

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
DEPARTAMENTO ACADÊMICO DE MECÂNICA
CURSO DE ESPECIALIZAÇÃO EM ENGENHARIA DE PRODUÇÃO

RICARDO DELAZZARI

**PREVISÕES DE DEMANDA EM UMA INDUSTRIA DE MANUFATURA
TERCEIRIZADA DO RAMO DE ELETRÔNICOS**

MONOGRAFIA DE ESPECIALIZAÇÃO

PATO BRANCO - PR

2017

RICARDO DELAZZARI

**PREVISÕES DE DEMANDA EM UMA INDUSTRIA DE MANUFATURA
TERCEIRIZADA DO RAMO DE ELETRÔNICOS**

Monografia de Especialização apresentada ao Departamento Acadêmico de Mecânica, da Universidade Tecnológica Federal do Paraná como requisito parcial para obtenção do título de “Especialista em Engenharia de Produção”.
Orientador: Prof. Dr. Marcelo Gonçalves Trentin

PATO BRANCO - PR

2017

TERMO DE APROVAÇÃO

PREVISÕES DE DEMANDA EM UMA INDUSTRIA DE MANUFATURA TERCEIRIZADA DO RAMO DE ELETRÔNICOS

por

RICARDO DELAZZARI

Esta Monografia foi apresentada em dezessete de março de 2017 como requisito parcial para a obtenção do título de Especialista em Engenharia de Produção. O(a) candidato(a) foi arguido(a) pela Banca Examinadora composta pelos professores abaixo assinados. Após deliberação, a Banca Examinadora considerou o trabalho aprovado.

Marcelo Gonçalves Trentin
Prof.(a) Orientador(a)

Gilson Adamczuk Oliveira
Membro titular

José Donizetti de Lima
Membro titular

RESUMO

DELAZZARI, Ricardo. PREVISÕES DE DEMANDA EM UMA INDUSTRIA DE MANUFATURA TERCEIRIZADA DO RAMO DE ELETRÔNICOS. 2017. 39 f. Monografia (Especialização em Engenharia de Produção) – Universidade Tecnológica Federal do Paraná. Pato Branco, 2017.

Realizar previsões de demanda com acurácia é uma tarefa difícil, mesmo quando dispõe de informações apropriadas que possam auxiliar neste trabalho. Quando a demanda de uma empresa é dependente de informações vindas de um cliente, esta tarefa se torna ainda mais difícil, prejudicando assim todo o planejamento de aquisição de matéria prima e capacidade de fábrica para atendimento da demanda. Um dos ramos de atuação que sofrem os efeitos de trabalhar com a demanda dependente do cliente é o chamado de *Contract Manufacturing*, ou seja, empresas que produzem eletrônicos de forma terceirizada. Dessa forma, este trabalho teve como objetivo estudar a demanda prevista com o cliente, com o intuito de encontrar pontos de melhoria que auxiliem o cliente a melhorar suas previsões. Para isso, este trabalho aborda os conceitos de previsão de demanda, métodos de suavização exponencial e metodologia ARIMA, bem como métodos de combinação de previsões. A partir dos conceitos abordados, foram aplicados os mesmos com o auxílio do *software* Statgraphics para definir os modelos que melhor se ajustaram à série histórica de dados. Foi realizada uma comparação entre o modelo combinado de previsão de demanda e o modelo de previsão utilizado pelo cliente, indicando qual o mais adequado para cada série histórica de dados. Em alguns casos, o modelo combinado alcançou MAPE 66% menores do que o método utilizado pelo cliente.

Palavras-chave: Previsão de demanda. Métodos de previsão. Combinação de previsões.

ABSTRACT

DELAZZARI, Ricardo. DEMAND FORECASTS IN A OUTSOURCED MANUFACTURING INDUSTRY OF THE ELECTRONICS BRANCH. 2017. 39 f. Monography (Specialization in Production Engineering) – Universidade Tecnológica Federal do Paraná. Pato Branco, 2017.

Accurately forecasting demand is a difficult task, even when you have the appropriate information to help with this work. When a company's demand is dependent on information coming from a customer, this task becomes even more difficult, thus harming all the planning of raw material acquisition and factory capacity to meet demand. One of the lines of action that suffer the effects of working with customer-dependent demand is called Contract Manufacturing, that is, companies that produce electronics in a third-party manner. Thus, this study aimed to study the expected demand with the customer, with the aim of finding improvement points that will help the client to improve his forecasts. For this, this work approaches the concepts of demand forecasting, exponential smoothing methods and ARIMA methodology, as well as prediction combining methods. From the concepts discussed, the same were applied with the help of Statgraphics software to define the models that best fit the historical series of data. A comparison was made between the combined demand forecasting model and the forecast model used by the client, indicating which is the most appropriate for each historical series of data. In some cases, the combined model achieved MAPE 66% lower than the method used by the client.

Keywords: Forecast of demand. Forecasting methods. Combination of forecasts.

LISTA DE TABELAS

Tabela 1 – Histórico de demanda por produto: séries temporais.....	25
Tabela 2 – Melhores modelos produto A.....	28
Tabela 3 – Modelos de Previsão Produto “A”.....	28
Tabela 4 – Previsões de demanda Produto “A”.....	28
Tabela 5 – Melhores modelos produto “B”.....	29
Tabela 6 - Modelos de Previsão Produto “B”.....	30
Tabela 7 – Previsões de demanda Produto “B”.....	30
Tabela 8 – Melhores modelos produto “C”.....	31
Tabela 9 - Modelos de Previsão Produto “C”.....	31
Tabela 10 – Previsões de demanda Produto “C”.....	31
Tabela 11 – Melhores modelos produto “D”.....	32
Tabela 12 - Modelos de Previsão Produto “D”.....	33
Tabela 13 – Previsões de demanda Produto “D”.....	33
Tabela 14 – Melhores modelos produto “E”.....	34
Tabela 15 - Modelos de Previsão Produto “E”.....	34
Tabela 16 – Previsões de demanda Produto “E”.....	34

SUMÁRIO

1	INTRODUÇÃO.....	8
2	PREVISÃO DE DEMANDA.....	10
2.1	Métodos de previsão de demanda.....	11
2.2	Séries temporais.....	12
2.3	Modelos de Suavização Exponencial.....	13
2.3.1	SUAVIZAÇÃO EXPONENCIAL SIMPLES.....	14
2.3.2	SUAVIZAÇÃO EXPONENCIAL LINEAR – MÉTODO DE HOLT.....	15
2.3.3	SUAVIZAÇÃO EXPONENCIAL DE HOLT-WINTERS.....	16
2.4	Modelos Box-Jenkins (ARIMA).....	17
2.4.1	MODELO AUTO-REGRESSIVO INTEGRADO DE MEDIA MOVEL – ARIMA.....	18
2.5	Medidas de Erros de Previsão.....	19
2.6	Combinação de Previsões.....	20
3	METODOLOGIA.....	22
3.1	Caracterização da Pesquisa.....	22
3.2	Procedimentos da Pesquisa.....	22
4	APRESENTAÇÃO E DISCUSSÃO DOS RESULTADOS.....	25
4.1	Avaliação do Produto “A”.....	27
4.2	Avaliação do Produto “B”.....	29
4.3	Avaliação do Produto “C”.....	31
4.4	Avaliação do Produto “D”.....	32
4.5	Avaliação do Produto “E”.....	34
5	ANÁLISE DOS RESULTADOS.....	36
6	CONSIDERAÇÕES FINAIS.....	38
	REFERÊNCIAS.....	39

1. INTRODUÇÃO

Saber a quantidade exata de vendas que um determinado produto terá no mercado em um determinado período é de extrema importância para que a empresa possa fazer um planejamento adequado dos seus recursos, evitando faltas ou excesso de matéria-prima no estoque, erros no dimensionamento da capacidade produtiva e também o risco de perder mercado para os concorrentes no caso da empresa não estar preparada para reagir às mudanças no ambiente em que compete, por não possuir um planejamento correto em relação à demanda dos produtos e serviços que oferece.

Dentro do contexto do mercado globalizado e cada vez mais competitivo, com o aumento da concorrência de empresas de outros países, uma correta previsão de como possivelmente será a demanda pode trazer diversos ganhos e se tornar um diferencial competitivo, proporcionando mais lucratividade e melhorando o fluxo de trabalho visto que o planejamento de todas as atividades pode ser realizado de forma mais clara e objetiva.

Apesar de tal importância, realizar previsões corretas é extremamente difícil e mesmo quando bem-feita, ainda apresenta divergência em relação à realidade. Realizar previsões corretas é difícil de uma maneira geral, porém, dependendo da área de atuação da empresa, essa atividade pode se tornar mais difícil e desafiadora visto que as características dos clientes têm grande variação ou especificidades que dificultam uma correta previsão por parte das empresas que fornecem os seus insumos. Pode-se considerar que quanto maior for o número de fatores que influenciam a realização de uma previsão de demanda, maiores serão as dificuldades para que a mesma seja correta e assertiva, ou seja, quanto maior a dependência de fatores externos, maior será a dificuldade. Considerando este pressuposto, o modelo de negócio chamado de Electronic Manufacturing Service – EMS, que é praticado pela empresa estudada, possui características que tornam a previsão da demanda mais difícil de ser realizada com precisão.

O modelo de negócio chamado de EMS é um termo utilizado para companhias que projetam, testam, produzem, distribuem e prestam serviços de reparo de produtos eletrônicos para outras empresas de forma terceirizada, que são as proprietárias do projeto/produto. Este modelo de negócio é especializado em produções de larga escala, sendo que entre os serviços prestados, além da manufatura estão ainda gestão de compra e armazenamento de matéria prima e logística de distribuição, além de expertise para melhoria e desenvolvimento de projetos de forma compartilhada (NGAMPAK; PHRUKSAPHANRAT, 2011).

Considerando assim que a empresa atua oferecendo serviços de forma terceirizada, outra característica deste modelo de negócio é o grande número de clientes que a mesma normalmente atende, sendo que cada um deles possui um modo diferente de administrar e fazer previsões para a demanda dos seus produtos, ou seja, cada empresa utiliza seus métodos e repassa suas previsões para a indústria EMS. Isso faz com a EMS tenha sua demanda dependente da previsão que é realizada pelos clientes, gerando grandes dificuldades no planejamento interno visto que a maioria dos clientes não consegue realizar boas previsões de demanda, pois não dispõe de profissionais com conhecimento técnico necessário para tal trabalho ou porque não dão a devida importância para boas previsões.

Dessa forma, este trabalho teve como objetivo estudar a demanda prevista com o cliente, com o intuito de encontrar pontos de melhoria que auxiliem o cliente a melhorar suas previsões e conseqüentemente auxiliem na melhoria do planejamento interno.

2 PREVISÃO DE DEMANDA

A demanda pode ser conceituada como sendo a quantidade de um bem ou serviço que o consumidor pretende adquirir em um determinado espaço de tempo e por um determinado preço. Quando este desejo é considerado em um grau de coletividade, pode ser caracterizado então como demanda de mercado. Além de identificar a quantidade desejada de determinado produto, é de extrema importância para as empresas conseguir identificar quantas pessoas/organizações possuem real poder de compra para adquirir determinado produto (WERNER; RIBEIRO, 2006).

Partindo desta dificuldade de identificar quais são realmente os consumidores que possuem o poder de compra necessário para adquirir o produto ou serviço oferecido, utilizar técnicas para tentar prever a demanda é de extrema importância, pois a quantidade a ser vendida dos produtos/serviços é o ponto de partida para o planejamento dos demais recursos utilizados no processo produtivo, sejam estes recursos financeiros, de recursos humanos, máquinas, matéria prima, entre outros. Sem uma boa previsão de vendas, todo o planejamento de operações da empresa fica comprometido e isso pode representar prejuízos ao longo do tempo (LIN, 2000).

O processo de previsão busca identificar o que irá acontecer em um evento futuro, por este motivo, pode-se considerar que todas (ou pelo menos grande parte) das previsões que são realizadas, na verdade não são exatas. O que ocorre na realidade é que busca-se realizar previsões com a menor discrepância em relação à demanda real quando bem realizadas, ou seja, apesar dos erros existirem, os mesmos são minimizados e de um modo geral, as previsões contribuem de forma positiva no planejamento das empresas (LIN, 2000).

Segundo Yamamoto (2007), para realizar a previsão da demanda, existem diferentes métodos que são divididos em dois grandes grupos, que são o grupo dos métodos qualitativos (opinião de especialistas) e o grupo dos métodos quantitativos (modelos matemáticos). Para um melhor resultado, o uso conjunto de métodos quantitativos e qualitativos pode reduzir a chance de erros, visto que pode-se unir os dados quantitativos calculados pelos modelos presentes neste grupo, com a opinião (qualitativa) de especialistas que tem convivência com o mercado em tempo real.

A escolha por um método e/ou outro depende de diversos fatores, como o objetivo do estudo que está sendo realizado, além disso, outro fator determinante na escolha é o conjunto de dados que se tem para realizar a análise. Quando se trata de um produto/serviço novo no

mercado, costuma-se utilizar principalmente métodos qualitativos como opinião de analistas e pesquisas de mercado, diretamente com os clientes. Já quando se tem um grande histórico de vendas do produto, os métodos quantitativos se destacam como sendo os que trazem os melhores resultados, usando os modelos quantitativos como apoio (PELLEGRINI, 2000).

A partir do objetivo deste trabalho, que tem como enfoque a análise da demanda através de métodos quantitativos, estes métodos serão estudados com maior detalhamento na próxima seção.

2.1 Métodos de previsão de demanda

Ao buscar na literatura existente, pode-se encontrar diversos métodos para previsão da demanda, com isso, é possível encontrar métodos que sejam mais adequados ou inadequados dependendo da situação em que sejam empregados. Com isso, estes métodos são divididos em dois grupos, que são: grupo dos métodos qualitativos e grupo dos métodos quantitativos (YAMAMOTO, 2007).

Os métodos qualitativos são utilizados quando se possui poucos ou nenhum histórico de dados sobre a demanda que se pretende analisar, como por exemplo a demanda de novos produtos que estão ainda sendo implementados no mercado. Com isso, para realizar previsões utilizando métodos qualitativos, é necessário que o analista tenha grande expertise sobre o mercado em que o produto está inserido. Além disso, são mais caras e trabalhosas de se realizar se comparado com os métodos quantitativos (PACHECO; SILVA, 2003).

Em contrapartida, os modelos quantitativos são baseados em dados históricos, e através destes dados, utiliza-se então equações matemáticas para realizar as previsões. Comparadas com as técnicas qualitativas, as quantitativas se mostram mais baratas e práticas de se utilizar, pois podem ser aplicadas através de *softwares* e os resultados encontrados são objetivos, sem a necessidade constante do conhecimento de especialistas de mercado. As séries históricas utilizadas para a previsão de demanda, utilizando métodos quantitativos, podem ser classificadas em dois grupos, que são as séries causais (modelos de regressão) e séries temporais (YAMAMOTO, 2007).

Para a realização do presente estudo, foram utilizadas apenas métodos quantitativos referentes ao grupo de séries temporais, que serão abordadas de forma detalhada nos capítulos seguintes.

2.2 Séries temporais

As séries temporais são medidas de determinadas variáveis (vendas de um produto, por exemplo), sendo que tomada dos dados é realizada em intervalos iguais, como por exemplo, dados coletados mês a mês. A coleta periódica de dados tem dois objetivos principais: o primeiro deles é identificar fenômenos que acontecem periodicamente e interferem nas observações, e a partir disso, realizar as previsões futuras considerando estes fenômenos, buscando assim aumentar a acurácia das previsões (FURTADO, 2006).

Existem diversos modelos que podem ser utilizados, sendo que a escolha de determinado modelo deve ser realizada levando em consideração as quatro principais características que compõem uma série temporal de dados, que são: média (variação em valor central), tendência (apresenta uma tendência ascendente ou descendente quando analisado um longo período de tempo), sazonalidade (ocorre quando existem padrões cíclicos de variação que se repetem em intervalos relativamente constantes de tempo) e ciclo (ocorre quando a série apresenta variações ascendentes e descendentes não regulares no tempo). Qualquer variação apresentada por uma série de dados que não possa ser explicada por umas destas quatro características é então considerada aleatória, causada por um fator externo, como política e economia, por exemplo (FURTADO, 2006).

Segundo Lin (2000), considerando as características apresentadas anteriormente, pode-se escolher um entre os diversos métodos que utilizam as séries temporais para realizar as previsões, que são:

- Métodos de extrapolação;
- Suavização exponencial;
- Médias, e;
- Box-Jenkins (ARIMA).

Conforme mencionado anteriormente, para a escolha de um ou mais métodos de séries temporais para realizar previsões deve-se verificar as características apresentadas pelos dados históricos que serão utilizados. Partindo deste princípio e após análise realizada nos dados que

foram utilizados para este trabalho, foram então escolhidos os métodos baseados na Suavização exponencial e Box-Jenkins (ARIMA), conforme será abordado nos capítulos a seguir.

2.3 Modelos de Suavização Exponencial

Dentre os métodos quantitativos de previsão de demanda, os modelos de suavização exponencial são largamente utilizados devido à sua facilidade de implementação e também por apresentar resultados considerados de boa acurácia, sem deixar a desejar para modelos mais complexos como o Box-Jenkins (ARIMA). Além disso, não necessitam de uma grande quantidade de dados para realizar boas previsões, ajustando-se facilmente às mudanças que ocorrem nas séries de dados (NOVAES; *et al.*, 2008).

A suavização exponencial caracteriza-se principalmente pela maneira que organiza o grau de importância dos dados presentes nas séries temporais, ou seja, este modelo considera que as observações mais recentes da série de dados têm maior grau de importância para a análise, dando assim pesos maiores para estas observações, em contrapartida, dá pesos menores para as observações mais antigas da série. Para fim de comparação, os modelos de médias, por exemplo, consideram pesos iguais para todas as observações da série (FOGLIATTO; *et al.*, 2005).

Segundo Yamamoto (2007), os modelos de suavização exponencial que são comumente encontrados na literatura são:

- Suavização exponencial simples;
- Suavização exponencial linear (método de Holt);
- E, Suavização exponencial com sazonalidade e tendência linear (método de Holt-Winters).

Cada um dos modelos de suavização exponencial irá se adequar a determinadas características de uma série temporal e apresentar melhores resultados. Dessa forma, Makridakis *et al.* (1998), recomenda a utilização do modelo Holt para séries que apresentam tendência, já para as séries que apresentam sazonalidade, recomenda-se a utilização do modelo Holt-Winters.

2.3.1 SUAVIZAÇÃO EXPONENCIAL SIMPLES

Segundo Novaes; *et al.*, (2008), a suavização exponencial simples é utilizada em casos que as séries temporais se mantem constante a um nível médio, ou seja, tem pequena variabilidade, pode-se utilizar este método para fazer a previsão de demandas futuras. Este método é expresso pela Equação 1.

$$P(t + 1) = \alpha D(t) + (1 - \alpha) \cdot P(t) \quad (1)$$

Na qual:

t: instante de tempo atual;

P(t+1): previsão para o instante de tempo seguinte de t;

P(t): previsão para o instante atual t;

D(t); demanda no instante t, e;

α : Constante de suavização exponencial.

Para dar início às previsões, este modelo necessita de uma fase de inicialização, que é definir um valor para P(t+1). Makridakis *et al.* (1998), sugere que essa inicialização pode ser feita de duas formas:

- Adotar $P(t+1) = D(t)$, ou;
- Adotar P(t+1) como média das 4 ou 5 primeiras observações da série histórica.

Este modelo se ajusta de acordo com os erros cometidos no passado, ou seja, compara os valores reais com os valores previstos identificando assim o erro de previsão, utilizando este erro encontrado no passado como base para cálculo da previsão no período futuro. Com isso, α é uma constante que varia entre 0 e 1 (YAMAMOTO, 2007).

Se o valor da constante α for mais próximo de 0, o modelo terá resultado semelhante ao modelo de Média Móvel, que não será abordado neste trabalho. Por outro lado, quanto mais próximo de 1 for o valor da constante, significa que o ajuste do modelo é mais agressivo em relação ao erro da previsão anterior. Isto significa que quanto maior o valor da constante se aproximando de 1, maior será a variabilidade dos resultados (DIAS, 1993).

Ballou (2001), destaca como principal vantagem para utilização deste modelo o fato do mesmo possuir grande capacidade de adaptação, sendo que isto ocorre pela possibilidade de alteração da Constante de Suavização Exponencial em qualquer ponto da série temporal analisada.

2.3.2 SUAVIZAÇÃO EXPONENCIAL LINEAR – MÉTODO DE HOLT

Quando uma série de dados apresenta tendência linear de crescimento ou decrescimento, o modelo de Holt é apontado com um dos mais adequados para realizar previsões de demanda. Este modelo tem como característica o uso de duas constantes de suavização, α e β , com valores que variam entre 0 e 1 (MAKRIDAKIS *et al.*,1998).

Segundo Yamamoto (2007), o modelo é descrito por três equações, sendo que a primeira delas realiza uma estimativa de nível, a segunda verifica a inclinação da série e a terceira realiza a previsão para os próximos k períodos da série temporal. As Equações 2, 3 e 4 representam este modelo.

- Nível :

$$L_t = \alpha Y_t + (1-\alpha)(L_{t-1} + T_{t-1}) \quad (2)$$

- Inclinação:

$$T_t = \beta(L_t - L_{t-1}) + (1-\beta)T_{t-1} \quad (3)$$

- Previsão futura:

$$Z_{t+k} = L_t + kT_t \quad (4)$$

Assim como a suavização exponencial simples, o método de Holt também precisa passar pela fase de inicialização, ou seja, estimar os valores iniciais para as L_0 e T_0 . Uma forma alternativa para estes cálculos é igualar L_0 ao último valor observado na série temporal e calcular a média da declividade nas últimas observações para T_0 . A segunda opção para este caso é utilizar a regressão linear simples aplicada aos dados da série temporal, onde pode-se obter o valor da declividade da série temporal e de L_0 em sua origem (PELLEGRINI, 2000).

2.3.3 SUAVIZAÇÃO EXPONENCIAL DE HOLT-WINTERS

O modelo de suavização exponencial de Holt-Winters descreve com propriedade dados de demanda que possuam a ocorrência de tendência linear, além de uma componente de sazonalidade. Caso a amplitude da variação sazonal mantenha-se constante, classifica-se como um modelo aditivo. Caso essa amplitude aumente com o tempo, classifica-se então como um modelo multiplicativo (PELLEGRINI; FLOGIATTO, 2000).

Segundo Morettin & Toli (2004), este modelo possui algumas vantagens, como fácil entendimento e aplicação, além de se adequar facilmente a séries com características mais generalistas. Já as grandes desvantagens são a dificuldade na escolha dos valores mais apropriados para as constantes de suavização, além da dificuldade de estudar as características probabilísticas da série, como média, mediana e variância.

Segundo Milnitz, Marchi e Samohyl (2011), o modelo aditivo de Holt-Winters é representado por quatro equações: Média (5), Tendência (6), Sazonalidade (7), e Modelo de previsão (8).

- Média:

$$L_t = \alpha.(S_t - S_{t-s}) + (1-\alpha).(L_{t-1} + T_{t-1}) \quad (5)$$

- Tendência:

$$T_t = \beta.(L_t - L_{t-1}) + (1-\beta).T_{t-1} \quad (6)$$

- Sazonalidade:

$$S_t = \gamma.(Z_t - L_t) + (1-\gamma).S_{t-s} \quad (7)$$

- Modelo de previsão:

$$Z_{t+k} = L_{t+k}.T_t + S_{t-s+k} \quad (8)$$

Onde, S é uma estação completa da sazonalidade. L_t , T_t e S_t representam o nível, a tendência e a sazonalidade da série. Z_{t+k} é a previsão para os próximos k períodos e por fim, γ é a constante de suavização que varia de 0 a 1 e controla os pesos relativos da sazonalidade.

A outra classificação existente para o modelo Holt-Winters é chamada de Modelo Sazonal Multiplicativo. Segundo Furtado (2006), este modelo é representado pelas quatro equações, Média (9), Tendência (10), Sazonalidade (11), e Modelo de previsão (12). :

- Média:

$$L_t = \alpha \cdot Z_t / S_{t-s} + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad (9)$$

- Tendência:

$$T_t = \beta \cdot (L_t - L_{t-1}) + (1 - \beta)T_{t-1} \quad (10)$$

- Sazonalidade:

$$S_t = \gamma \cdot Z_t / L_t + (1 - \gamma)S_{t-s} \quad (11)$$

- Modelo de previsão:

$$Z_{t+k} = (L_t + kT_t)S_{t-s+k} \quad (12)$$

Onde Z_{t+k} é a previsão no período $t+k$. As constantes de suavização são representadas por α , β , e γ , sendo que variam de 0 a 1, e são escolhidas de acordo com os métodos já citados anteriormente. L_t , T_t e S_t representam o nível, a tendência e a sazonalidade da série.

Tanto o modelo sazonal aditivo quanto o sazonal multiplicativo possui grande utilização e a escolha entre um e outra baseia-se apenas na característica da série de dados. Uma alternativa para estes modelos é o chamado Box-Jenkins (ARIMA), que é considerado mais preciso, e por isso será apresentado de forma detalhada no capítulo a seguir.

2.4 Modelos Box-Jenkins (ARIMA)

Os modelos Box-Jenkins, também conhecidos como ARIMA (*Auto Regressive Integrated Moving Averages*), são modelos matemáticos que buscam identificar o comportamento da correlação seriada, ou seja, qual a correlação entre os valores da série temporal. A partir desta correlação, são então feitas as previsões para os períodos futuros (WERNER; RIBEIRO, 2003).

De acordo com BOX et al., (1994), os modelos são construídos baseados na correlação dos dados temporais, e dividem-se em quatro principais modelos, que são:

- Modelos autoregressivos (AR), que exploram a estrutura de autocorrelação da variável;

- Modelos de médias móveis (MA), que exploram a estrutura de autocorrelação dos erros de previsão;
- Modelos autoregressivos e de médias móveis (ARMA), adequados para séries onde é desejável um número não muito grande de parâmetros;
- Modelo autoregressivo integrado de média móvel (ARIMA), para séries não-estacionárias.

Cada um dos modelos citados apresenta características distintas e devem ser aplicados de acordo com a necessidade. Com isso, para este trabalho, serão utilizados apenas os modelos ARIMA, abordados com mais detalhes no item a seguir.

2.4.1 MODELO AUTO-REGRESSIVO INTEGRADO DE MÉDIA MOVEL – ARIMA

Os modelos ARIMA são baseados em séries de dados chamadas estacionárias, ou seja, séries que a característica do processo não se altera ao longo do tempo. Estes modelos ARIMA (p,d,q), são modelos que se diferenciam d vezes da série original, possuem p parâmetros autoregressivos e q parâmetros de média móveis (ABURTO, WEBER, 2007).

Segundo Vasconcelos e Alves (2000), como estes modelos trabalham com séries estacionárias, se determinada série não for estacionária, o primeiro passo a realizar é transformar esta série de não-estacionária para estacionária. Para isso, é realizada a aplicação de d diferenças, sendo que este processo pode ser realizado uma ou duas vezes até que a série seja transformada totalmente em estacionária. Para isso, são utilizadas as seguintes equações:

- Primeira diferença de

$$Z_t: \Delta Z_t = Z_t - Z_{t-1} \quad (13)$$

- Segunda diferença de

$$Z_t: D^2 Z_t = Z_t - 2Z_{t-1} - Z_{t-2} \quad (14)$$

O número de d diferenças necessárias para transformar determinada em estacionária é chamada de ordem de integração. Com a inclusão deste termo é possível então aplicar os modelos ARIMA (p,d,q), que é representado pela Equação 15, abaixo apresentada (WERNER, 2004).

$$w_t = \phi_1 w_{t-1} + \dots + \phi_p w_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q} \quad (15)$$

Onde: $Wt = \Delta^d Zt$.

A equação pode ser rescrita utilizando um operador de defasagem L, conforme Equação 16, a seguir:

$$\phi(L)(1-L)^d Z_t = \theta(L)\varepsilon_t \quad (16)$$

Onde : $Wt = (1 - L)^d Zt$

Os modelos ARIMA são largamente utilizados por apresentarem elevada precisão nas previsões que realizam, o que o torna um dos modelos mais utilizados, apesar de sua complexidade na aplicação. Assim como todos os outros modelos quantitativos existentes, o modelo ARIMA tem sua acurácia medida a partir de métodos que calculam os erros existentes nas previsões. Com isso, os métodos para se calcular estes erros serão apresentados no item a seguir.

2.5 Medidas de Erros de Previsão

Para se medir a precisão das previsões realizadas, ou seja, o a diferença entre os valores previstos e os valores observados, existem diversos modelos matemáticos que são utilizados para auxiliar no ajuste dos modelos que são aplicados para determinada série de dados. Quanto menor for o valor do erro identificado em uma previsão, entende-se então que o modelo está mais ajustado à série (PACHECO; SILVA, 2003).

Segundo Furtado (2006), as principais formas de medir a acurácia das previsões são apresentadas nas Equações 17, 18 e 19:

- Média do quadrado dos erros (MQE);

$$MQE = \frac{1}{n} \sum_{t=1}^n e_t^2 \quad (17)$$

- Média absoluta dos erros (MAE);

$$MAE = \frac{1}{n} \sum_{t=1}^n |e_t| \quad (18)$$

- Média absoluta percentual dos erros (MAPE);

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{e_t}{z_t} \times 100 \right| \quad (19)$$

Dentre os métodos citados acima, o mais utilizado é o MAPE, que será utilizado também como parâmetro de análise deste trabalho. Para a utilização deste modelo, a única restrição existente é a necessidade de não haver valores iguais a 0 na série de dados, pois isso impossibilita a aplicação da fórmula matemática que este modelo se baseia (KAHN, 1998).

2.6 Combinação de Previsões

Sobre as técnicas previsão de demanda, sabe-se que não existe método que seja livre de erros, ou seja, todos os métodos existem apresentam discrepâncias em suas previsões. A partir deste pressuposto, busca-se diversas técnicas para que as previsões sejam melhoradas e os erros minimizados ao máximo.

Segundo Werner e Ribeiro (2006, p.2),

[...]a combinação é uma abordagem atraente para realizar previsões, visto que, ao invés de tentar escolher a melhor técnica, formula-se o problema perguntando que técnicas poderiam ajudar na melhoria da acurácia. Como as previsões podem ser afetadas por diversos fatores, cada técnica pode contribuir capturando algum tipo de informação que influencia esses fatores.

As combinações podem ser feitas por diferentes métodos, partindo de métodos como a média aritmética ou ponderada, além de métodos que utilizam a variância, onde são atribuídos pesos para cada previsão que será combinada, de acordo com a sua variância (HOLLAUER; ISSLER; NOTINI, 2008).

Neste trabalho, serão realizadas combinações utilizando-se o método de média aritmética. Armstrong e Collopy (1998), reforça que o método de média aritmética é um método largamente utilizado e considerado de fácil aplicação, visto que não é necessário conhecer o grau de precisão ou o grau de dependência entre as previsões que serão combinadas.

Segundo Hibon e Eugeniou (2005), a combinação de previsões por média aritmética pode ser considerada um dos métodos mais utilizados. Com isso, este método pode ser representado pela Equação 20, abaixo:

$$X = \frac{x_1+x_2+x_3\dots+x_n}{n} \quad (20)$$

Para a equação, X é igual a média aritmética, x_n representa os valores das previsões que serão comparadas e n é a quantidade de previsões a serem combinadas.

3 METODOLOGIA

Para a realização do trabalho, foi necessário a utilização de diversas técnicas e procedimentos para se chegar ao resultado almejado. Dessa forma, neste capítulo serão apresentados os devidos procedimentos, ferramentas e técnicas utilizadas na análise e obtenção dos resultados.

3.1 Caracterização da Pesquisa

A pesquisa realizada foi caracterizada com uma pesquisa quantitativa. Este tipo de pesquisa tem como principal característica a utilização de técnicas matemáticas e estatísticas, utilizando dados matemáticos para realizar as análises e apresentado de forma objetiva os resultados dos estudos (RICHARDSON, 2012).

O estudo realizado com os métodos quantitativos foi realizado com foco em uma indústria de eletrônicos que atua no seguimento de *Contract Manufacturing*, também chamado de EMS, podendo assim ser considerado como um estudo de caso. Yin (2010), descreve o estudo de caso como um estudo profundo e exaustivo de um ou de poucos objetivos, de maneira a permitir o seu conhecimento amplo e detalhado.

Este estudo detalhado da demanda, que é específica para a empresa, permitiu entender melhor como a mesma se comporta e assim identificar os modelos que melhor se adequaram à realidade encontrada na empresa, possibilitando assim alcançar os resultados desejados.

3.2 Procedimentos da Pesquisa

Inicialmente, para a realização do estudo foram coletados os dados referentes às demandas dos produtos A, B, C, D e E que foram analisados. Esta coleta dos históricos de demanda foi realizada através da análise documental de arquivos da empresa. A empresa em questão atua na área de terceirização de montagem de produtos eletrônicos, ramo conhecido como *Contract Manufacturing* – CM (manufatura por contrato). Esse ramo de negócio se caracteriza pela prestação de serviços de montagem de produtos eletrônicos, além de gestão de compra de matéria prima, estoques de componentes, serviços de engenharia e desenvolvimento compartilhado de produtos, entre outras operações que envolvem toda a cadeia de produção.

Dessa forma, a montadora terceirizada (também conhecida como CM), trabalha como sendo uma fábrica do cliente, montando total ou parcialmente seus produtos, conforme sua necessidade e estratégia de negócio.

Por se tratar de um negócio onde a produção se caracteriza por ser totalmente sob encomenda, quem realiza as previsões de demanda futura dos produtos é o cliente, que repassa essa demanda para o CM adquirir então a matéria prima necessária e organizar suas operações para e atender esta demanda. Os principais clientes da empresa trabalham com sistemas de *forecast*, ou seja, fornecem para o CM informações referentes à demanda de três a seis meses a frente, porém somente o primeiro mês à frente é considerada demanda certa, já os demais meses sempre possuem variação, dificultando assim o planejamento das operações que são realizadas pelo CM.

Estes documentos analisados se tratam de arquivos com o histórico das demandas passadas. As séries temporais coletadas consistem no histórico da demanda referente a 36 meses, ou seja, período de março de 2014 a fevereiro de 2017, sendo que a pedido da empresa os dados foram modificados (multiplicados por uma mesma constante), mantendo o seu comportamento.

Os dados foram analisados utilizando os modelos de previsão de demanda com o auxílio de um *software* estatístico. Para esta análise e identificação dos melhores modelos, os 30 primeiros dados da série temporal foram utilizados para ajuste dos modelos no software, enquanto os últimos 6 últimos dados da série foram utilizados para calcular o MAPE e realizar a comparação entre os modelos que foram encontrados, realizar a combinação entre estes modelos, e por fim poder comparar a acurácia de previsão averiguando a combinação realizada e o respectivo modelo que já é utilizado pelo cliente. Para cada combinação realizada, foram escolhidos os três modelos que apresentaram melhor desempenho na fase de ajustes, sendo que os modelos foram selecionados através do MAPE encontrado nas previsões, ou seja, os que tiveram menor erro foram considerados os melhores (melhor acurácia). A combinação empregada foi a média das previsões encontradas pelos três modelos.

Em relação ao modelo de previsão utilizado pelo cliente, o mesmo não divulga as informações ao CM de qual é exatamente o modelo que utiliza. Dessa forma, para realização da comparação, o que será utilizado serão apenas os históricos de previsão que o mesmo informa através de uma planilha de *forecast*. Vale ressaltar ainda que o cliente ainda possui um especialista que pode manipular os dados obtidos com a utilização do modelo numérico, ou seja, este especialista pode utilizar informações complementares para na tentativa de melhorar

as suas previsões. Já os modelos ajustados neste trabalho, consideram apenas a série de dados para a previsão, sem este ajuste do especialista, podendo assim possibilitar que a previsão do cliente possa receber influência. A comparação será realizada entre os valores da demanda real, previsão realizada pelo cliente e previsão combinada dos três melhores modelos

A partir dos ajustes realizados no *software* e a comparação realizada, foram realizadas as devidas considerações sobre os resultados encontrados e sobre as características de cada série temporal que pode ter influenciado no resultado encontrado.

4 APRESENTAÇÃO E DISCUSSÃO DOS RESULTADOS

Neste capítulo serão descritos os procedimentos realizados para coleta dos dados, a aplicação dos métodos de previsão de demanda bem como a combinação de previsões em busca dos melhores modelos para cada série de dados, para que os mesmos pudessem servir de base para sugerir melhorias nas previsões realizadas pelos clientes.

Em grande parte dos casos, a variação existente entre a demanda prevista e demanda real que o cliente é extremamente grande, sendo que isso ocorre pela inexperiência, falta de conhecimento e/ou pouca importância que o cliente dá para a realização das previsões, sem saber dos impactos que isso causa no planejamento do CM.

No estudo, foram escolhidos cinco produtos que possuem demanda corrente e, que por sua complexidade para compra de matéria prima e montagem, geram grande impacto e problemas para o CM. O histórico de demanda destes produtos referente aos últimos 36 meses é apresentado na Tabela abaixo:

Tabela 1 – Histórico de demanda por produto: séries temporais

Mês de referência	Demanda por produto				
	Produto "A"	Produto "B"	Produto "C"	Produto "D"	Produto "E"
mar/14	19922	3474	955	789	1417
abr/14	19124	477	466	789	596
mai/14	12730	76	637	789	764
jun/14	38190	741	1591	789	637
jul/14	48374	255	2349	19127	1060
ago/14	18585	891	1528	21005	334
set/14	35050	1055	827	4774	639
out/14	39789	246	637	3946	764
nov/14	33111	61	2126	17066	2368
dez/14	39351	1273	327	32888	500
jan/15	16231	764	242	36805	165
fev/15	9022	182	146	40100	509
mar/15	18540	127	859	30552	1655
abr/15	35050	1055	378	24266	1910
mai/15	26256	1668	1452	19095	365
jun/15	28770	2495	1729	21005	3240
jul/15	24641	1264	993	15514	1814
ago/15	35295	2084	1400	17186	2471
set/15	25926	1455	1432	58558	354
out/15	15608	1941	677	44549	2051
nov/15	27622	811	275	33213	1394
dez/15	24307	1066	144	8260	759
jan/16	34730	1660	2209	8730	395
fev/16	34371	2075	1035	23479	2309


mar/16	32068	2864	1688	29192	2689
abr/16	20873	387	1576	62101	2419
mai/16	31322	1273	1310	44625	1419
jun/16	23484	956	1115	39781	2305
jul/16	27200	1898	974	65305	1910
ago/16	31971	900	643	33416	2106
set/16	16221	3501	2392	18140	4710
out/16	41532	1640	2535	10108	3844
nov/16	23582	911	2037	20629	3039
dez/16	17869	833	2971	38827	1180
jan/17	15436	722	2387	49329	414
fev/17	11229	582	2797	38438	1782

Fonte: Empresa estudada (2017)

Para realizar as análises e identificar o modelo combinado de previsão para cada série temporal, foram utilizados os períodos de 1 a 30 para as análises no software Statgraphics, já os dados referentes aos períodos 31 a 36 foram utilizados para a comparação entre a previsão do cliente e a combinação dos modelos.

Como fase inicial do estudo, foi realizado uma visualização prévia do comportamento das séries temporais através de gráficos, que representaram o comportamento destas séries nos 30 primeiros períodos. No Gráfico 1, estão apresentadas as características dos produtos A e D, que possuem demanda com maior volume.


Gráfico 1 – Características das séries temporais Produtos A e D



Fonte: Autoria própria (2017)

Já no Gráfico 2, estão apresentadas as características dos produtos B, C e E, que possuem menor volume.

Gráfico 2 – Características das séries temporais Produtos B, C e E



Fonte: Autoria própria (2017)

Conforme pode-se perceber nos gráficos, as séries temporais aparentam ter grande variação e instabilidade na demanda, não apresentando características claramente apresentadas de sazonalidade, por exemplo. Como destaque, as séries que apresentaram maior instabilidade foram a dos produtos “A” e “D”. A partir desta análise inicial, é possível identificar que estas variações nas séries causam maior ruído nos dados e conseqüentemente erros maiores.

Partindo para o próximo passo, cada uma das séries temporais foi avaliada no Statgraphics para que os modelos de suavização exponencial e ARIMA apresentados no Capítulo 2 deste trabalho, fossem testados e ajustados para assim identificar o mais adequado e que melhor se ajustava à série, conforme será apresentado a seguir.

4.1 – Avaliação do Produto “A”

A partir das séries temporais, os dados foram analisados e ajustados no Statgraphics, resultando assim na identificação dos modelos que melhor se ajustaram a estas séries e que apresentam melhores previsões. Os três modelos com melhor desempenho para o produto A estão apresentados na Tabela 2.

Tabela 2 – Melhores modelos produto A

Modelo	MAPE
Model: ARIMA(1,2,3)x(1,0,0)14 with constant	43,27896
Model: ARIMA(0,2,2)x(1,0,0)14 with constant	47,415266
Model: ARIMA(3,2,2)x(1,0,0)14 with constant	48,398547

Fonte: Autoria própria (2017)

Para fins de análise, os melhores modelos foram primeiramente combinados, gerando assim um conjunto de previsões (período 31 a 36) com seu respectivo MAPE, e por fim, o modelo combinado foi comparado com a previsão realizada pelo cliente a fim de identificar se as previsões realizadas atingiram melhores resultados do que a realizada pelo cliente, utilizando como base de comparação o MAPE. Dessa forma, para o produto “A”, os dados para comparação são encontrados estão apresentados na Tabela 3.

Tabela 3 – Modelos de Previsão Produto “A”

Modelo	MAPE
Combinado	46,364257
Previsão do cliente	38,93885

Fonte: Autoria própria (2017)

De acordo com cada modelo, as previsões encontradas estão apresentadas na Tabela 4, a seguir.

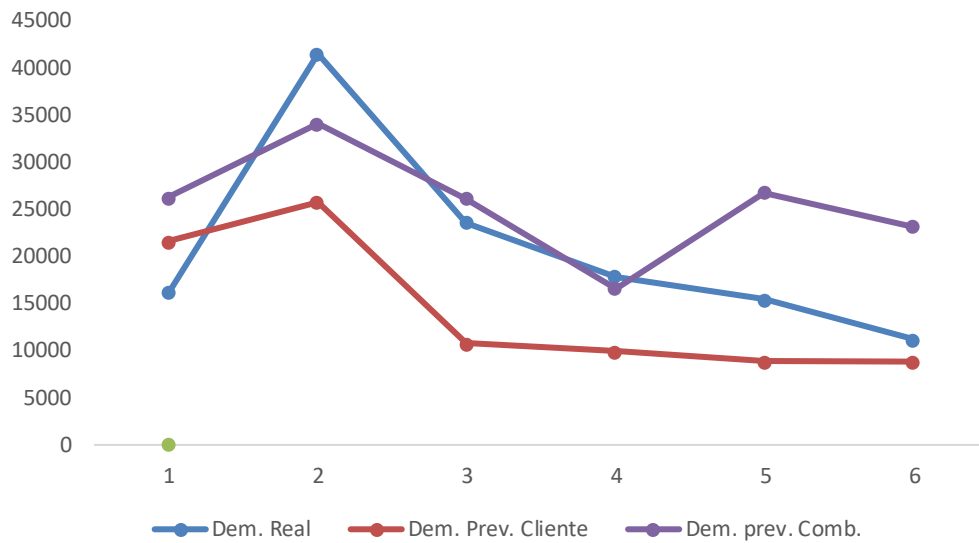
Tabela 4 – Previsões de demanda Produto “A”

Dem. Real	Dem. Prev. Cliente	Dem. prev. Comb.
16221	21628	26246
41532	25772	34120
23582	10757	26133
17869	9942	16577
15436	8892	26778
11229	8847	23246

Fonte: Autoria Própria (2017).

Conforme apresentado na Tabela 3, o modelo combinado obteve um MAPE de 46,364257, enquanto a previsão realizada pelo cliente MAPE igual a 38,93885. Com isso, percebe-se que nenhum dos modelos analisados pelo software foi capaz de igualar ou melhorar as previsões realizadas pelo cliente no período utilizado como base para comparação. A diferença entre as previsões pode ser percebida na representação do Gráfico 03, a seguir.

Gráfico 03 – Previsões para comparação de modelos produto “A”



Fonte: Autoria própria (2017)

A partir das análises realizadas, foi possível então chegar à conclusão de qual modelo é mais adequado para a série temporal, conforme apresentado no Capítulo 4.

4.2 Avaliação do Produto “B”

Assim como feito para o produto “A”, o mesmo procedimento de análise foi realizado para o produto “B”. Com isso, os três melhores modelos estão apresentados na Tabela 5, bem como os respectivos MAPE.

Tabela 5 – Melhores modelos produto “B”

Modelo	MAPE
Model: ARIMA(0,2,2)x(1,0,0)14 with constant	36,807155
Model: Winter's exp. smoothing with alpha = 0,3796, beta = 0,0001, gamma = 0,2884	41,370502
Model: ARIMA(4,2,2)x(1,0,0)14 with constant	67,024552

Fonte: Autoria Própria (2017)

A partir dos modelos identificados, o modelo combinado então pode ser identificado. Na Tabela 6, está apresentado o modelo combinado com seu respectivo MAPE e o modelo utilizado pelo cliente.

Tabela 6 - Modelos de Previsão Produto “B”

Modelo	MAPE
Combinado	27,627698
Previsão do cliente	72,9037

Fonte: Aatoria Própria (2017)

Conforme pode-se perceber, a combinação entre os três melhores modelos encontrados apresentou o menor MAPE, que foi igual a 27,627698. Isso significa que a combinação apresentou erro quase 3 vezes menor do que a previsão do cliente (72,9037). Dessa forma, percebe-se que o modelo utilizado pelo cliente não está de acordo com as características da série temporal, e nem mesmo o especialista foi capaz de ajustar a previsão de acordo com o seu conhecimento e assim melhorar a previsão realizada.

As previsões encontradas para o produto “B” podem ser visualizadas na Tabela 7.


Tabela 7 – Previsões de demanda Produto “B”

Dem. Real	Dem. Prev. Cliente	Dem. prev. Comb.
3501	3456	872
1640	1948	1151
911	1683	968
833	1438	1113
722	1438	701
582	1517	687

Fonte: Aatoria Própria (2017).

A diferença entre as previsões pode ser visualizada com maior clareza no Gráfico 04, onde fica evidente o melhor ajuste que foi encontrado através da previsão combinada. Nos períodos 1 e 2, a previsão do cliente conseguiu se ajustar muito próxima à demanda real, porém a partir do período 3 até o 6, a queda na demanda causada principalmente pela crise econômica não foi identificada pela previsão realizada pelo cliente

Gráfico 04 – Previsões para comparação de modelos produto “B”



Fonte: Aatoria própria (2017)

A partir das análises realizadas, foi possível então chegar à conclusão de qual modelo é mais adequado para a série temporal, conforme apresentado no Capítulo 4.

4.3 Avaliação do Produto “C”

Realizando o mesmo procedimento já apresentado, para o produto “C” foram realizadas as análises e os modelos que melhor se ajustaram estão apresentados na Tabela 7.

Tabela 8 – Melhores modelos produto “C”

Modelo	MAPE
Model: Simple exponential smoothing with alpha = 0,0135	56,3586
Model: Brown's quadratic exp. smoothing with alpha = 0,004	56,41516
Model: Brown's linear exp. smoothing with alpha = 0,0065	56,48191

Fonte: Autoria própria (2017)

Na tabela 9, já estão apresentados os resultados do modelo combinado bem como o modelo utilizado pelo cliente.

Tabela 9 - Modelos de Previsão Produto “C”

Modelo	MAPE
Combinado	56,41856
Previsão do cliente	52,84598

Fonte: Autoria própria (2017)

Conforme percebido pelos dados apresentados na tabela 7, o modelo combinado teve MAPE igual a 56,41856, enquanto a previsão do cliente alcançou MAPE de 52,84598. Com isso, a previsão realizada pelo cliente tem maior precisão do que os modelos encontrados no Statgraphics. As previsões encontradas para o produto “C” podem ser visualizadas na Tabela 10.

Tabela 10 – Previsões de demanda Produto “C”

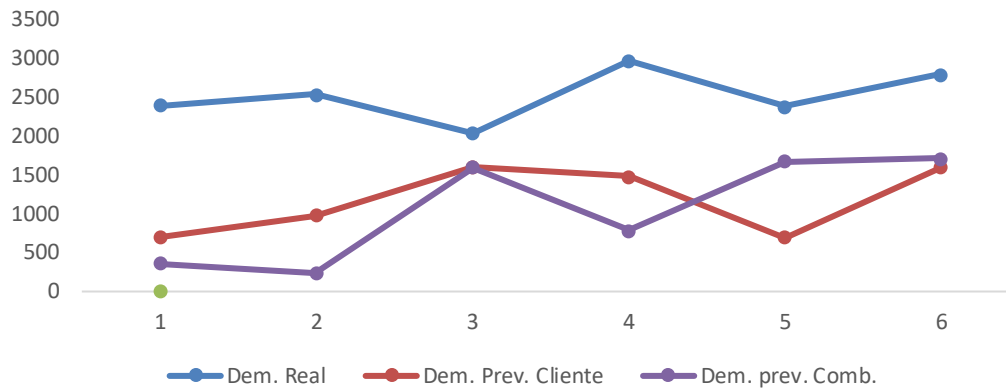
Dem. Real	Dem. Prev. Cliente	Dem. prev. Comb.
2392	700	364
2535	974	237
2037	1603	1602
2971	1483	791
2387	701	1675
2797	1601	1719

Fonte: Autoria Própria (2017).

No gráfico 05, fica evidente as diferenças entre as previsões e a demanda real. Neste produto, uma diferença diferente foi identificada em relação às demais séries analisadas, pois a

demanda real apresentou aumento mesmo no período mais crítico da crise econômica, dificultando assim as previsões que foram realizadas tanto pelo cliente quanto pelo modelo combinado.

Gráfico 05 – Previsões para comparação de modelos produto “C”



Fonte: Autoria própria (2017)

A partir das análises realizadas, foi possível então chegar à conclusão de qual modelo é mais adequado para a série temporal, conforme apresentado no Capítulo 4.

4.4 Avaliação do Produto “D”

Para o produto “D”, as análises realizadas indicaram os modelos da tabela 11 como sendo os de melhor ajuste para a série temporal deste produto, conforme apresentado abaixo.

Tabela 11 – Melhores modelos produto “D”

Modelo	MAPE
Model: ARIMA(1,2,1)x(1,0,0) ₁₂ with constant	25,2941
Model: ARIMA(2,2,1)x(1,0,0) ₁₂ with constant	31,43598
Model: ARIMA(3,2,1)x(1,0,0) ₁₂ with constant	32,13207

Fonte: Autoria própria (2017)

Depois de identificados os três melhores modelo, foi possível então encontrar o modelo combinando bem como comparar o mesmo com o modelo utilizado pelo cliente, conforme apresentado na Tabela 12.

Tabela 12 - Modelos de Previsão Produto “D”

Modelo	MAPE
Combinado	29,33698
Previsão do cliente	53,59258

Fonte: Aatoria própria (2017)

A partir dos dados apresentados na tabela 12, o modelo de previsão utilizado pelo cliente apresentou o pior resultado na comparação. O mesmo apresentou MAPE de 53,59258, erro esse que foi duas vezes maior do que o modelo combinado, que alcançou MAPE de 29,33698. As previsões encontradas para o produto “C” podem ser visualizadas na Tabela 13.

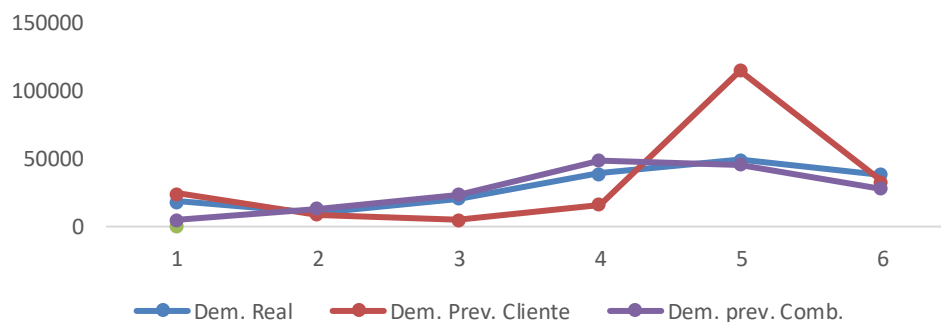
Tabela 13 – Previsões de demanda Produto “D”

Dem. Real	Dem. Prev. Cliente	Dem. prev. Comb.
18140	24187	4962
10108	9085	13129
20629	5068	23376
38827	16625	48561
49329	114653	45402
38438	33416	28007

Fonte: Aatoria Própria (2017).

No gráfico 6, é possível visualizar como a previsão combinada teve bom ajuste para a série temporal, tendo previsões muito próximas a demanda real. Já o modelo de previsão utilizado pelo cliente não teve boas previsões em nenhum dos períodos, sendo que alguns períodos apresentaram previsões menores que o real, já em outras apresentou previsões muito maiores do que a real, com ênfase para o período 5 de comparação, que a demanda prevista pelo cliente gerou grandes transtornos para a aquisição de matéria prima e ajustes na capacidade de fábrica, pois previu alta demanda enquanto o mercado não absorveu tudo o que o cliente pretendia vender.

Gráfico 06 – Previsões para comparação de modelos produto “D”



Fonte: Aatoria própria (2017)

A partir das análises realizadas, foi possível então chegar à conclusão de qual modelo é mais adequado para a série temporal, conforme apresentado no Capítulo 4.

4.5 Avaliação do Produto “E”

Para o produto “E”, os modelos de previsão que melhor se adequaram a série de dados estão apresentados na tabela 14, abaixo.

Tabela 14 – Melhores modelos produto “E”

Modelo	MAPE
Model: ARIMA(4,2,1)x(1,0,0) ₁₂ with constant	50,11510039
Model: ARIMA(3,2,2)x(1,0,0) ₁₂ with constant	51,97525752
Model: Winter's exp. smoothing with alpha = 0,2039, beta = 0,0763, gamma = 0,2402	52,9355895

Fonte: Autoria Própria (2017)

Depois de identificados os três melhores modelo, foi possível então encontrar o modelo combinando bem como comparar o mesmo com o modelo utilizado pelo cliente, conforme apresentado na Tabela 15.

Tabela 15 - Modelos de Previsão Produto “E”

Modelo	MAPE
Combinado	43,58929857
Previsão do cliente	35,87135211

Fonte: Autoria própria (2017)

De acordo com a análise, o modelo de previsão que obteve o melhor resultado foi o que o cliente já utiliza para suas previsões, pois apresentou MAPE de 35,87. Já o modelo combinado alcançou MAPE igual a 43,5892. As previsões encontradas para o produto “C” podem ser visualizadas na Tabela 16.

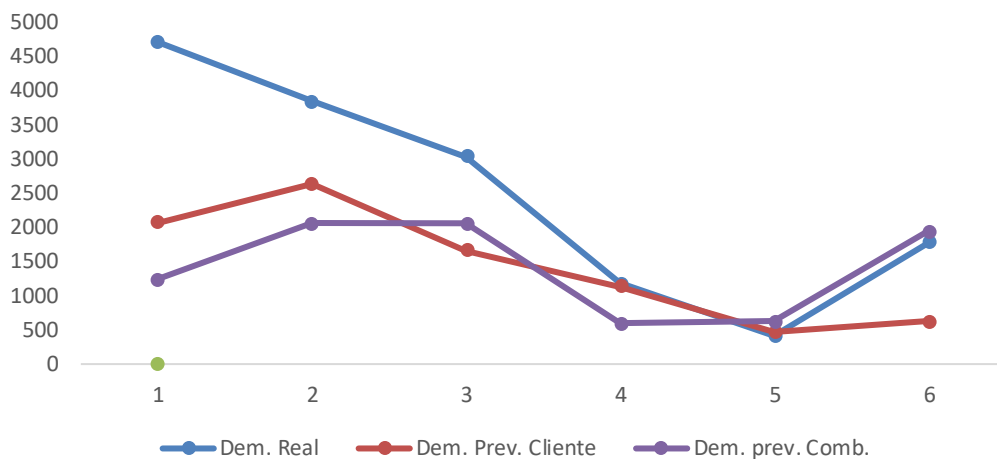
Tabela 16 – Previsões de demanda Produto “E”

Dem. Real	Dem. Prev. Cliente	Dem. prev. Comb.
4710	2067	1242
3844	2635	2055
3039	1665	2060
1180	1130	599
414	470	624
1782	629	1943

Fonte: Autoria Própria (2017).

De acordo com o gráfico 6, o modelo utilizado pelo cliente apresentou melhor resultado principalmente nos períodos 1 e 2 de comparação, e manteve bons resultados nos demais períodos, fazendo assim com que seus ajustes fossem melhores que o modelo combinado. Porém, pode-se notar que o MAPE do modelo combinado é próximo do erro encontrado pelo modelo do cliente, pode-se levantar então a hipótese de que esta diferença se deve pelo conhecimento do especialista, utilizado pelo cliente.

Gráfico 07 – Previsões para comparação de modelos produto “7”



Fonte: Autoria própria (2017)

A partir das análises realizadas, foi possível então chegar à conclusão de qual modelo é mais adequado para a série temporal, conforme apresentado no Capítulo 4.

5 ANÁLISE DOS RESULTADOS

No Gráfico 01, pode-se perceber que a demanda do produto “A” possui grande variação nos meses utilizados como base para formulação dos modelos, variação esta que foi justificada junto à empresa como causada pela crise econômica que afetou o país. Esta característica fica também evidenciada no Gráfico 03, onde a demanda real possui uma queda acentuada nos períodos de 3 a 6, devido aos problemas de mercado enfrentados em época de crise e que a previsão realizada pelo cliente conseguiu se ajustar melhor a esta característica, sendo que este melhor ajuste pode ter ocorrido devido a alguma informação privilegiada que o especialista possuía, vindo a intervir.

Por outro lado, apesar da previsão combinada não ter conseguido atingir erro menor do que a previsão realizada pelo cliente, nota-se que as previsões que apresentaram maior diferença em relação à demanda real foram as previsões dos períodos 5 e 6 da comparação, enquanto os períodos de 1 a 4 apresentaram resultados muito próximos ao real. Isso pode ser explicado pelo agravamento da crise econômica, que o modelo combinado não conseguiu identificar pois a série temporal não demonstrava esta tendência.

Dessa forma, para o produto “A”, a sugestão que deve ser repassada ao cliente no momento é que o mesmo continue utilizando o seu atual modelo de previsão de demanda, que é o mais preciso no momento. Porém, visualizando uma estabilização na demanda, aconselha-se a realizar uma análise em busca de um novo modelo, pois mesmo com a grande instabilidade na demanda, o modelo que melhor se ajustou teve MAPE muito próximo ao que foi previsto pelo cliente, e possivelmente trará resultados melhores no caso da estabilização da demanda.

A partir destas análises, para o produto “B”, a sugestão ao cliente é de que use para as suas previsões a combinação dos três modelos apresentados na tabela 4, para que assim melhore em quase três vezes as previsões que realiza no momento. A melhora na previsão do cliente utilizando o modelo combinado poderia ter resultado em um melhor dimensionamento dos recursos que seriam adquiridos para atender a demanda real que o cliente teve neste período. Utilizando seu modelo, o cliente previu uma demanda muito maior do que a real, causando assim compra excessiva de matéria prima e dimensionamento de mão de obra para a fábrica, gerando custos desnecessários para o CM.

Analisando o produto “C” no atual momento com os dados que foram utilizados como base para análise da série temporal, a sugestão ao cliente é que continue utilizando o seu atual

modelo de previsão, porém com a recomendação de realizar nova análise para encontrar um novo modelo, pois como a diferença foi pequena entre os modelos, uma pequena variação nas características da demanda deste produto pode fazer com que um novo modelo se torne mais preciso do que o atualmente utilizado.

Para o produto “D” recomenda-se para o cliente a utilização do modelo combinado para melhorar suas previsões, pois foi o que apresentou o melhor ajuste em relação à demanda real.

Dessa forma, para o produto “E”, sugere-se ao cliente que continue utilizando temporariamente, o modelo que já utilizava anteriormente, pois no momento é o que melhor atende às características da série de dados deste produto.

6 CONSIDERAÇÕES FINAIS

Após as análises realizadas, pode-se considerar que os resultados obtidos foram satisfatórios e os objetivos propostos de estudar a demanda prevista com o cliente, com o intuito de encontrar pontos de melhoria que auxiliem o cliente a melhorar suas previsões e consequentemente auxiliem na melhoria do planejamento interno, foram atingidos conforme inicialmente planejados. As análises realizadas permitiram conhecer melhor as características de demanda dos produtos em questão e assim melhorar o planejamento que é realizado pela empresa no atual momento.

Apesar de todas as análises terem sido realizadas em um período conturbado da economia brasileira, fato esse que influenciou nos resultados e dificultou a realização de uma análise mais acurada, visualizou-se que existe grande margem para melhoria nas previsões que os clientes realizam atualmente, principalmente se esta mesma análise for realizada periodicamente, buscando uma situação econômica mais estável como momento base para a realização de um novo estudo.

Outro ponto que dificultou as análises do trabalho foi não ter acesso à mais informações sobre como os clientes realizam suas previsões, quais os modelos e métodos que utilizam, pois, tendo esta informação seria possível buscar melhorias também nos modelos que já são utilizados.

Dessa forma, pode-se concluir que este trabalho foi de grande valia para adquirir maior conhecimento em relação as características da demanda da empresa, bem como identificar os possíveis pontos de melhoria. Para o autor do trabalho, a aplicação da pesquisa foi de suma importância para a aplicação dos conceitos aprendidos em sala de aula e possibilitando assim um grande aprendizado e desenvolvimento profissional na área em que o estudo foi aplicado.

Como sugestão para pesquisas futuras, pode-se considerar a oportunidade de testar mais métodos de combinação existentes para se tentar um resultado melhor, visto que a limitação de tempo para realização do trabalho não permitiu que mais métodos fossem testados, ficando assim como oportunidade para um próximo trabalho.

REFERÊNCIAS

- ABURTO, L.; WEBER, R. **Improved supply chain management based in hybrid**. Applied Soft Computing – Elsevier. Chile, n.7, p.136-144, 2007.
- ARMSTRONG, J. S.; COLLOPY, F. **Integration of Statistical Methods and Judgments of Time Series Forecasting: Principles for Empirical Research**. In: WRIGHT, G.; GOODWIN, P. Forecasting with Judgment. Wiley & Sons, 1998.
- BALLOU, R. H. **Gerenciamento da cadeia de suprimentos: planejamento, organização e logística empresarial**. 4. ed. Porto Alegre: Bookman, 2001.
- BOX, G.E.P.; JENKINS, G.M. & REINSEL, G.C. **Time series analysis – forecasting and control**, 3ªed., Prentice Hall, New Jersey. 1994.
- DIAS, M. A. P. **Administração de materiais: uma abordagem logística**. 4. ed. São Paulo: Atlas, 1993.
- FOGLIATTO, Flávio Sanson. *et al.* **Previsão de demanda por energia elétrica – Método e aplicação**. XXV Encontro Nac. de Eng. de Produção – Porto Alegre, RS, Brasil, 29 out a 01 de nov de 2005.
- FURTADO, Maurício Rocha. **Aplicação de um modelo de previsão de demanda total nos credenciados Belgo Pronto**. Curso de Engenharia de Produção da Universidade Federal de Juiz de Fora – MG. 2006.
- HIBON, M.; EUGENIOL, T.. **To combine or not to combine: selecting among forecasts and their combinations**. International Journal of Forecasting. v. 15, p 15-24, 2005.
- HOLLAUER, Gilberto; ISSLER, João Victor; NOTINI, Hilton H. **Previendo o crescimento da produção industrial usando um número limitado de combinações de previsões**. Econ. Apl. vol.12 no.2 Ribeirão Preto, 2008.
- KAHN, K. B. **Benchmarking Sales Forecasting Performance Measures**. The journal of Business Forecasting Methods & Systems, v.17, n.4, p.19-23, winter 1998/1999.
- LIN, Tamy Ymei. **Tema: Estudo de Modelos de Previsão de Demanda**. Escola de Administração de Empresas de São Paulo – Fundação Getúlio Vargas. 2000.
- MAKRIDAKIS, S., WHEELWRIGHT, S.C. & HYNDMAN, R.J. **Forecasting. Methods and applications**. Third Edition. John Wiley & Sons. New York. 1998.
- MILNITZ, Diego; MARCHI, Jamur Johnas; SAMOHYL; Robert Wayne. **Previsão de demanda: uma aplicação do método Holt-Winters em uma indústria têxtil de grande porte**. XXXI Encontro Nacional de Engenharia de Produção. Belo Horizonte, MG, Brasil, 04 a 07 de outubro de 2011.
- MORETTIN, P.A. & TOLOI, C.M. **Análise de Séries Temporais**. Edgar Blucher Ltda. São Paulo. 2004

NGAMPAK, Nittaya; PHRUKSAPHANRAT; Busaba. **Cellular Manufacturing Layout Design and Selection: A Case Study of Electronic Manufacturing Service Plant.** International Multiconference of Engineers and Computers Scientists. 2011.

NOVAES, Mario Lucio de Oliveira; GONÇALVES, Antônio Augusto; GOUVEIA, David Sérgio Adães de; SIMONETTI, Vera Maria Medina. **Utilização dos métodos de suavização exponencial e da média móvel aritmética para a previsão de demandas na área de saúde.** XXVIII ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO. Rio de Janeiro, RJ, Brasil, 13 a 16 de outubro de 2008.

RICHARDSON, Roberto Jarry; **Pesquisa Social: métodos e técnicas.** 2.ed. São Paulo: Atlas, 2012.

PELLEGRINI, Fernando Rezende. **Metodologia para implementação de sistemas de previsão de demanda.** Universidade Federal do Rio Grande do Sul – Programa de pós-graduação em Engenharia de Produção. Porto Alegre. 2000.

PACHECO, Ricardo Ferrari; SILVA, Alisson Vitor Forti. **Aplicação de modelos quantitativos de previsão em uma empresa de transporte rodoviário.** XXIII Encontro Nac. de Eng. de Produção - Ouro Preto, MG, Brasil, 21 a 24 de out de 2003.

PELLEGRINI, F.R. & FOGLIATTO, F. **Estudo comparativo entre modelos de Winters e de Box- Jenkins para a previsão de demanda sazonal.** Revista Produto & Produção. Vol. 4, número especial, p.72-85. 2000.

VASCONCELOS, M. A. S.; ALVES, D. **Manual de econometria: nível intermediário.** São Paulo. Editora Atlas. 2000.

WERNER, Liane. **Um modelo composto para realizar previsão de demanda através da integração da combinação de previsões e do ajuste baseado na opinião.** Universidade Federal do Rio Grande do Sul. Programa de pós-graduação em Engenharia de produção. Porto Alegre, 2004.

WERNER, Liane; RIBEIRO, José Luis Duarte. **Modelo composto para prever demanda através da integração de previsões.** Universidade Federal do Rio Grande do Sul. Produção, v. 16, n. 3, p. 493-509, Set./Dez. 2006.

WERNER, Liane; RIBEIRO, José Luis Duarte. **Previsão de demanda: uma aplicação dos modelos Box-Jenkins na área de assistência técnica de computadores pessoais.** Revista Gestão & Produção. V.10, n.1, p.47-67. 2003.

YAMAMOTO, Ronaldo Nito. **Modelo de previsão de demanda em uma indústria alimentícia utilizando um método quantitativo.** Escola Politécnica da Universidade de São Paulo. São Paulo. 2007.

YIN, Robert K. **Estudo de Caso: planejamento e métodos.** 4. ed. Porto Alegre : Bookman, 2010.