso tendem a diminuir consideravelmente. Decorrente disto, a tendência é uma economia significativa de recursos, principalmente financeiros. A previsão de demanda possibilita também um melhor atendimento do cliente, decorrente principalmente



do comprimento de prazos de entrega e disponibilidade de produtos, contribuindo assim para a imagem da loja e conseqüentemente com a atração e fidelização de clientes. Estratégias de expansão e aberturas de filiais também podem ser embasadas na previsão da demanda.

Referente ao planejamento estratégico, a previsão de demanda é uma ferramenta importante no processo decisório. Os investimentos de uma organização devem ser justificados a partir da perspectiva das vendas, portanto, a previsão da demanda oferece o subsídio para o gestor decidir quanto investir e como investir os recursos. Além disso, oferece indicadores para verificar como está o desempenho da área comercial da empresa. Necessidades de treinamento também podem ser verificadas a partir da comparação entre a previsão de demanda e os dados reais. Portanto, demonstrou-se com o estudo a importância e relevância dos métodos de previsão da demanda para as organizações, suas aplicações gerenciais e suas possíveis contribuições práticas para o negócio.

## REFERÊNCIAS

ARMSTRONG, J. S. **Principles of forecasting: a handbook for researchers and practitioners**, Kluwer, Philadelphia, 1999.

\_\_\_\_\_. Combining Forecasting. In: ARMSTRONG, J. S. **Principles of Forecasting: A Handbook for Researchers and Practitioners**. Kluwer Academic Publishers. 2001.

BALLOU, R. H. **Gerenciamento da cadeia de suprimentos: planejamento, organização e logística empresarial**. 5. ed. Porto Alegre: Bookman, 2006.

BARNSTON, A. G. Correspondence among the Correlation, RMSE, and Heidke Forecast Verification Measures; Refinement of the Heidke Score. **Notes and Correspondence**, Climate Analysis Center, USA, 1992.

BATCHELOR, R.; DUA, P. Forecaster Diversity and the Benefits of Combining Forecasts. **Management Science**, v.41, p.68-75, 1995.

BATES, J. M.; GRANGER, C. W. J. The Combining of Forecasts. **Operational Research Quarterly**, v.20, n.4, p.451-468, 1969.

BESSLER, D. A.; BRANDT, J. A. Forecasting Livestock Prices with Individual and Composite Methods. **Applied Economics**, v.13, p.513-522, 1981.

BOX, G. E. P; JENKINS, G. M.; REINSEL, G. C. **Time series analysis - forecasting and control**. 3ª ed., Prentice Hall, New Jersey, 1994.

\_\_\_\_\_; LUCENO, A. **Statistical control by monitoring and feedback adjustment**. John Wiley, New York, 1997.

CLEMEN, R. T. Combining Forecasts: A Review and Annotated Bibliography. International. **Journal of Forecasting**. v.5, p.559-583, 1989.

\_\_\_\_\_; WINKLER, R. L. Combining Economic Forecasts. **Journal of Business and Economic Statistics**, v.4, p.39-46, 1986.



- COUTO, L. F. G.; LEAO, C. A.; TANNUS, B. G. R. V. M.; CARNEIRO, M. S. A aplicação de métodos de previsão e sua influência na lucratividade de uma relojoaria. In: XXXVI ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO, **Anais...** João Pessoa - PB, 2016.
- CRISOSTOMO, C. P.; MAINEL, A. V.; PADRAO, J. R.; COSTA, A. F.; BARBALHO, S. C. M. Previsão de demanda e gestão da capacidade e estoque de uma franquia de massas. In: XXXVI ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO, **Anais...** João Pessoa - PB, 2016.
- DAVIS, M. M.; AQUILANO, N. J.; CHASE, R. B. **Fundamentos da administração da produção**. 3. ed. Porto Alegre: Bookman Editora, 2001
- ELSAYED, E. A.; BOUCHER, T. O. **Analysis and control of production systems**, 2º ed., Prentice Hall, New Jersey, 1994.
- FLORES, B. E.; WHITE, E. M. A Framework for the Combination of Forecasts. **Journal Academic Marketing Science**, v.16, n.3-4, p.95-103, 1988.
- FLORES, B.E.; WHITE, E. M. Subjective versus Objective Combining of Forecasts: An Experiment. **Journal of Forecasting**, v.8, p.331-341, 1989.
- FULLER, W. A. **Introduction to statistical time series**. 2ª ed., John Wiley, New York, 1996.
- GOODWIN, P. Integration Management Judgement and Statistical Methods to Improve Short-term Forecasts. Omega. **The International Journal of Management Science**, v.30, p.127-135, 2002.
- GRANGER, C. W. J.; RAMANATHAN, R. Improved Methods of Forecasting. **Journal of Forecasting**, v.3, p.197-204, 1984.
- GUPTA, S.; WILTON, P. C. Combination of Forecasts: An Extension. **Management Science**, v.33, n.3, p.356-372, 1987.
- HAMILTON, J. D. **Time series analysis**, Princeton Univ. Press, Princeton NJ, 1994.
- JOHNSON, L. A.; MONTGOMERY, D. C. **Operations research in production planning, scheduling and inventory control**. John Wiley, New York, 1974.
- LEWIS, C. D. **Demand Forecasting and Inventory Control**. New York: Wiley, 1997.
- LIBBY, R.; BLASHFIELD, R. K. Performance of a Composite as a Function of the Number of Judges. **Organizational Behavior and Human Performance**, v.21, p. 121-129, 1978.
- LUSTOSA, L. J.; MESQUITA, M. A.; QUELHAS, O. L. G.; OLIVEIRA, R. J. **Planejamento e Controle da Produção**. 2 ed. Rio de Janeiro: Elsevier, 2008.



MAHMOUD, E. Combining Forecasts: Some Managerial Issues. **International Journal of Forecasting**, v.5, p.599-600, 1989.

MAKRIDAKIS, S.; WHEELWRIGHT. S. C. HYNDMAN, R. J. Forecasting - methods and applications, 3ª ed., John Wiley, New York, 1998.

MENTZER, J. T.; BIENSTOCK, C. C. **Sales Forecasting Management**. California: Sage, 1998.

MONTGOMERY, D. C.; JOHNSON, L. A.; GARDINER, J. S. **Forecasting and time series analysis**, 2ª ed., McGraw-Hill, Inc., New York, 1990.

NEWBOLD, P.; GRANGER, C. W. J. Experience with Forecasting Univariate Time Series and Combination of Forecasts. **Journal Royal Statistical Society**, v.137, n.2, p.131-165, 1974.

PELLEGRINI, F. R.; FOGLIATTO, F. S. Passos para a implantação de sistemas de previsão de demanda - Técnicas e estudo de caso. **Revista Produção**, v. 11, n. 1, p. 43-64, 2001.

ROSS, S. M. **Introduction to probability models**. 5ª ed., Academic Press, San Diego, 1993.

TAYLOR, J. W.; BUNN, D. W. Investigating Improvements in the Accuracy of Prediction Intervals for Combinations of Forecasts: A Simulation Study. **International Journal of Forecasting**, v.15, p.325-339, 1999.

WEBBY, R.; O'CONNOR, M. Judgement and Statistical Time Series Forecasting: a Review of the Literature. **International Journal of Forecasting**, v.12, p.91-118, 1996.

WINKLER, R. L.; MAKRIDAKIS, S. The Combination of Forecasting. **Journal of the Royal Statistical Society**, v.146, p.150-157, 1983.

WINTERS, P. R. Forecasting sales by exponentially weighted moving averages. **Management Science**, v. 6, n. 3, p. 324-342, 1960.

ZOU, H.; YANG, Y. Combining Time Series Models for Forecasting. **International Journal of Forecasting**, v.20, n.1, p.69-84, 2004.