UNIVERSIDADE DE CAXIAS DO SUL PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO MESTRADO PROFISSIONAL EM ENGENHARIA DE PRODUÇÃO

EZEQUIEL BROLLO

METODOLOGIA PARA PREVISÃO DE DEMANDA EM UMA INDÚSTRIA COM CARACTERÍSTICAS DE CUSTOMIZAÇÃO EM MASSA

Orientadora: Prof. Dra. Cíntia Paese Giacomello

BENTO GONÇALVES 2018

EZEQUIEL BROLLO

METODOLOGIA PARA PREVISÃO DE DEMANDA EM UMA INDÚSTRIA COM CARACTERÍSTICAS DE CUSTOMIZAÇÃO EM MASSA

Dissertação apresentada como requisito parcial para a obtenção do título de Mestre, pelo Programa de Pós-Graduação em Engenharia de Produção da Universidade de Caxias do Sul – UCS

Orientadora Prof. Dra. Cíntia Paese Giacomello

BENTO GONÇALVES 2018

Dados Internacionais de Catalogação na Publicação (CIP) Universidade de Caxias do Sul Sistema de Bibliotecas UCS - Processamento Técnico

B867m Brollo, Ezequiel

Metodologia para previsão de demanda em uma indústria com características de customização em massa / Ezequiel Brollo. – 2018. 65 f.: il.; 30 cm

Dissertação (Mestrado) - Universidade de Caxias do Sul, Programa de Pós-Graduação em Engenharia de Produção, 2018. Orientação: Cíntia Paese Giacomello.

Administração da produção.
 Planejamento da produção.
 Engenharia de produção.
 Giacomello, Cíntia Paese, orient.
 II. Título.

CDU 2. ed.: 658.5

EZEQUIEL BROLLO

METODOLOGIA PARA PREVISÃO DE DEMANDA EM UMA INDÚSTRIA COM CARACTERÍSTICAS DE CUSTOMIZAÇÃO EM MASSA

Dissertação apresentada como requisito parcial para a obtenção do título de Mestre, pelo Programa de Pós-Graduação em Engenharia de Produção da Universidade de Caxias do Sul – UCS.

Prof. Dra. Cíntia Paese Giacomello Universidade de Caxias do Sul – UCS Prof. Dr. André Luis Korzenowski Universidade do Vale do Rio dos Sinos – UNISINOS Prof. Dr. Gabriel Vidor Universidade de Caxias do Sul – UCS

Prof. Dr. Leonardo Dagnino Chiwiacowsky Universidade de Caxias do Sul – UCS

Aprovada em 29 de maio de 2018

BENTO GONÇALVES
2018

RESUMO

Nos dias atuais a personalização de bens e serviços, idealizada por meio dos conceitos de Customização em Massa, tem se tornado uma importante estratégia da indústria na busca de mecanismos para se manter competitivo no mercado. Esta estratégia implica em uma nova realidade no que tange os desafios para Gestão de Operações das companhias, visto que, torna-se necessário desenvolver novos mecanismos para gerenciamento do negócio. Este trabalho aborda este tema propondo um método para previsão de demanda de produtos finais considerando um cenário onde existe uma ampla oferta de combinações de itens customizados e um ambiente com sazonalidade. Propõe-se a combinação entre o método de agrupamento por correlação e uso do modelo ARIMA para previsão de demanda. A acurácia da previsão proposta pelo método obteve melhor desempenho em comparação com a utilizada na empresa em grupos responsáveis por 85% das vendas. O MAPE obtido com a metodologia proposta foi de 33,6% em comparação a 69,7% da metodologia existente na empresa. Os resultados comprovam a possibilidade de um melhor desempenho na definição de itens que devem ser produzidos para estoque em momentos que a demanda do mercado não atinge os níveis da capacidade de produção da empresa, garantindo que o custo e o prazo de entrega, características dos ambientes de Customização em Massa sejam atendidos, pois permitem que um maior número de itens seja considerado na previsão.

Palavras-chave: Customização em Massa; Gestão de Operações, Previsão de Demanda.

ABSTRACT

Nowadays, the goods and services customization, introduced through the Mass Customization concepts, has become an important industry strategy in the search for opportunities to remain competitive in the market. That strategy implies a new reality regarding the challenges for Companies Operation Management whereas it becomes necessary to develop new business management methodologies. This Master Dissertation proposes a demand forecast methodology for seasonal customized items. The model considers a scenario where there is an ample offer of combinations for customized items and a seasonal environment. It is proposed the combination between of correlation clustering method and ARIMA model to forecast demand. The accuracy of the proposed forecast method performed is better than the current company method in clusters that represent 85% of sales. The MAPE resulted from the proposed demand forecast methodology was 33.6% in comparison of 69.7% obtained from company methodology. That results indicate a possibility of better adjustment in the items set that must be produced for inventory when the market demand does not reach the company production capacity level, guaranteeing cost and delivery time, characteristics of Mass customization environments to be reached because it allows a bigger number of items to be considered in the forecast.

Key – words: Mass Customization; Operation Management; Demand Forecasting.

LISTA DE FIGURAS

Figura 1: Representação de agrupamentos por Dendograma	24
Figura 2: Direção dos passos nos Métodos Hierárquicos	25
Figura 3: Demonstração de operação do k-means	28
Figura 4: Etapas de funcionamento do método	39
Figura 5: Número de itens em intervalos sem venda	44
Figura 6: Distribuição dos itens nos agrupamentos	46
Figura 7: Análise gráfica do Grupo 1	46
Figura 8: Série temporal do somatório dos itens por grupo	47
Figura 9: Gráfico de representatividade da demanda por grupo	48
Figura 10: Valores previstos e realizados no Grupo 1	51
Figura 11: Método para previsão de itens customizados em massa	52

LISTA DE TABELAS

Tabela 1: Leiaute da tabela de dados extraídos	40
Tabela 2: Representação da caracterização do novo item	41
Tabela 3: Parâmetros de treinamento dos modelos ARIMA	49
Tabela 4: Tabela de erros de previsão	50

LISTA DE QUADROS

Quadro	1: Agrupamento	de tópicos para	a área de pesquis	a15	

SUMÁRIO

1 INTRODUÇÃO	11
1.1 CONTEXTUALIZAÇÃO DO TRABALHO	12
1.2 JUSTIFICATIVA	14
1.3 QUESTÃO DE PESQUISA	16
1.4 OBJETIVOS	17
1.4.1 Objetivo Geral	17
1.4.2 Objetivos Específicos	17
2 FUNDAMENTAÇÃO TEÓRICA	18
2.1 CUSTOMIZAÇÃO EM MASSA	18
2.2 ANÁLISE DE AGRUPAMENTOS	22
2.2.1 Métodos hierárquicos de agrupamento	24
2.2.2 Métodos não-hierárquicos de agrupamento	26
2.3 MÉTODOS DE PREVISÃO	
2.3.1 Séries Temporais	30
2.3.2 Modelos de Box e Jenkins	33
3 METODOLOGIA	37
3.1 MÉTODO DE PESQUISA	37
3.2 MÉTODO DE TRABALHO	38
4 IMPLEMENTAÇÃO	43
5 CONCLUSÕES	53
REFERÊNCIAS	56
APÊNDICE A	60
APÊNDICE B	61
APÊNDICE C	62

1 INTRODUÇÃO

A Customização em Massa (CM) foi proposta e definida por Davis (1989) como a capacidade de produzir bens e ou serviços que visem atender as necessidades específicas de cada cliente em requisitos como custo e prazo de entrega compatíveis aos de produtos fabricados em massa. De modo mais abrangente o conceito de CM pode ser definido como uma estratégia empresarial com foco em fornecer produtos e serviços que satisfaçam as necessidades individuais dos clientes (BROWN; BESSANT, 2003; JIAO; MA; TSENG, 2003).

O desenvolvimento deste conceito revela que as organizações têm se apropriado de forma distinta de seus conceitos, uma visão voltada a avaliar e adequar processos internos e suas características, perspectiva interna, e outra voltada para analisar o mercado e sua dinâmica, perspectiva externa.

Estudos sob a perspectiva interna focam na otimização da configuração dos produtos e serviços por meio de algoritmos. Esses estudos lidam com modelos em que se incluem ou se retiram itens de uma configuração padrão de tal forma a melhorar o desempenho de uma função objetivo, resultando em menor custo ou maior lucro (ALJOREPHANI; ELMARAGHY, 2016; BRUNOE; NIELSEN, 2016; MOURTZIS; DOUKAS; PSAROMMATIS, 2013; VIDOR; MEDEIROS; CRUZ, 2015).

No que se refere à perspectiva externa, uma das formas de análise é em relação ao envolvimento e ao atendimento das necessidades do cliente (PAN; HOLLAND, 2006; YOO; PARK, 2016) e à consequente segmentação do mercado (BARDAKCI; WHITELOCK, 2003, 2004), sendo que cada uma destas segmentações de mercado podem ser entendidas também como um nível de customização a ser implementado pela empresa.

Em relação à forma como a empresa organiza sua estratégia de customização, ambas perspectivas, a interna e a externa, são necessárias, pois associado a elas existe o paradoxo de o quanto a empresa quer *versus* o quanto é possível customizar (VIDOR, 2014). De fato, a esta possibilidade de customização é atribuído um nível que permite o uso de técnicas de gestão de operações consolidadas ou demandará o desenvolvimento de outras técnicas (DURAY, 2002).

Uma vez que a perspectiva de empresa é definida, torna-se necessário a avaliação de uma série de fatores internos, dentre esses fatores estão a gestão da

produção, o *mix* de produtos, os níveis de estoque e a gestão da demanda, todos aspectos ligados à gestão de operações.

Neste trabalho, o foco está na perspectiva externa, especificamente no que se refere à previsão de demanda para os itens de venda da empresa para posterior definição da melhor composição do estoque dentro de um ambiente de customização em massa. Para desenvolver esta temática, o presente trabalho está dividido cinco capítulos, sendo que o primeiro compreende uma introdução ao tema de estudo seguido pela contextualização do problema e sua justificativa. Ainda no primeiro capítulo é apresentada a questão de pesquisa e os objetivos geral e específicos. No segundo capítulo é apresentada uma revisão da literatura sobre os temas abordados na construção da metodologia proposta pelo presente trabalho. No capítulo três é apresentada a metodologia desenvolvida para aplicação no problema da empresa, onde são desenvolvidas as etapas propostas para sua resolução. O capítulo quatro trata dos resultados obtidos na aplicação da metodologia e o quinto capítulo são apresentadas as considerações e contribuições deste trabalho.

1.1 CONTEXTUALIZAÇÃO DO TRABALHO

A CM vem sendo utilizada por um número crescente de companhias como uma importante estratégia para alavancar a competitividade e prover alto nível de flexibilidade às empresas (DA SILVEIRA; FOGLIATTO; FENDYUR, 2016). Estudos evidenciam que a adoção da CM está sendo a opção estratégica adotada por empresas dos mais variados ramos da atividade econômica (DAABOUL; DA CUNHA, 2014; MACHADO; MORAES, 2008) desde grandes conglomerados empresariais até pequenas e médias empresas, evidenciando sua adaptação e benefícios a uma ampla gama de negócios (BRUNOE; NIELSEN, 2016).

Duray et al. (2000) observa que a utilização de modulações é o caminho para viabilizar a adoção da estratégia de CM e apresenta um conceito de modulação por *mix* onde componentes padronizados são combinados dando origem a um novo produto.

A empresa Telasul local onde este trabalho será aplicado, possui 45 anos de história e atualmente é a terceira maior fabricante de cozinhas de aço do país. Seus produtos nascem do conceito de modularização detalhado por Duray et al. (2000),

onde a intercambialidade dos componentes entre os diferentes módulos de venda é um característica fundamental para a redução da quantidade de *part numbers* a serem manufaturados e otimização dos recursos de manufatura. Porém, mesmo adotando esta estratégia de modularização nos *part numbers*, devido as características do mercado de atuação é necessário oferecer produtos customizados, de modo que, em localidades onde existam mais de um varejista concorrente, ambos possam ofertar produtos diferenciados mesmo em se tratando de uma mesma modulação. A diferenciação implementada diz respeito aos diferentes *designs* no acabamento das portas de cada módulo, criando assim uma grande variedade de códigos finais de venda para os produtos.

A ampla oferta de combinações associada à necessidade de atender a altos volumes de produção, que por sua vez deriva da demanda de consumo externo e da necessidade de custos reduzidos, exige alta performance operacional. Isso significa dizer, um elevado nível de ocupação (maior eficiência) dos recursos de manufatura disponíveis. A ocupação é uma relação direta entre a demanda e a capacidade, e desta forma, toda vez que existe algum nível de sazonalidade na demanda do mercado, para equalizar a ocupação aos níveis planejados de produção, é necessário fabricar produtos para acrescentar ao estoque ou utiliza-lo como buffer para atendar a volumes maiores que a capacidade. O que ocorre é que o elevado *mix* de produtos comercializados, associado à inexistência de uma metodologia apropriada para este fim, torna a previsão de demanda dos produtos que devem ser produzidos para estoque uma tarefa complexa. Atualmente esta operação resulta em estoques internos que não potencializam a venda em um momento futuro, por ficarem restritos a uma baixa quantidade de itens que possuem grande representatividade de venda no aspecto de volume, porem baixa abrangência em relação a quantidade de itens que são ofertados pela empresa.

Nesse contexto, portanto, um dos desafios encontrados na gestão de operações da empresa é dado pela complexidade em definir qual o *mix* de produtos que deve ser produzido para estoque em períodos de demanda externa abaixo da capacidade de produção. A complexidade na determinação dos produtos é originada em função do elevado número de produtos finais disponíveis no *portfólio* da empresa e da necessidade de produzi-los de maneira balanceada para atender a demanda em períodos onde a sazonalidade de mercado gera demanda acima da capacidade de

produção. Nestes casos, o estoque atua como nivelador entre o mercado e a capacidade produtiva planejada.

1.2 JUSTIFICATIVA

A CM é um tema que tem tido reconhecimento na academia desde a década de 1980. Dois trabalhos destacam esta trajetória e cobrem um período de 21 anos de publicações na área. O primeiro foi publicado no ano de 2001 (DA SILVEIRA; BORENSTEIN; FOGLIATTO, 2001) e o segundo publicado no ano de 2012 (FOGLIATTO; DA SILVEIRA; BORENSTEIN, 2012). Neles os autores apresentaram duas extensas revisões sistemáticas acerca do tema CM. Após análise e categorização das publicações os autores propuseram quatro grandes áreas de pesquisa em CM, sendo elas definidas como segue: aspectos econômicos em CM, fatores de sucesso em CM, habilitadores para implementação da estratégia em CM e interação entre consumidores e indústria em CM.

Para a análise das recentes publicações acerca do tema em questão, realizou-se uma pesquisa na base de dados *Science Direct* com as seguintes condições de parâmetros como filtro:

- a) pesquisar por "mass customisation" ou "mass customization",
- b) pesquisar em títulos, palavras chave e resumos,
- c) selecionar somente "artigos",
- d) período de busca a partir de 2010 até o presente.

A pesquisa resultou em 239 trabalhos que foram automaticamente agrupados em 20 diferentes tópicos por metodologia própria da base de dados *Science Direct*. Cada um destes 20 tópicos foi alocado a uma das quatro áreas de pesquisa apresentadas, e as relações são apresentadas no Quadro 1.

Artigos da área de pesquisa "aspectos econômicos relacionados a ambientes de CM" possuem ênfase em estudos que avaliam métodos para determinação do custo de produção e o *trade-off* entre os preços de produtos *premium* e os custos de produção (ALJOREPHANI; ELMARAGHY, 2016; ÜLKÜ; HSUAN, 2017), assim como na determinação dos diferenciais que se transformam em valor percebido para os consumidores (YOO; PARK, 2016).

A área de pesquisa "fatores de sucesso em CM" desenvolve estudos onde são analisadas quais são as práticas empresariais que provem um ambiente com melhores condições de sucesso na implementação de estratégias de CM. Estes estudos se desenvolvem em diferentes aspectos do negócio e abordam análises que avaliam melhores práticas em gestão de equipes (ZHANG; ZHAO; QI, 2014), a relevância e consequente implicação da gestão da qualidade na cadeia de fornecedores (ZHANG et al., 2017) e organização dos métodos de manufatura (LUŠIĆ et al., 2015; ZHANG; ZHAO; QI, 2014).

Quadro 1: Relação entre tópicos e número de artigos com a área de pesquisa

Tópicos Science Direct	Nº	Área de Pesquisa
Consumidor	6	Aspectos econômicos em CM
Personalização	6	Aspectos econômicos em CM
Customização em Massa	17	Fatores de sucesso em CM
Cadeia de Fornecimento	16	Fatores de sucesso em CM
Produção	10	Fatores de sucesso em CM
Empresas	4	Fatores de sucesso em CM
Produto	53	Habilitadores para implementação da estratégia em CM
Manufatura	24	Habilitadores para implementação da estratégia em CM
Design	15	Habilitadores para implementação da estratégia em CM
Montagem	8	Habilitadores para implementação da estratégia em CM
Sistemas de Manufatura	8	Habilitadores para implementação da estratégia em CM
Massa	7	Habilitadores para implementação da estratégia em CM
Design Axiomático	5	Habilitadores para implementação da estratégia em CM
Robô	5	Habilitadores para implementação da estratégia em CM
Clientes	14	Interação entre consumidores e fabricantes
Sistemas	9	Interação entre consumidores e fabricantes
Serviços	6	Interação entre consumidores e fabricantes
Familia de Produtos	5	Interação entre consumidores e fabricantes
Conferências	4	Não categorizado
Estado da Arte	4	Não categorizado

Fonte: o autor

A viabilidade de aplicação da estratégia de CM é um fator crítico que deve ser avaliado com rigor por qualquer empresa que decida adotar esta estratégia em seu negócio. A área de estudo "habilitadores para implementação da estratégia em CM" se dedica a analisar quais são os recursos necessários para que uma empresa opere em ambientes de CM. Exemplos de estudos nesta área abordam temas como sistemas de manufatura flexível (LAFOU et al., 2016), tecnologias aplicadas à manufatura e o planejamento de atividade produtivas (MICHNIEWICZ; REINHART; BOSCHERT, 2016) e sistemas robustos para projeto e desenvolvimento de novos produtos (BONEV et al., 2015; SHIH, 2011).

A estratégia de CM carrega intrínseca ao seu conceito um estreito laço de relacionamento entre cliente e indústria. Esta característica é pesquisada na área definida com "interação entre consumidores e fabricantes" onde mecanismos tecnológicos que permitem um completa interação entre as partes são estudadas e desenvolvidas de modo a facilitar a customização de produtos por meio de configuradores (TRENTIN; PERIN; FORZA, 2013).

Percebe-se, portanto, uma prevalência associada à temática que estuda os habilitadores para implementação da estratégia em CM que contempla 125 dos 226 artigos selecionados, em segundo lugar estão os artigos que avaliam os fatores de sucesso em CM com 47 artigos publicados, em terceiro ficam os estudos relacionados à interação entre consumidores e fabricantes com 34 artigos publicados e por fim os estudos relacionados a aspectos econômicos em CM com 12 artigos publicados evidenciando assim que a área de gestão de operações carece de pesquisa no que se refere a CM.

Na análise desta produção para esta base, não foram identificados artigos que tratassem do tema desta dissertação, que é a determinação do estoque de produtos, considerando um ambiente de CM. Assim, o presente trabalho justifica-se pela necessidade de estudos com avaliação modelo para previsão de demanda em empresas que atuam com estratégia de CM. Mourtzis (2016) em recente revisão da literatura corrobora com o aspecto acima intuído, afirmando que existe uma carência estrutural no desenvolvimento de ferramentas que possam ser aplicadas em todos os níveis: estratégico, tático e operacional da gestão de operações. Nesse sentido fica evidente que a área de gestão de operações carece de maior detalhamento e estudo e vem de encontro ao tema desta dissertação de mestrado, visto que o estudo de caso utilizado está associado a esse contexto.

1.3 QUESTÃO DE PESQUISA

Dentre o apresentado nas seções anteriores, entende-se como questão de pesquisa para essa dissertação: qual a forma de prever o estoque dos produtos finais em um ambiente com características de customização em massa?

1.4 OBJETIVOS

Nessa seção são apresentados os objetivos geral e específicos da dissertação.

1.4.1 Objetivo Geral

O objetivo geral desse trabalho é aplicar uma metodologia de previsão de demanda para produtos customizados em massa.

1.4.2 Objetivos Específicos

Para viabilizar a esse objetivo geral o trabalho foi organizado por meio objetivos específicos, são eles:

- 1) classificar em categorias os itens customizados em massa;
- 2) verificar o comportamento da demanda de cada categoria de itens customizados em massa;
- realizar a previsão da demanda das categorias de itens customizados em massa;
- 4) avaliar os ganhos obtidos na implantação do método de previsão de demanda.

2 FUNDAMENTAÇÃO TEÓRICA

Este capítulo apresenta os principais conceitos utilizados ao longo da apresentação da metodologia proposta neste trabalho. Inicialmente apresentam-se as características de um ambiente de customização em massa como forma de elucidar quais fatores e comportamentos são encontrados em empresas que optam pela estratégia. Na sequência são abordados aspectos relativos à aplicação das ferramentas de análise de agrupamentos, que permitirá classificar os itens em grupos e os métodos de previsão de demanda.

2.1 CUSTOMIZAÇÃO EM MASSA

Muitos conceitos acerca do termo Customização em Massa (CM) tem sido discutidos deste sua primeira apresentação na literatura, quando proposta foi definida por Davis (1989).

Como apresentado na introdução deste trabalho, a CM inicialmente foi definida como a capacidade de produzir bens e ou serviços que visam atender as necessidades específicas de cada cliente atendendo requisitos como custo e prazo de entrega compatíveis aos de produtos fabricados em massa (DAVIS, 1989).

Em essência o conceito deve ser entendido como uma estratégia empresarial com foco em fornecer produtos e serviços que satisfaçam as necessidades individuais dos clientes (BROWN; BESSANT, 2003; JIAO; MA; TSENG, 2003) obtendo-os por meio de estratégias de produção que otimizem custo e o inventário (FOGLIATTO; DA SILVEIRA; BORENSTEIN, 2012).

Dado a complexidade em se obter produtos e serviços que atendam estas características em um contexto empresarial / industrial, e tendo em vista o alto nível de recursos envolvidos desde o momento em que cliente inicia o processo de compra de um produto até a entrega desse bem, inúmeros estudos tem propostos fatores que seriam diferenciais e ou facilitadores ao se adotar esta estratégia empresarial. Estes fatores nada mais são do que características que medem o quão adequado está o processo da organização a operar na estratégia de CM, e por esse motivo, são denominados fatores habilitadores para CM. A revisão sistemática apresentada por Fogliatto, Da Silveira e Borenstein (2012) elenca oito habilitadores, que são:

metodologias de produção, elicitação de pedidos, postergação de processo, plataforma de produtos, programação da produção, gestão da cadeia de suprimentos, tecnologias de fabricação e tecnologia de informação.

- Metodologias de produção diz respeito à utilização de conceitos e métodos de produção enxuta, e produção ágil no desenvolvimento dos produtos e serviços da empresa;
- 2) Elicitação de pedidos representa estratégias e ou mecanismos que visam permitir a interação do consumidor no processo de definição ou especificação do produto a que deseja obter;
- 3) Postergação de processo é a capacidade que permite a fabricação de partes intermediárias do produto sem atribuir as características finais ao mesmo, e desta forma adiando ao máximo o momento da customização. Esta característica pode ser entendida como o mais importante habilitador para CM;
- 4) Plataforma de produto ou arquitetura de produtos avalia o nível de modularização do *mix* de produtos, ou seja, o grau de padronização de componentes base que pode dar origem a novos itens customizados por meio de configurações definidas pelo usuário;
- 5) Programação da produção trata das tecnologias e ferramentas para programação e controle de produção. Tendo em vista o alto número de variáveis e restrições que podem ser demandados na fabricação de itens customizados é necessário a adoção de ferramentas de sequenciamento de produção e estratégia de produção que permitam produzir contra pedido;
- 6) Gestão da cadeia de suprimentos tem se tornado crucial para implementação da CM pois o fornecedor tem papel relevante em fatores como nível de inventário e *leadtime* de entrega dos produtos;
- 7) Tecnologias de fabricação trata da utilização de ferramentas e tecnologias que permitam o gerenciamento assistido de processos CAM (computer aided manufacturing) e projeto assistido CAD (computer aided design);
- 8) Tecnologia de informação são recursos que proporcionam velocidade na interação entre os consumidores e a fabricante, esses recursos vão desde sites de *e-commerce* a complexos configuradores de produto *online*. Neste habilidade também são avaliados sistemas de informação referentes ao

negócio como por exemplo software de gestão os ERP (*enterprise resource* planning)

Existe ainda uma categorização atribuída às empresas em função de como a CM ocorre no ambiente do negócio. Esta categorização pode ser avaliada a partir de duas perspectivas, uma interna, que aborda aspectos relacionados ao produto e ao processo de fabricação, e uma externa, que aborda uma visão do cliente e seu envolvimento na customização do produto e ou serviço (VIDOR; MEDEIROS; RIBEIRO, 2013).

Na visão interna, Da Silveira, Borenstein e Fogliatto (2001) definem os níveis de customização que podem ser utilizados para classificar as empresas: padronização, utilização, embalagem e distribuição, adição de serviço, adição de trabalho, montagem, fabricação e projeto.

- 1) Nível padronização: fabricação de produtos altamente padronizados, ou seja, com baixíssimo nível de customização sem interferência do cliente;
- Nível utilização: o mesmo produto tem mais que uma utilização e pode ser aproveitado de diferentes formas de acordo com a necessidade de cada cliente;
- 3) Nível embalagem e distribuição: produtos padronizados são adaptados com diferentes embalagens e configurações de distribuição;
- Nível adição de serviços: a customização é ofertada através de um serviço adicional;
- 5) Nível adição de trabalho: o produto padronizado é agregado com complementos antes da entrega ao cliente;
- 6) Nível montagem: produtos diferentes são obtidos por mudanças nos arranjos modulares de montagem;
- 7) Nível fabricação: o projeto é adaptado para que se adeque às preferências do cliente a partir de um projeto inicial;
- 8) Nível projeto: o cliente atua de forma colaborativa no desenvolvimento do projeto, sendo manufatura e entrega de um produto definidas pelas necessidades específicas do cliente.

Na visão externa, Pan e Holland (2006) definem estes níveis de customização em seis graus, que são: captação de cliente, alteração, superficialidade, transparência, adaptação e colaboração.

- Nível captação do cliente: refere-se a entender o mercado e a partir das informações coletadas ajustar o sistema de manufatura de modo a oferecer uma maior variedade de produtos e desta forma permitir que o cliente encontre exatamente o que procura;
- Nível alteração: pressupõe que a prática da customização é fomentada entre os funcionários da empresa de modo a vendê-lo como diferencial para os clientes;
- Nível superficialidade: customização do sistema de distribuição e entrega, dos itens ao cliente final;
- Nível transparência: proporciona aos clientes obter produtos únicos através do monitoramento das necessidades dos clientes;
- 5) Nível adaptação: envolvimento do cliente no desenvolvimento do projeto agregando informações à manufatura e ao pós-vendas;
- 6) Nível colaboração: os clientes desenvolvem o projeto do produto juntamente com a empresa.

Avaliando ambas as visões, é possível deduzir que independentemente do método que se utilize para classificar a empresa quanto ao nível de customização, existe uma convergência de conceitos. Tendo por base este alinhamento, Vidor, Medeiros e Ribeiro (2013) propõe uma simplificação nesta classificação, conforme segue:

- Nível alto: abrange os níveis de projeto, processo, colaboração e adaptação;
- 2) Nível médio-alto: abrange os níveis de montagem e transparência;
- 3) Nível médio-baixo: abrange os níveis adição de trabalho, adição de serviço, embalagem, distribuição e superficialidade;
- 4) Nível baixo: abrange os níveis de adaptação, alteração.

Na proposta de Vidor, Medeiros e Ribeiro (2013) o nível de padronização e captação não são categorizadas em função de representarem características de estratégias de produção em massa e não de customização em massa e desta forma as comprimem para quarto níveis.

2.2 ANÁLISE DE AGRUPAMENTOS

A análise de agrupamento, ou análise de *clustering*, é um procedimento de análise exploratória de dados que é utilizado para ajudar a entender a relação existente entre as características de variáveis analisadas (JAIN, 2010). Estudos utilizando classificação e agrupamentos de dados vem sendo desenvolvidos em diversas áreas da ciência como biologia, astronomia, ciências sociais e engenharia para identificar grupos dentro de populações de modo a maximizar a homogeneidade dos componentes dentro dos grupos ao mesmo tempo que maximiza a heterogeneidade entre os grupos, utilizando por base alguma medida de similaridade obtida das variáveis que descrevem o objeto (HAIR et al., 2010; JAIN, 2010).

A similaridade entre os objetos é uma medida de semelhança entre os objetos a serem agrupados. Segundo Hair et al. (2010) os métodos de cálculo para definição das medidas de similaridade que dominam as aplicações de análises de agrupamento são: medidas correlacionais, medidas de distância e medidas de associação, sendo os dois primeiros métodos aplicados em dados métricos e o terceiro em dados não métricos.

Medidas correlacionais são obtidas por meio do coeficiente de correlação entre os objetos, e desta forma, altos valores de correlação indicam alta similaridade entre os objetos, assim como baixos valores de correlação indicam baixa similaridade entre os objetos (KAUFMAN; ROUSSEEUW, 2005). É importante ressaltar que a medida de correlação não avalia a magnitude do objeto e sim seu padrão de comportamento o que a torna menos usual do que os métodos baseados em distância (HAIR et al., 2010).

A correlação entre duas variáveis x e y é definida pela na Equação (1), denominada de Coeficiente de Correlação de Pearson.

Os valores dos coeficiente de correlação de Pearson estão dentro do intervalo de $-1 \le R \le 1$, sendo que quanto mais próximo de 1 maior o nível de correlação entre os dados, e em se aproximando de -1 indicando um menor nível de correlação (KAUFMAN; ROUSSEEUW, 2005).

$$R(x,y) = \frac{\sum_{i=1}^{p} (x_i - \mu_x)(y_i - \mu_y)}{\sqrt{\sum_{i=1}^{p} (x_i - \mu_x)^2} \sqrt{\sum_{i=1}^{p} (y_i - \mu_y)^2}}$$
(1)

onde:

 x, y, x_i, y_i : valores do i-ésimos atributos das variáveis x, y;

 μ_x , μ_y : médias dos valores das variáveis x, y;

p: número de componentes;

Como mencionado anteriormente, as medidas de distância focam na magnitude do objeto, e desta forma um valor de distância elevado indica uma baixa similaridade, assim como distâncias baixas indicam alta similaridade. Os métodos mais utilizados para medir a distância entres os objetos são: distância euclidiana, distância de Manhattan e distância de Mahalanobis (HAIR et al., 2010; NOVAES, 2002).

A distância euclidiana entre variáveis x e y é definida na Equação (2), e é a mais comumente utilizada.

$$d(x,y) = \sqrt{(x_x - x_y)^2 + (Y_x - Y_y)^2}$$
 (2)

A distância de Manhattan ou também conhecida como *city-block* é uma simplificação da distância euclidiana. Sua aplicação requer atenção pois ela parte da suposição de que as variáveis não correlacionadas, e em casos onde esta premissa não for atendida sua aplicação não válida (HAIR et al., 2010). A distância de Manhattan é definida na Equação (3).

$$d(x,y) = |x_x - x_y| + |x_x - x_y|$$
 (3)

A distância de Mahalanobis é uma medida comumente utilizada e possui o benefício de incorporar um procedimento de padronização sobre os dados, o qual, estabelece uma escala em termos de desvio padrão além de somar variância e covariância acumulada dentro dos grupos de modo a ajustar a intercorrelação entre as variáveis, e desde modo, atribuir mais peso às variáveis no processo de agrupamento. A distância de Mahalanobis é a mais adequada para o cálculo de distância, porém, não está disponível em todos os softwares como uma medida de similaridade (HAIR et al., 2010).

A partir da definição e cálculo da matriz de similaridade, é necessário determinar o método que será utilizado para formação dos grupos significativos de objetos, sendo eles subdivididos em duas grandes categorias: os Métodos Hierárquicos e Nãohierárquicos de agrupamento também conhecidos na literatura como Métodos Particionais (HAIR et al., 2010; JAIN, 2010).

2.2.1 Métodos hierárquicos de agrupamento

Os métodos hierárquicos operam com uma série de sucessivas fusões, conhecidas como métodos aglomerativos, e/ou sucessivas divisões, conhecidas como métodos divisivos (HAIR et al., 2010). Uma característica dos métodos hierárquicos é que não requerem que seja definido um número a *priori* de agrupamentos (HAIR et al., 2010; JAIN, 2010).

Usualmente para se definir os agrupamentos utilizam-se ferramentas gráficas, sendo a mais conhecida e utilizada o Dendograma (JAIN, 2010). O Dendograma é uma representação gráfica em forma de árvore das estruturas que compõem os agrupamentos bem da ordem em que os dados foram agrupados, um exemplo de representação de agrupamentos por Dendograma é apresentado na Figura 1, onde observa-se a relação entre a representação do Dendograma e o agrupamento definido para os dados amostrados, evidenciando graficamente o processo de formação dos grupos, objetivo da aplicação das técnicas de agrupamento.

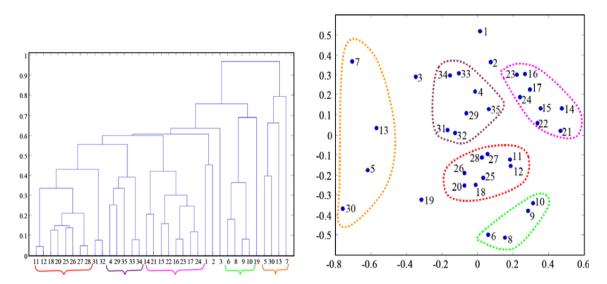


Figura 1: Representação de agrupamentos por Dendograma

Fonte: Adaptado de Jain (2010)

Como mencionado no início desta seção, os métodos hierárquicos possuem dois mecanismos de operação, os métodos aglomerativos e os divisivos. Nos métodos aglomerativos cada objeto inicia o processo representando seu próprio agrupamento de modo que a cada passo do processo os objetos são combinados com os objetos mais próximos formando novos agregados e reduzindo o número de grupos. Os métodos divisivos realizam um caminho oposto aos aglomerativos e iniciam o processo com todos os objetos combinados em um único grupo e a cada passo do processo o grupo é fragmentado dando origem a nos grupos (JAIN; MURTY; FLYNN, 1999). Estes processos são representados de forma esquemática na Figura 2 e o sentido de evolução de cada método é representado pela seta nas laterais do Dendograma.

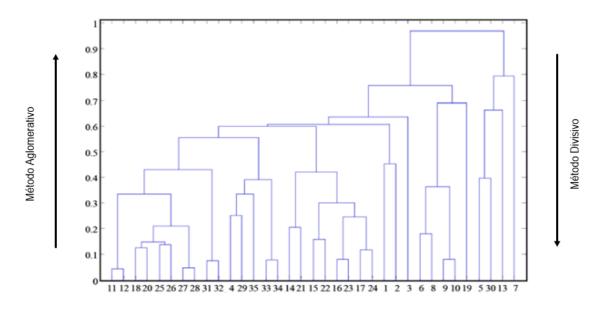


Figura 2: Direção dos passos nos Métodos Hierárquicos

Fonte: Adaptado de Kaufman; Rousseeuw (2005)

Os pacotes computacionais mais utilizados empregam o método aglomerativo, muito pelo fato que ambos os métodos possuem mecanismos de agrupamento similares, sendo de fato um método contrário ao outro em execução e não em resultado. Desta forma, pode-se dizer que o método aglomerativo é o mais utilizado, sendo importante apresentar os principais algoritmos utilizados para criar os agregados, que são: ligação individual, ligação completa, ligação média, método Ward e método centroide (HAIR et al., 2010; JAIN; MURTY; FLYNN, 1999).

1) Ligação individual, também conhecido como método do vizinho mais próximo: encontra os dois objetos separados pela menor distância e os

coloca em um primeiro agrupamento. Em seguida o algoritmo procura novamente a menor distância gerando a possibilidade de um terceiro objeto se juntar os dois primeiros e a criação de um novo grupo com dois elementos. Esta rotina se repete até que todos os objetos se tornem um único agregado. É importante salientar que neste algoritmo a menor distância entre dois agrupamentos é representada pela menor distância entre quaisquer objetos de cada agregado (HAIR et al., 2010; JAIN; MURTY; FLYNN, 1999).

- 2) Ligação completa, também conhecida como vizinho mais distante: utiliza por base a maior distância entre dois objetos, e deste modo esta distância representa o diâmetro mínimo de um esfera que inclua todos os objetos de ambos os grupos (HAIR et al., 2010; JAIN; MURTY; FLYNN, 1999).
- 3) Ligação média: funciona do mesmo modo de uma ligação completa, exceto pelo fato que a distância entre os agregados é obtida pela média das distâncias entre todos os elementos de cada agrupamento. Uma característica deste algoritmo é que, como mencionado acima, o agrupamento é baseado em todos os elementos dos agregados e não somente em uma parte de extremos como na ligação completa e individual (HAIR et al., 2010).
- 4) Método de Ward: a distância entre dois agrupamentos é definida pela soma dos quadrados entre dois agrupamentos feita sobre todas as variáveis (HAIR et al., 2010). Uma característica deste algoritmo é que ele tende a combinar agrupamentos com um número pequeno de objetos (HAIR et al., 2010; JAIN; MURTY; FLYNN, 1999).
- 5) Método centroide: a distância entre dois agrupamentos é a distância entre seus centroides. A vantagem deste algoritmos dá-se pelo fato de ele ser menos influenciado por valores atípicos (ruídos) do que os demais métodos listados (HAIR et al., 2010).

2.2.2 Métodos não-hierárquicos de agrupamento

Os métodos não-hierárquicos são baseados na otimização de uma função objetivo definida localmente, a partir de um subconjunto de objetos, ou globalmente,

definido sobre todos os objetos (JAIN; MURTY; FLYNN, 1999). Os objetos são agrupados em um número k de agrupamentos definido a *priori*, sendo assim, o objeto será alocado no agrupamento que corresponder ao melhor resultado da função entre todos os k grupos definidos (HAIR et al., 2010; JAIN; MURTY; FLYNN, 1999).

Entre as vantagens dos métodos não-hierárquicos em relação aos métodos hierárquicos estão a possibilidade de um objeto poder mudar de agrupamento com a evolução do algoritmo e de apresentar melhor desempenho ao operar com grandes bases de dados (JAIN; MURTY; FLYNN, 1999).

Como desvantagem está o fato de o número de agrupamentos ser definido a *priori*, o que permite ao usuário impor interpretações erradas sobre a estrutura dos dados em casos onde a escolha do número de agrupamentos não seja a ideal, de modo ao método impor uma estrutura aos dados ao invés de buscar a estrutura inerente aos objetos (HAIR et al., 2010).

O algoritmo não-hierárquico mais utilizado para formação de grupos de padrões é o conhecido por k-means. O k-means vem sendo aplicado por mais de 50 anos em praticamente todos os ramos da ciência que tenham necessidade de identificar padrões a partir de uma base de dados. Facilidade de implementação, simplicidade, eficiência e sucesso empírico são as principais razões para sua popularidade (JAIN, 2010).

Diferentemente dos métodos hierárquicos, o k-means não cria uma estrutura em árvore para descrever o agrupamento dos dados. O algoritmo procura a partição tal que o erro quadrático entre a média interna de um agrupamento e os objetos no agrupamento seja minimizado, sendo seu objetivo final minimizar a soma do erro quadrático de todos os agrupamentos (JAIN, 2010).

O erro quadrático interno de um agrupamento k é definido na Equação (4)

$$J(C_k) = \sum_{x_i \in C_k} ||x_i - \mu_k||^2$$
 (4)

onde:

J: erro quadrático interno no agrupamento C_k ;

k: número de agrupamento definidos a *priori*;

 μ_k : média interna dos objetos no agrupamento C_k ;

 $x = \{x_i, i = 1, ..., n: \text{ valor } n\text{-dimensional dos objetos no agrupamento } k;$

 $C = \{C_k\}, k = 1, ..., k$: agrupamento ao qual o objeto x pertence;

Como mencionado, o objetivo final do k-means é minimizar a somas do erro quadrático dos k agrupamentos. Este objetivo é modelado pela Equação (5).

minimizar
$$J(C_k) = \sum_{k=1}^{k} \sum_{x_i \in C_k} ||x_i - \mu_k||^2$$
 (5)

A Figura 3 ilustra o desenvolvimento de um algoritmo k-*means* aplicado a objetos bidimensionais alocados em três agrupadores.

(1) Entrada de objetos (2) Definição das partições (3) Execução 1

Figura 3: Demonstração de operação do k-means

Fonte: Adaptado de Jain (2010)

Um procedimento geral para implementação do algoritmo pode ser descrito nos seguintes passos (JAIN, 2010):

- 1) Selecionar a partição inicial com os k agrupamentos;
- 2) Para cada objeto determinar a partição mais próxima;
- 3) Calcular a nova média de cada partição;
- 4) Repetir os passos 2 e 3 até a estabilidade.

A solução encontrada pelo k-*means* depende do ponto de partida, ou seja, depende da inicialização do problema, sendo necessário definir o número de agrupamentos, a alocação da distribuição inicial dos objetos.

2.3 MÉTODOS DE PREVISÃO

Diante da velocidade experimentada nas mudanças de consumo e competitividade do mercado em geral, é crescente a busca por métodos que auxiliem na redução das incertezas relacionadas à tomada de decisões necessárias na área de operações industriais (PILINKIENĖ, 2015).

As previsões de demanda e venda são importantes métodos disponíveis para as organizações que buscam uma maior estruturação na tomada destas decisões e planejamento, com base em informações oriundas da própria empresa ou do mercado (SLACK; CHAMBERS; JOHNSTON, 2009).

Slack, Chambers e Johnston (2009) afirmam ainda que conhecer apenas que a demanda por produtos e serviços de uma empresa está crescendo ou decrescendo já não basta para um correto planejamento do negócio dada a crescente complexidade do mercado e das operações das empresas.

Para Corrêa, Gianesi e Caon (2007) possuir os meios necessários para prever a demanda é fator determinante para que seja possível antecipar, com alguma precisão, o comportamento do mercado e desta forma atuar por meio de decisões estratégicas no direcionamento do negócio.

Werner e Ribeiro (2003) complementam estas visões dizendo que as previsões contribuem não somente para o direcionamento do planejamento estratégico como também na resolução de problemas de custo prazo das empresas, pois é possível por meio delas observar as tendências do mercado e prover ações.

No que tange aos modelos de previsão, é importante ressaltar, que mesmo aplicando-se modelos estatísticos de alta complexidade, o resultado ainda será uma estimativa de futuro, e desta forma pode ser afetado por um número incalculável de eventos e fatores que podem alterar o comportamento futuro das vendas, exigindo assim, uma análise sistemática dos dados de modo a realizar os ajustes necessários na análise das informações gerenciais (CORRÊA; GIANESI; CAON, 2007; PILINKIENĖ, 2015).

A literatura sobre métodos e modelos de previsão é vasta e desta forma a escolha dos métodos é definida pelo tipo de aplicação ou resposta a que se deseja. Os métodos mais amplamente difundidos e utilizados são os métodos baseados em informações qualitativas e quantitativas (PILINKIENĖ, 2015) ou uma combinação entre ambos (PELLEGRINI; FOGLIATTO, 2001; WERNER; RIBEIRO, 2003).

Os métodos quantitativos utilizam dados históricos, ou seja, acontecimentos passados para determinar o futuro, também muito conhecidos como séries temporais. Já os métodos qualitativos baseiam-se em opiniões de especialistas, e devido ao fato de ser baseado em opinião, fica vulnerável a tendências que podem distorcer ou prejudicar sua confiabilidade (WERNER; RIBEIRO, 2003).

2.3.1 Séries Temporais

Séries temporais são modelos que avaliam um padrão do comportamento passado de um fenômeno no tempo e utiliza esta análise para prever o comportamento futuro desse fenômeno, como por exemplo, o comportamento de vendas de um produto pode ser utilizado para prever sua demanda futura, tomando por base a premissa de que o padrão de comportamento observado no passado forneça informações adequadas para a previsão de valores futuros da demanda (SLACK; CHAMBERS; JOHNSTON, 2009).

A análise de séries temporais parte do pressuposto de que a tendência que gerou a demanda no passado continuará gerando a demanda no futuro. A análise de séries temporais é geralmente utilizada em situações de curto prazo, pois se ocorrerem alterações no ambiente externo elas irão afetar a precisão da previsão (SLACK; CHAMBERS; JOHNSTON, 2009).

As séries temporais podem exibir quatro principais características em seu comportamento, que são: média, sazonalidade, ciclo e tendência (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998; MONTGOMERY; JENNINGS; KULAHCI, 2008).

- 1) média: quando os valores flutuam em torno de um valor constante;
- sazonalidade: quando ocorrem padrões cíclicos de variação se repetindo em intervalos regulares no tempo dentro do período de um ano;
- ciclo: quando ocorrem variações de crescimento e decrescimento, porém em intervalos de tempo maiores;
- tendência: quando a série apresenta comportamento ascendente e ou descendente por um período contínuo de tempo.

Além destas características que podem ser modeladas, existe ainda a presença do ruído aleatório que consiste em variações que não são facilmente explicadas no comportamento da série de dados.

Pellegrini e Fogliatto (2001) expõe que os principais modelos aplicados como métodos para previsão de demanda para dados quantitativos são:

- modelo de suavização exponencial simples: são amplamente utilizados pois possuem uma facilidade de aplicação e ajuste à série de dados, além de boa acurácia;
- modelo de suavização exponencial Linear de Holt: possui melhor ajuste a séries com tendência linear;
- modelo de suavização exponencial sazonal e linear de Winter: possuem boa adaptabilidade para séries que possuem tendência linear com componentes de sazonalidade;
- 4) modelo de decomposição: este método parte do pressuposto que uma série pode ser representada pelos seus componentes de média, sazonalidade, ciclo e tendência separadamente;
- 5) modelos de Box e Jenkins: são modelos que partem da ideia principal de que todos os valores de uma série temporal são dependentes, e desta forma podem ser explicados por valores prévios existentes na série.

A escolha por um método de previsão ou outro dependerá da capacidade do modelo de se ajustar aos dados. Montgomery, Jennings e Kulahci (2008) apresentam que o modelo mais usual para validação e comparação entre métodos de previsão é a quantificação do erro de previsão dada pela Equação (6).

$$e_t(1) = z_t - \hat{z}_t(t-1) \tag{6}$$

onde:

 e_t : erro medido em t;

 z_t : valor real;

 \hat{z}_t : valor previsto;

Para séries com inúmeros períodos de previsão, o erro é medido pela soma dos erros dos diferentes períodos de previsão. Três são os critérios de medição mais

aplicados para este fim, o erro absoluto médio (MAE) dado pela Equação (7) e o erro quadrado médio (MSE) dado pela Equação (8).

$$MAE = \frac{1}{n} \sum_{t=1}^{n} |e_t(1)| \tag{7}$$

onde:

MAE: erro absoluto médio;

$$MSE = \frac{1}{n} \sum_{t=1}^{n} [e_t(1)]^2$$
 (8)

onde:

MSE: erro quadrado médio;

É importante observar que erro médio (ME) avalia o erro com relação a um valor esperado, enquanto o MAE e MSE são medidas de variabilidade dos erros de previsão.

Ainda, como a avaliação de erro pretende apresentar uma medida de acuracidade dos valores previsto, é indicado avaliar o desempenho do método a partir de um indicador que avalia o percentual de erro da previsão, sendo os mais comumente encontrados o erro percentual médio (MPE) dado pela Equação (9) e o erro absoluto percentual médio (MAPE) dado pela Equação (10).

$$MPE = \frac{1}{n} \sum_{t=1}^{n} \frac{e_t(1)}{z_t} 100$$
 (9)

onde:

MPE: erro percentual médio;

$$MAPE = \frac{1}{n} \sum_{t=1}^{n} \left| \frac{e_t(1)}{z_t} 100 \right| \tag{10}$$

onde:

MAPE: erro absoluto percentual médio;

Existem diferentes formas de fazer a previsão de uma série temporal. Os métodos de suavização exponencial simples são utilizados para séries que se mantém constantes em torno de um valor médio. Seus mecanismos utilizam ponderações distintas para cada valor observado na série temporal e funcionam atribuindo maiores pesos para valores mais recentes da série (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998). Os mesmos autores, para séries com tendências lineares, sugerem o uso do modelo de suavização exponencial linear de Holt.

Quando as séries apresentam tendência linear associadas a componentes de sazonalidade o método de Winter é o mais apropriado (PELLEGRINI; FOGLIATTO, 2001). Os modelos de Winter são subdivididos em dois grupos denominados de Modelo de Winter Multiplicativo e Modelo de Winter Aditivo (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998). O modelo de Winter Multiplicativo é utilizado em dados sazonais onde amplitude do ciclo sazonal possui variação em relação ao tempo. O modelo de Winter Aditivo é aplicado em modelagens de dados sazonais onde a amplitude do ciclo sazonal permanece constante ao longo do tempo.

Os modelos de decomposição partem da premissa de que a série temporal pode ser representada e decomposta por seus componentes de sazonalidade, tendência, média, ciclo e ruído aleatório (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998), estes modelos podem ser aditivos ou multiplicativos.

Outra família de modelos de previsão de demanda compreendem os modelos de Box e Jenkins, neste método considera-se que os valores são relacionados ao longo do tempo, sendo ele amplamente utilizados na indústria e o qual será aplicado neste trabalho, e desta forma melhor explorado nesta revisão.

2.3.2 Modelos de Box e Jenkins

Os modelos de Box e Jenkins são mais comumente encontrados na literatura como modelos ARIMA (*Autoregressive Integrated Moving Average*). Modelos ARIMA são baseados na ideia de que valores encontrados em séries temporais são altamente dependentes e desta forma um valor presente pode ser explicado por valores prévios da série (BOX et al., 2016).

A ideia de utilizar modelos matemáticos para determinar o comportamento de fenômenos já é consolidada, porém, nem sempre é possível obter valores exatos em relação ao fenômeno analisado. Sempre que for possível determinar um valor exato para o resultado de um modelo, este modelo será denominado de determinístico, no entanto, quase em sua totalidade os fenômenos são influenciados por variáveis desconhecidas (ruído aleatório) que interferem em seus resultados. Para estes casos os modelos utilizam métodos probabilísticos para determinar o resultado futuro, estes modelos são denominados modelos estocásticos (BOX et al., 2016).

No estudo dos modelos ARIMA é importante diferenciar as séries com comportamento estacionário ou não-estacionário. Modelos estacionários assumem um comportamento de equilíbrio estatístico variando em torno da média e mantendo um desvio constante ao longo do tempo. Na prática porém, os modelos de previsão são aplicados em ambientes reais como da indústria, na economia, e de negócios em geral não seguem este comportamento organizado e constante ao redor de média, e nestes casos são denominados como modelos não-estacionários (BOX et al., 2016).

Desta forma, modelos estocásticos de que uma série temporal z_t com valores altamente dependentes podem ser estimados por meio de uma série de ruído aleatório a_t transformada por meio de uma função linear. A função linear de transformação do ruído aleatório a_t para o processo z_t é definida pela Equação(11), uma função filtro que realiza a soma ponderada dos ruídos aleatórios prévios (BOX et al., 2016).

$$z_t = \mu + \psi_1 a_{t-1} + \psi_2 a_{t-2} + \dots + \psi_n a_{t-n}$$
 ou
$$z_t = \mu + \psi(B) a_t \tag{11}$$

Onde:

μ: parâmetro de nível do processo;

B: operador de defasagem definido por $B^m a_t = a_{t-m}$;

 ψ : função de transferência do filtro $\psi(B) = 1 + \psi_1 B + \psi_2 B^2 + K$.

Modelos oriundos da Equação (11) podem representar séries estacionárias e também séries não estacionárias, sendo necessário avaliar a sequência finita ou infinita de somatório dos módulos de ψ_1, ψ_2, \dots . Caso o valor seja convergente a série z_t é estacionária com média em μ , do contrário, caso tenda ao infinito a série z_t será não-estacionária com média em μ sendo apenas uma referência de nível (BOX et al., 2016).

2.3.2.1 Modelos Autoregressivos

O modelo autoregressivo é um modelo estocástico utilizado na representação de um grande número de séries temporais. Nele o valor do processo é expresso por meio de uma combinação linear finita de valores prévios e por um ruído aleatório a_t . Os valores observados de um processo são definidos em espaços de tempo igualmente definidos t, t-1, t-2, ... e por $z_1, z_{t-1}, z_{t-2}, ...$ e também os desvios com relação a média $\widetilde{z_t}, \widetilde{z_{t-1}}, \widetilde{z_{t-2}}, ...$ dados por $\widetilde{z_t} = z_t - \mu$. O Modelo Autoregressivo de ordem p pode ser estacionário ou não-estacionário e é definido pela Equação (12) (BOX et al., 2016).

$$\tilde{z}_{t} = \phi_{1}\tilde{z}_{t-1} + \phi_{2}\tilde{z}_{t-2} + \dots + \phi_{n}\tilde{z}_{t-n} + a_{t}$$
 (12)

Onde:

 ϕ : coeficiente autoregressivo definido por $\phi(B)\tilde{z}_t = a_t$.

2.3.2.2 Modelos Média Móvel

Nos modelos de média móvel, \tilde{z}_t depende de um número finito q de valores prévios do ruído aleatório a_t . O modelo de média móvel de ordem q é definido pela Equação (13) (BOX et al., 2016).

$$\tilde{z}_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q}$$
 (13)

Onde:

heta: coeficiente de média móvel definido por $ilde{z}_t = heta(B)a_t$.

2.3.2.3 Modelos Misto Autoregressivos e Média Móvel

Com objetivo de encontrar um melhor ajuste a série de dados, algumas vezes é vantajoso utilizar uma combinação dos modelos autoregressivo e de média móvel. A essa combinação é dado no nome de modelo ARMA (*autoressive-moving average*), que é definido pela Equação (14) (BOX et al., 2016).

$$\tilde{z}_{t} = \phi_{1}\tilde{z}_{t-1} + \dots + \phi_{p}\tilde{z}_{t-p} + a_{t} - \theta_{1}a_{t-1} - \dots - \theta_{q}a_{t-q}$$
 (14)

Neste caso o modelo possui p + q + 2 parâmetros desconhecidos que devem ser estimados a partir de valores observados na série temporal (BOX et al., 2016).

2.3.2.4 Modelos Não-estacionários

Para séries com comportamento não-estacionário, em nenhum intervalo de tempo as observações possuem um comportam de acordo com um outro intervalo de tempo distinto, porém, ainda assim podem apresentar um comportamento homogêneo independentemente da média local. Sendo assim, as séries não-estacionárias podem ser representados por meio de um operador autoregressivo generalizado $\varphi(B)$ em que uma ou mais raízes do polinômio sejam igual a 1 em módulo e desta forma caso existam d raízes unitárias o operador $\varphi(B)$ será determinado conforme a Equação (15) (BOX et al., 2016).

$$\phi(B) = \phi(B)(1-B)^d \tag{15}$$

Onde:

 $\phi(B)$: operador autoregressivo estacionário.

Já para caos em que o modelo apresenta comportamento homogêneo e nãoestacionário o operador é definido pela Equação (16) (BOX et al., 2016).

$$\phi(B)w_t = \theta(B)a_t \tag{16}$$

Onde:

 w_t : definido como $(1-B)^d z_t$.

Assim um comportamento homogêneo não-estacionário pode ser representado por um processo estacionário com d níveis de diferenciação. O processo definido na Equação (16) produz um modelo eficiente utilizado para descrever séries temporais estacionárias e não-estacionárias e conhecido modelo ARIMA (*autoregressive integrated moving average*) de ordem p,d,q, sendo desta forma o componentes autoregressivo correspondente a p, o componente de média móvel q e o número de diferenciações d.

3 METODOLOGIA

Com base nos objetivos e no problema de pesquisa apresentados, este capítulo apresenta a metodologia de trabalho utilizada nesta dissertação, cujo objetivo é desenvolver uma metodologia para previsão de demanda para itens de produção em ambientes de Customização em Massa (CM).

Este capítulo é divido em dois aspectos sendo o primeiro referente ao método de pesquisa utilizado, o segundo apresenta a metodologia proposta para o atingimento dos objetivos.

Este trabalho está associado aos temas de interesse da Engenharia de Produção na área de Gestão da Operações.

3.1 MÉTODO DE PESQUISA

A busca por uma resposta ou solução para um problema por meio de procedimentos sistemáticos e racionais é o que caracteriza a pesquisa científica. Uma pesquisa científica é classificada a partir de quatro aspectos, sua abordagem, sua natureza, seus objetivos e métodos utilizados (GERHARDT; SILVEIRA, 2009).

Quanto a sua abordagem uma pesquisa científica pode ser classificada em qualitativa e quantitativa. A abordagem quantitativa é centrada na objetividade dos dados, tendo como característica a possibilidade de mensurar os resultados obtidos, estruturando-os geralmente em linguagem matemática (MIGUEL et al., 2012). Já abordagens qualitativas de pesquisa focam em um entendimento e compreensão do fato pesquisado, sem uma preocupação em mensurá-lo ou quantificá-lo (MIGUEL et al., 2012).

A natureza de uma pesquisa científica pode ser classificada em pesquisa básica, que possui como principal característica construir conhecimento novos contribuindo para o avanço da ciência em um primeiro momento sem a preocupação com uma possível aplicação prática, e a pesquisa aplicada, dirigida para construção de conhecimento por meio de estudo práticos dirigidos à solução de problemas reais (GERHARDT; SILVEIRA, 2009).

Ainda, de acordo com os objetivos de interesse com a pesquisa, a mesma pode ser classificada em três grupos, a pesquisa exploratória, a pesquisa descritiva e a pesquisa explicativa. A pesquisa exploratória tem vistas a explicitar o problema ou formar uma visão inicial sobre o mesmo. A pesquisa descritiva tem como propósito fornecer subsídios para construção de teorias a respeito dos problemas e temas de pesquisa e desta forma foca em entender e descrever o fenômeno observado. Por fim, a pesquisa explicativa ou também confirmatória visa testar conceitos previamente definidos de modo a validá-los por meio de experimentos controlados (GERHARDT; SILVEIRA, 2009; MIGUEL et al., 2012).

Com relação ao procedimento adotado para realização da pesquisa existem diversas possibilidade sendo que o detalhamento de doze procedimentos pode ser estudado no trabalho de Gerhardt e Silveira (2009). Já Miguel et al. (2012) elencam sete procedimentos como os mais presentes em pesquisa na área de engenharia de produção e gestão de operações. O estudo de caso está presente em ambas as relações de procedimentos, sendo definido com um estudo de caráter empírico que investiga um fenômeno real e atual focado na observação de uma unidade, que pode ser uma empresa, um indivíduo, um evento e ou um programa (GERHARDT; SILVEIRA, 2009).

O presente trabalho é classificado quanto a sua abordagem como quantitativo devido à análise de dados numéricos e aplicação de métodos estatísticos que dão conta de uma resposta numérica formada a partir de dados quantitativos observados. Quando a sua natureza, é classificado como pesquisa aplicada visto que será desenvolvido a partir de um problema real contido em um ambiente empresarial. Adotará como procedimento de pesquisa a metodologia de estudo de caso, dado o caráter particular da validação da metodologia proposta.

3.2 MÉTODO DE TRABALHO

Com base na análise das características do problema e a luz do conhecimento científico avaliado, estudado e descrito no capítulo de fundamentação teórica deste trabalho, é agora apresentada uma metodologia para previsão de demanda para empresas que possuem características de CM em sua estratégia de operação. A metodologia é estruturada em oito etapas descritas resumidamente na Figura 4 e detalhadas ao longo desta sessão.

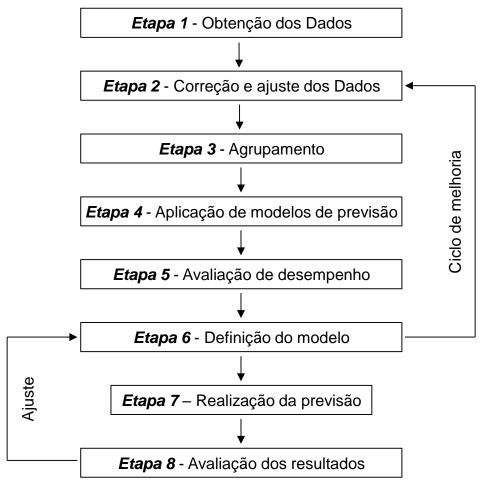


Figura 4: Etapas de funcionamento do método

A empresa onde o trabalho foi implementado opera com o auxílio de um sistema de informação do tipo ERP (*Enterprise Resource Planning*) desenvolvido pela empresa Focco Sistemas de Gestão. Esse sistema integra todos os processos de negócio da empresa, e desta forma todos os dados gerados pelas operações diárias são armazenados em um banco de dados.

Diariamente uma quantidade expressiva de dados são produzidos, os quais, quando organizados de maneira lógica podem apresentar informações relevantes para os diferentes processos do negócio.

Para a etapa 1, a obtenção dos dados relevantes para a aplicação da metodologia de previsão, os dados foram extraídos do banco de dados como auxílio de um *script*, o qual foi desenvolvido de modo a organizar os dados de venda da empresa em uma tabela simplificada e desta forma apresentar somente dados úteis para a aplicação da metodologia de previsão proposta. O leiaute dos dados a serem extraídos é apresentado na Tabela 1.

Tabela 1: Leiaute da tabela de dados extraídos

cod_item	data_carga	mes	ano	sub_familia	tam	linha	qtde_ped
item 1	data 1	1	2014	Armário	40	linha 1	Х
item 2	data 2	2	2015	Balcão	35	linha 2	X
item	data		2016	Aéreo	35	linha	X
item n	data n	n	2014	Paneleiro	40	linha n	X

Ainda, com o objetivo de eliminar da análise dos dados a interferência de itens não mais comercializados pela empresa e também garantir a existência de ao menos três períodos completos de tempo para a construção da previsão, serão implementados dois filtros no *script*, o primeiro visa extrair dados realizados dentro do período de 01 de janeiro de 2013 e 31 de dezembro de 2016 e o segundo visa excluir informação de itens fora de linha, ou seja não mais comercializados, da análise.

A etapa 2 – correção e ajuste dos dados, será utilizada para realizar a preparação dos dados para a aplicação da técnica de agrupamento e posteriormente o método de previsão. O objetivo dessa etapa da metodologia é encontrar e corrigir valores *outliers* (fora do padrão) existente nos dados extraídos. Segundo Montgomery, Jennings e Kulahci (2008) para esta etapa é necessário examinar toda a base em busca problemas, e desde modo, devem ser identificados todos os potenciais problemas como *missing*, valores fora dos padrões esperados ou com valores atípicos para posterior adequação. Apesar de existirem ferramentas computacionais para realização destas etapas, ferramentas gráficas como gráficos de séries, histogramas e gráficos de dispersão são ainda as mais utilizadas para este fim. Nesta etapa ainda não são tratados os *missings*, fato que será justificado na etapa 3.

Uma das características mais comuns encontradas em empresas que operam na estratégia de CM é a elevada quantidade de diferentes configurações de itens de venda. Por este motivo, é comum a utilização de critérios como o da curva ABC para selecionar os itens relevantes para análise. Neste sistema, opta-se por tratar os itens mais importantes, desconsiderando os itens com baixa representatividade, para reduzir a quantidade de previsões necessárias. Porém, é importante perceber que dada a diversificação inerente ao processo de CM, mesmo lançando mão de técnicas com o objetivo de reduzir a base de itens para análise, a quantidade de itens necessários para compor uma parcela relevante de informação ainda é expressiva, tendo em vista a grande pulverização da venda. Ainda, a quantidade de itens que seriam descartados da análise carrega em si informações importantes sobre o comportamento do negócio avaliado.

Com o objetivo a tratar este problema, a etapa 3 apresenta uma nova abordagem para a redução da quantidade de itens da base de análise. Para tal é proposto a aplicação de análise de agrupamento de modo que os grupos originados serão interpretados como novos itens, os quais representarão as características de comportamento de todos os itens de venda que os compõem. A caracterização deste novo item é definida pela soma da quantidade de venda por período de cada item que compõe cada um dos agrupamentos formados, sendo a Tabela 2 a representação do processo mencionado.

Tabela 2: Representação da caracterização do novo item

Agrupamonto	código item	quantidade do pedido					
Agrupamento		período 1	período 2	período	período n		
1	item x	2		6	2		
1	item y	4	2		6		
1	item w	3	1	4	8		
	novo item	9	3	10	16		

Fonte: o autor (2018)

Neste ponto é importante ressaltar um aspecto que ficou em aberto na etapa 2, a questão dos *missings*. Uma vez que que o novo item é formado pela soma do comportamento de venda de uma série de itens agrupados por similaridade, a tendência é que a existência de *missings* nos novos itens formados seja praticamente eliminada, desta forma justificando a não realização desta operação na etapa 2. Caso ainda existam valores *missing*, o método mais comum utilizado para substituição de um valor é a utilização da média dos valores existentes para definição do novo valor a ser incluído na base. A utilização da média possui como vantagem a sua relativa facilidade de aplicação e cálculo, assim como o fato de não alterar o comportamento da série caso a mesma não possua tendência ou padrão sazonal. Já para séries que onde as características de tendência e sazonalidade estão presentes, é necessário lançar mão de uma variável aleatória a ser adicionada ao valor médio de modo a permitir incorporar na série as características de tendência e sazonalidade (MONTGOMERY; JENNINGS; KULAHCI, 2008).

Na análise de agrupamentos, etapa 3, é aplicado o método hierárquico de modo a identificar e formar os agrupamentos utilizando como medida a correlação existente entre o comportamento de venda dos itens ao longo do período.

A etapa 4 – aplicação dos modelos de previsão, inicia-se pela análise gráfica do comportamento dos novos itens gerados, visando identificar a existência de padrões

cíclicos, sazonais ou tendência e obter conhecimentos macro sobre as séries. Destaca-se que valores *missings* e *outliers* são novamente avaliados nesta etapa, e caso ainda existam problemas na série será realizada a correção conforme proposto por Montgomery, Jennings e Kulahci (2008).

Na etapa 5 serão avaliados os desempenhos dos diferentes modelos de previsão executados na etapa 4. Para determinação do modelo que melhor se ajusta a cada série de dados serão utilizados como parâmetros os indicadores de média absoluto dos erros (MAE), média quadrática dos erros (MSE) e erro absoluto percentual médio (MAPE).

A etapa 6, que é um passo de formalização, consiste basicamente em realizar a avaliação dos resultados dos indicadores calculados na etapa 5 e desta forma o modelo que possuir o menor valor de erro de acordo com os indicadores será escolhido para a etapa posterior.

Na etapa 7, é novamente executado o modelo específico de previsão que obteve o melhor desempenho para cada correspondente novo item, objetivando um cenário de previsão de seis meses.

De posse dos dados originados na etapa 7, a parte final da metodologia, a etapa 8, se caracteriza por um passo onde os dados de previsão serão comparados com os valores realizados pela empresa de modo analisar o alinhamento entre os valores previstos e os executados.

Duas etapas de melhoria contínua também foram planejadas na proposta, uma definida como Ciclo de Melhoria e a segunda como Ajuste. Com o ciclo de melhoria a ideia é formalizar a necessidade de que periodicamente os modelos devem ser questionados de modo a reavaliar o comportamento das séries e a formação dos grupos. Já o Ajuste, visa que com base nas análises da etapa 8 seja possível questionar o modelo definido por meio da comparação com o comportamento real do mercado. Estas etapas serão realizadas periodicamente a cada intervalo de seis meses de operação.

Todo o método proposto será especificado como um procedimento operacional da empresa, definindo desta forma as etapas, responsáveis pela execução, a periodicidade e a constante avaliação dos resultados no processo operacional de definição e gerenciamento dos estoques.

4 IMPLEMENTAÇÃO

O estudo de caso apresentado neste nesse trabalho foi realizado em uma empresa do setor moveleiro situada na cidade de Garibaldi no estado do Rio Grande do Sul. A empresa possui em seu modelo de negócio características como escala de produção e amplo *portfólio* de itens de venda que compartilham os mesmos recursos produtivos, fatores que permitem denominar sua estratégia como de customização em massa. Devido à elevada quantidade de itens que formam o espectro de possibilidades de compra dos clientes, realizar a previsão de vendas da empresa é uma tarefa desafiadora visto que implica em considerar todos os itens do *portfólio* como relevantes para determinar a previsão, o que sobrecarregaria o trabalho de execução desta tarefa. Neste contexto a proposta foi elaborada prevendo uma etapa que agrupe os itens de modo a reduzir o esforço de previsão de vendas a uma quantidade controlada de séries, fator que viabiliza a operacionalização das previsões e utiliza de toda a informação coletada do histórico avaliado para o cálculo das projeções.

Seguindo as etapas propostas no capítulo 3, a primeira se propôs a extrair os dados históricos correspondentes à venda dos itens. Os filtros parametrizados para selecionar os movimentos de venda pertinentes à análise foram inicialmente dois: o intervalo de tempo, iniciando em 01 de janeiro de 2013 e finalizando em 31 de dezembro de 2016; e a disponibilidade do item no *portfólio* de venda da empresa na data final da consulta. A pesquisa resultou em um montante de 16.939 registros de movimentos os quais foram tabulados em colunas contendo informações básicas para a análise de demanda, objetivo deste trabalho, que são: mês, ano, código do item e quantidade vendida. É importante observar que os registros representam as movimentações de venda da empresa (faturamento), logo os 16.939 registros não correspondem à quantidade direta de diferentes itens do portfólio, e sim à quantidade de eventos de venda realizados durante o período de pesquisa, e suas respectivas informações.

Após a coleta dos dados, a segunda etapa teve como finalidade a avaliação e correção de problemas nos dados amostrados, onde, inicialmente foi identificada a necessidade de excluir registros de itens para os quais a previsão de demanda não é de interesse do trabalho. Estes itens são classificados pela empresa como

componentes diversos e são utilizados como partes enviadas para assistência técnica, totalizando a quantidade de 476 registros, todos excluídos da base inicial. Outro aspecto importante observado é que as diferentes séries de dados possuem comportamentos com significativas variações de venda entre os diferentes períodos, característica que pode ser justificada pela variabilidade da demanda do mercado. Ainda nesta fase, para a formação das séries temporais, que representam o comportamento de venda dos itens no intervalo amostrado, os dados originais foram tabulados em linhas e colunas, sendo cada linha correspondente a um item específico do *portfólio* e as colunas correspondentes aos meses amostrados. A matriz final foi composta por 705 linhas e 48 colunas de valores de vendas.

A nova tabulação dos dados evidenciou uma característica esperada na formulação da proposta deste trabalho: o comportamento de venda dos itens, quando avaliado do ponto de vista individual é semelhante a uma série aleatória para inúmeros itens do *portfólio*, uma vez que são identificados inúmeros períodos da série onde nenhum evento de venda é registrado. O gráfico apresentado na Figura 5 representa este comportamento.

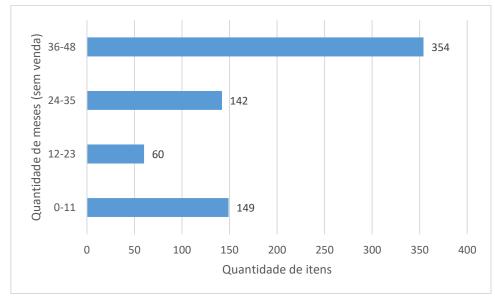


Figura 5: Número de itens em intervalos sem venda.

Fonte: o autor (2018)

Neste gráfico, os intervalos expressam o número de períodos da série temporal correspondente a cada item onde não ocorreram eventos de vendas, sendo 48 o máximo de eventos possíveis (48 meses) e o eixo horizontal expressa a quantidade de itens contidos em cada intervalo. É importante observar que apenas 21% dos itens, ou seja, 149 dentre 705, possuem vendas em pelo menos 75% do intervalo

amostrado. Ao contabilizar a quantidade de séries completas nos 48 meses a contagem é reduzida para 28 itens, valor que corresponde a 3,97% do total de itens do *portfólio* do negócio. Essas informações são apresentadas para evidenciar a constante presença de intervalos sem informações de venda. Estes *gaps* não podem ser definidos como um erro de coleta ou *missing* por se tratarem de uma característica oriunda do comportamento do mercado de atuação, porém, para a realização da previsão da demanda de uma destas séries individualmente implicaria na necessidade de correção dos dados de modo a compensar estas lacunas.

Partindo desses aspectos, a aplicação da uma técnica para agrupamento das séries possui ao menos dois benefícios diretos: a compensação destes *gaps* por meio da combinação entre as demandas dos diferentes itens que compõe um mesmo grupo; e a redução da quantidade de previsões necessárias para planejar a demanda da empresa.

A partir das 705 séries temporais obtidas do histórico de venda da empresa a terceira etapa tem como objetivo realizar o agrupamento dos itens, de modo que cada agrupamento seja caracterizado como um *novo item* gerado a partir da soma da quantidade de venda em cada respectivo período de todos os itens atribuídos a um mesmo agrupamento, conforme procedimento apresentado na Tabela 2. A técnica de agrupamento aplicada na formação dos grupos foi o *K-means*, tendo como métrica de agrupamento a correlação entre o comportamento temporal de venda entre as diferentes séries de tal forma que os relacionamentos entre os itens são importantes, ao invez das representatividades dos itens em cada periodo.

A operacionalização computacional necessária para classificação de cada item em seu correspondente grupo foi executada pela função *K-means*, nativa do software Matlab® R2016a e atribuindo como parâmetros de entrada a métrica da distância de correlação e a quantidade de 10 grupos.

A escolha pelo uso da correlação como métrica para formação dos grupos foi definida pelo fato de entender que se deseja realizar a previsão agrupando itens que possuam mesmos comportamentos de venda ao longo do período, sendo a correlação entre as séries o parâmetro mais adequado para este fim.

A determinação do número de grupos exige que se faça a ponderação entre uma menor quantidade de agrupamentos o que pode significar menor homogeneidade dentro dos agregados *versus* um grande número de agrupamentos e maior homogeneidade interna. Foram testados modelos com 15 e 20 grupos, porém, os

resultados não se mostraram interessantes e optou-se por utilizar 10 grupos como quantidade que melhor distribuiu os itens nos diferentes agrupamentos, sendo a quantidade de itens atribuídos a cada agrupamento apresentada na Figura 6.

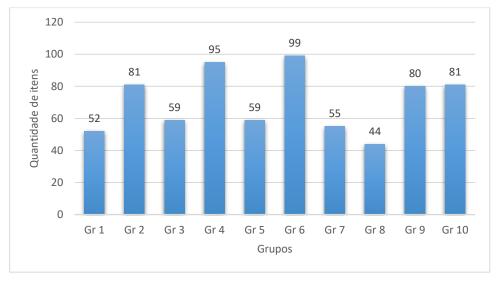


Figura 6: Distribuição dos itens nos agrupamentos

Fonte: o autor (2018)

A representação gráfica do comportamento de venda dos itens que constituem cada um dos agrupamentos é apresentada no Apêndice A. A análise dos gráficos permite identificar as peculiaridades existentes no comportamento dos itens de cada agrupamento, fato que valida empiricamente a estratégia de utilizar a correlação entre os comportamentos de venda como característica para formação dos grupos. Como exemplo apresenta-se na Figura 7 o comportamento de todas as 52 séries que geraram o Grupo 1.



Figura 7: Análise gráfica do Grupo 1

Fonte: o autor (2018)

Percebe-se que, de forma geral, fazem parte deste grupo itens que possuem crescimento nas vendas ao longo do tempo, com maior concentração nos períodos finais. Ainda, para melhor visualizar o comportamento descontando diferenças de escala, procedeu-se a análise gráfica dos valores padronizados para cada item que compõe cada grupo. Os resultados, apresentados no Apêndice B indicam também um bom ajustamento pela análise de agrupamento, novamente validando a realização de 10 grupos.

A partir de soma da demanda dos itens que compõem cada um dos agrupamentos foram obtidas as séries temporais que representam o que na sessão 3.2 foi denominado *novo item*. Estas novas séries, apresentadas na Figura 8, serão utilizadas para realizar a previsão de demanda.

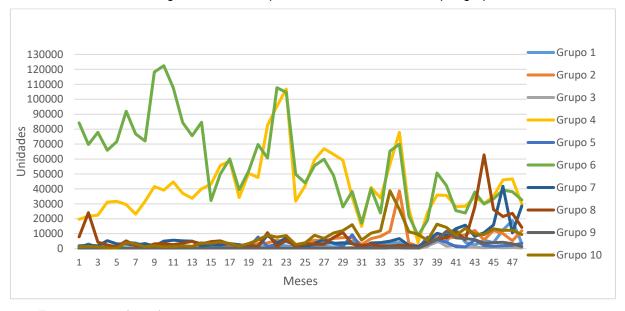


Figura 8: Série temporal do somatório dos itens por grupo

Fonte: o autor (2018)

É evidente na Figura 8 que as séries 4 e 6 possuem relevância na composição da demanda desde os primeiros períodos amostrados. Desta forma, visando avaliar a representatividade de cada *novo item* em relação a demanda total dos períodos amostrados é apresentado na Figura 9 um gráfico com a representatividade de cada *novo item* em relação à demanda total do período avaliado.

A análise gráfica evidencia a representatividade de aproximadamente 75% da demanda do período composta pelos grupos 6 e 4. Estes dois grupos são formados por 99 e 95 itens respectivamente, e portanto, juntos representam também 27,5 % dos itens do *portfólio* da empresa.

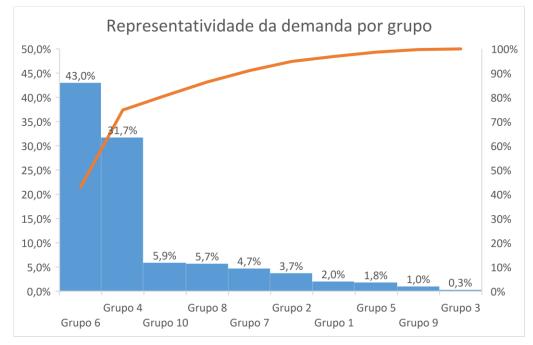


Figura 9: Gráfico de representatividade da demanda por grupo

A etapa seguinte da proposta refere-se à aplicação do modelo de previsão para cada *novo item* obtido a partir da técnica de agrupamento. Nessa etapa foi aplicado o método ARIMA para cada série. A escolha pelo modelo ARIMA é motivada pela seu amplo espectro de aplicações na indústria e no varejo, tornando-se assim um modelo aplicável ao contexto deste trabalho (HUBER; GOSSMANN; STUCKENSCHMIDT, 2017).

O modelo ARIMA sazonal é representado por (p,d,q,P,D,Q), onde p(P) é a ordem do componente auto regressivo, d(D) representa a ordem do componente diferencial e q(Q) a ordem do componente de média móvel da série. A caracterização do modelo foi realizada a partir dos dados relativos aos 48 meses amostrados, ou seja, dados de janeiro de 2013 a dezembro de 2016, sendo os resultados dos parâmetros obtidos para cada grupo apresentados na Tabela 3.

Após a obtenção dos parâmetros de (*p*,*d*,*q*,*P*,*D*,*Q*) o modelo ARIMA foi executado para um horizonte de previsão de seis períodos e os resultados foram comparados com a demanda obtida de dados reais de venda da empresa referentes ao período de janeiro de 2017 a junho de 2017. Os indicadores de erro das previsões foram calculados por meio dos critérios de erro absoluto médio (, erro quadrado médio (MSE) e erro absoluto percentual médio (MAPE).

Tabela 3: Parâmetros de treinamento dos modelos ARIMA

Grupo	ARIMA (p,d,q)(P,D,Q)			
Grupo 1	(1,0,0) (0,1,0)			
Grupo 2	(3,0,0) (0,0,0)			
Grupo 3	(1,1,0) (0,0,0)			
Grupo 4	(1,0,0) (1,0,0)			
Grupo 5	(0,0,0) (0,0,0)			
Grupo 6	(0,1,0) (0,0,0)			
Grupo 7	(0,1,1) (0,0,0)			
Grupo 8	(1,0,0) (0,0,0)			
Grupo 9	(0,1,0) (0,0,0)			
Grupo 10	(0,1,0) (0,0,0)			

Em adicional aos valores obtidos da previsão executada pelo modelo ARIMA, foi realizada a comparação entre a demanda real de venda e a previsão realizada pela empresa em seu dia-a-dia, sendo este basicamente baseado em dois processos distintos que são definidos pela demanda do item. Para os itens com maior representatividade nas vendas é realizada uma análise de tendência pelo cálculo da média móvel dos últimos três períodos, e em geral este procedimento é utilizado para os 10 itens mais vendidos na empresa. Todos os demais itens são avaliados de maneira subjetiva pelo programador. Resumidamente, pode-se afirmar que o estoque é composto majoritariamente pelos itens que tem maior giro de venda.

Os índices de erro obtidos da comparação entre os cenários foram tabulados e apresentados na Tabela 4. O modelo ARIMA obteve melhor desempenho, quando comparado ao método utilizado na empresa, na previsão para os grupos 4, 6, 7 e 8. Os demais grupos indicaram que o sistema adotado pela empresa foi mais eficaz. Os quatro grupos onde a previsão pelo modelo ARIMA obteve melhor desempenho correspondem a 85,2% da demanda de venda da empresa e 41,6% dos itens, e portanto, é possível afirmar que a adoção de um sistema de previsão baseado em modelos estatísticos mais robustos pode auxiliar a empresa a gerenciar sua programação de produção e consequentemente nivelar melhor seus estoques. O cálculo do MAPE geral ponderado pela representatividade de cada grupo, mostrou uma pequena melhoria de desempenho, sendo MAPE geral Empresa 71,7% enquanto o obtido pela metodologia deste trabalho 67,4%.

Tabela 4: Tabela de erros de previsão

Grupo	% vendas	Empresa			ARIMA		
		MAE	MSE	MAPE	MAE	MSE	MAPE
Grupo 1	2,0%	1.713	3.703.433	82%	9.791	171.146.219	523%
Grupo 2	3,7%	5.391	48.805.773	94%	7.162	57.975.610	221%
Grupo 3	0,3%	435	197.004	99%	2.899	12.272.385	755%
Grupo 4	31,7%	17.177	306.527.505	66%	8.627	89.832.493	36%
Grupo 5	1,8%	1.800	4.240.696	90%	997	1.508.165	143%
Grupo 6	43,0%	18.612	387.565.984	69%	5.864	49.726.812	27%
Grupo 7	4,7%	17.301	354.597.964	87%	7.266	83.030.427	59%
Grupo 8	5,7%	15.198	295.287.239	81%	8.846	109.742.245	47%
Grupo 9	1,0%	2.439	6.523.227	89%	4.807	42.363.737	197%
Grupo 10	5,9%	6.609	47.512.647	73%	17.414	461.823.251	218%

Entretanto esta melhoria não deve ser considerada pois não se justifica a aplicação de um método de previsão em todos os grupos, pois em alguns grupos o resultado não foi satisfatório. Considerando a possibilidade de trabalhar com os resultados da previsão da demanda nestes quatro grupos onde o resultado foi satisfatório, o MAPE correspondente a 85% das vendas passaria de 69,7% para 33,6%, caracterizando um ganho considerável de acuracidade na previsão.

Na análise das características individuais de cada grupo é possível inferir que em alguns grupos a previsão foi eficaz. Os gráficos apresentando as séries dos dados e a previsão para cada um dos grupos estão apresentados no Apêndice C.

Como exemplo, pode-se destacar os resultados obtidos nos dados do Grupo 1 apresentado na Figura 10. Percebe-se que os valores de previsão propostos pelo modelo ARIMA refletiram o comportamento que estava sendo observado nos últimos períodos, indicando aumento nas vendas com picos semestrais. Entretanto, observouse que os valores realizados nos períodos de 2017 não refletiram o comportamento prévio da série. A partir da imagem é possível afirmar que a previsão pelo modelo ARIMA foi adequada ao comportamento prévio da série, o que se verificou foi a mudança do comportamento do mercado para este grupo de itens, resultando em um valor baixo de ajuste na previsão. Da mesma forma, as análises de outros grupos com baixa representatividade também mostraram mudanças bruscas de comportamento para o ano de 2017, como é o caso do Grupo 2, cuja tendência era de crescimento e praticamente zerou as vendas em 2017. Para os Grupos 3 e 10 o modelo sugeriu um grande crescimento, seguindo o realizado no mesmo período de 2016, que não se verificou em 2017.

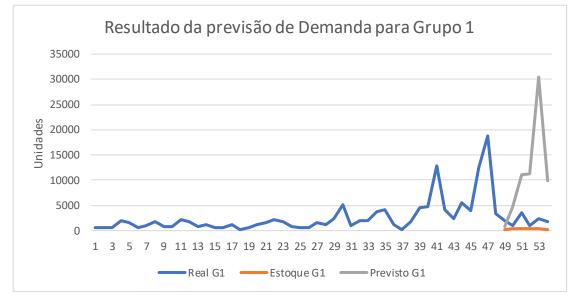


Figura 10: Valores previstos e realizados no Grupo 1

Por outro lado, analisando os grupos onde o ajuste teve melhor desempenho, a exemplo do Grupo 6 com representatividade de 43% nas vendas, MAPE melhorou de 69% para 27%. O Grupo 4, com representatividade de 32% passou de um MAPE de 66% para 36%. Outros grupos menores que apresentaram bons resultados foram o Grupo 7, que representa 5% dos das vendas e o Grupo 8 com 6%.

Cabe neste ponto um destaque, no atual procedimento utilizado na empresa são utilizados os 10 itens mais representativos, estes itens ficaram contemplados nos grupos 4 e 6, portanto, mesmo com o uso do agrupamento para a previsão estes itens foram contemplados na análise.

Após a avaliação do desempenho dos modelos ajustados pode-se inferir que o uso de métodos de previsão para itens customizados deve ser feito com cautela, sendo necessário analisar o grau de ajuste do modelo ao grupo. A definição de um sistema de previsão para a empresa passa pela necessidade de identificar qual modelo é melhor para cada conjunto de itens. Por meio dos resultados obtidos percebe-se a necessidade de usar um conjunto de métodos de previsão de demanda qualitativos para itens com baixa representatividade (e/ou comportamento não estável) associados aos modelos quantitativos.

A partir desta fase, a próxima etapa a ser executada na empresa é realizar a previsão de vendas para os itens dos grupos onde os ajustes obtiveram melhores índices de erro para os itens que compõe cada grupo. Neste caso, há necessidade de se distribuir a previsão para os meses seguintes proporcionalmente para cada um dos

itens. Uma vez que os grupos foram compostos por similaridade de comportamento (correlação), podem fazer parte do grupo itens com baixa representatividade, sendo estes inclusos na programação de produção atendendo a parâmetros do sistema de programação da empresa, que define o tamanho mínimos dos lotes econômicos de produção.

Resumidamente, a Figura 11 apresenta como este sistema de previsão foi implantado na empresa.

Criar as variáveis para Construir a base de dados Fazer as previsões análise Executar o Definir o horizonte Ajustar modelos de análise k-means ARIMA Agrupar itens nos Avaliar ajuste dos Extrair os dados dados grupos Selecionar grupos Limpar a base viáveis Individualizar previsão

Figura 11: Método para previsão de itens customizados em massa

Fonte: o autor (2018)

5 CONCLUSÕES

Este trabalho focou na análise de um problema recorrente em empresas que operam em condições que dificultam a previsão dos estoques: a customização em massa e a flutuação da demanda. A customização em massa se refere a produzir de acordo com as necessidades de cada cliente, considerando custo e prazo de entrega compatíveis com produção em massa. Esta forma de trabalhar, do ponto de vista da perspectiva externa, atende às demandas dos clientes, porém, sob a perspectiva interna, necessita que uma quantidade muito grande de itens de produção esteja disponível a um curto prazo. A segunda diz respeito à flutuação da demanda, onde a maior parcela das vendas se dá em meses específicos, períodos onde o comércio se organiza para abastecer as vendas do final de ano.

Ainda, aliado a estas características a empresa opera num cenário de competitividade em custo, o que exige que haja um controle rígido sobre os custos de produção, fato que está diretamente relacionado ao correto balanceamento dos recursos de produção ao longo de todo ano, intercalando períodos onde a capacidade de produção supera a demanda de mercado e outros onde ocorre o inverso. O estoque, neste caso, deve atuar como um mecanismo de regulagem entre capacidade de produção e demanda, permitindo que os recursos de produção operem nos níveis de eficiência planejados garantindo as características de custo.

Considerando estas condições, o objetivo do trabalho foi implementar um método para previsão de demanda para itens customizados em massa. O resultado financeiro deste projeto não está relacionado a reduzir o valor de estoque, mas em reorganizar o *mix* de estoque. Do ponto de vista da operação, quando são analisados os itens que serão vendidos através da previsão, é possível fazer escolhas assertivas dos itens que serão postos em programação de forma a compor um estoque com itens que tenham maior potencial de venda.

O método utilizado pela empresa para prever os estoques de itens tinha como característica selecionar os itens com maior giro e produzi-los para estoque quando da ocorrência de ociosidade na fábrica, em função da baixa demanda de mercado. Entretanto, esta estratégia acaba gerando uma quantidade restrita de códigos de itens em estoque e nos momentos de pico de demanda muitos outros itens do *portfólio* não estão disponíveis para entrega, tornando o estoque parcialmente ineficiente em seu

objetivo de suplementar a capacidade de fabricação na entrega de itens para o mercado.

A proposta implementada utilizou a análise de agrupamento e a análise de séries temporais. A utilização de uma técnica de agrupamento dos itens se fez necessária pela grande quantidade de itens individuais existente e pela falta de estabilidade nas vendas de muitos itens. A estratégia de usar a correlação como medida de agrupamento foi importante para garantir que o formador dos grupos fosse o comportamento da série ao longo do tempo e não o valor ou quantidade das vendas. A aplicação do agrupamento permitiu uma considerável redução na quantidade de previsões necessárias, sendo que 702 itens foram transformados em 10 grupos aos quais a previsão foi aplicada.

Os resultados obtidos na empresa indicam que o método proposto foi superior ao método utilizado na empresa em quatro dos dez grupos, os quais, juntos, correspondem a 85% do volume de vendas. Segmentando um pouco mais, os dois melhores resultados de ajuste foram obtidos nos grupos que correspondem a 75% das vendas.

Ainda, o uso do método permite que o *mix* de estoques seja mais variado que o atual, contemplando itens que mesmo com vendas mais baixas possuem maior probabilidade de serem vendidos no período de futuro. Uma das vantagens do uso do método é de que não é necessário fazer a escolha dos itens, eles são selecionados pelo modelo, a partir da correlação existente entre os itens dos grupos, contemplando também itens cuja representatividade é menor e nunca seriam considerados para previsão no modelo da empresa.

Na operacionalização do método entende-se como importante a etapa de avaliar a previsão e utiliza-la somente nos grupos onde houver um bom ajuste. Sugere-se continuar contanto com a expertise da equipe de vendas para contribuir na previsão de demanda através de outros métodos, por exemplo, métodos qualitativos, para itens que compõe produtos que estão nas fases iniciais ou finais de seu ciclo de vida e, portanto, não tem séries de dados robustas que permitam fazer inferências.

Do ponto de vista teórico este trabalho cobre uma lacuna que é a previsão de demanda para empresas que operam com customização em massa, apresentando uma proposta viável e de implementação que considera todos os itens inicialmente contidos no *portfólio* da empresa. Desta forma é possível gerenciar toda a cadeia logística baseando-se as decisões em uma menor quantidade de previsões.

Percebe-se como limitação do trabalho a utilização de somente um método de previsão de demanda e para trabalhos futuros sugere-se a análise comparativa de diferentes modelos de previsão de modo a avaliar quais poderiam melhor se adaptar às expressivas variações de volume de venda observadas nas séries.

REFERÊNCIAS

ALJOREPHANI, S. K.; ELMARAGHY, H. A. Impact of Product Platform and Market Demand on Manufacturing System Performance and Production Cost. **Procedia CIRP**, v. 52, p. 74–79, 2016.

BARDAKCI, A.; WHITELOCK, J. Mass-customisation in marketing: the consumer perspective. **Journal of Consumer Marketing**, v. 20, n. 5, p. 463–479, set. 2003.

BARDAKCI, A.; WHITELOCK, J. How "ready" are customers for mass customisation? An exploratory investigation. **European Journal of Marketing**, v. 38, n. 11/12, p. 1396–1416, nov. 2004.

BONEV, M. et al. Formal computer-aided product family architecture design for mass customization. **Computers in Industry**, v. 74, p. 58–70, dez. 2015.

BOX, G. E. P. et al. **Time series analysis: forecasting and control**. 6. ed. Hoboken, New Jersey: John Wiley & Sons, Inc, 2016.

BROWN, S.; BESSANT, J. The manufacturing strategy-capabilities links in mass customisation and agile manufacturing – an exploratory study. **International Journal of Operations & Production Management**, v. 23, n. 7, p. 707–730, jul. 2003.

BRUNOE, T. D.; NIELSEN, K. Complexity Management in Mass Customization SMEs. **Procedia CIRP**, v. 51, p. 38–43, 2016.

CORRÊA, H. L.; GIANESI, I. G. N.; CAON, M. Planejamento, programação e controle da produção: MRP II/ERP: conceitos, uso e implantação. 5. ed. São Paulo (SP): Atlas, 2007.

DA SILVEIRA, G.; BORENSTEIN, D.; FOGLIATTO, F. S. Mass customization: Literature review and research directions. **International Journal of Production Economics**, v. 72, n. 1, p. 1–13, jun. 2001.

DA SILVEIRA, G. J. C.; FOGLIATTO, F. S.; FENDYUR, A. Demographics of mass customization: a global study of manufacturing plants. **Production**, v. 26, n. 1, p. 1–11, mar. 2016.

DAABOUL, J.; DA CUNHA, C. M. Differentiation and Customer Decoupling Points: Key Value Enablers for Mass Customization. In: GRABOT, B. et al. (Eds.). . **Advances in Production Management Systems. Innovative and Knowledge-Based Production Management in a Global-Local World**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2014. v. 440p. 43–50.

DAVIS, S. M. From "future perfect": Mass customizing. **Planning Review**, v. 17, n. 2, p. 16–21, fev. 1989.

DURAY, R. et al. Approaches to mass customization: configurations and empirical validation. **Journal of Operations Management**, v. 18, n. 6, p. 605–625, nov. 2000.

- DURAY, R. Mass customization origins: mass or custom manufacturing? **International Journal of Operations & Production Management**, v. 22, n. 3, p. 314–328, mar. 2002.
- FOGLIATTO, F. S.; DA SILVEIRA, G. J. C.; BORENSTEIN, D. The mass customization decade: An updated review of the literature. **International Journal of Production Economics**, v. 138, n. 1, p. 14–25, jul. 2012.
- GERHARDT, T. E.; SILVEIRA, D. T. **Método de pesquisa**. Porto Alegre: Editora UFRGS, 2009.
- HAIR, J. F. et al. (EDS.). **Multivariate data analysis**. 7th. ed. Upper Saddle River, NJ: Prentice Hall, 2010.
- HUBER, J.; GOSSMANN, A.; STUCKENSCHMIDT, H. Cluster-based hierarchical demand forecasting for perishable goods. **Expert Systems with Applications**, v. 76, p. 140–151, jun. 2017.
- JAIN, A. K. Data clustering: 50 years beyond K-means. **Pattern Recognition Letters**, v. 31, n. 8, p. 651–666, jun. 2010.
- JAIN, A. K.; MURTY, M. N.; FLYNN, P. J. Data clustering: a review. **ACM Computing Surveys**, v. 31, n. 3, p. 264–323, 1 set. 1999.
- JIAO, J.; MA, Q.; TSENG, M. M. Towards high value-added products and services: mass customization and beyond. **Technovation**, v. 23, n. 10, p. 809–821, out. 2003.
- KAUFMAN, L.; ROUSSEEUW, P. J. Finding groups in data: an introduction to cluster analysis. Hoboken, N.J.: Wiley, 2005.
- LAFOU, M. et al. Manufacturing System Flexibility: Sequence Flexibility Assessment. **Procedia CIRP**, v. 57, p. 229–234, 2016.
- LUŠIĆ, M. et al. Engineering Framework for Enabling Mass Customisation of Curvilinear Panels with Large Surfaces by Using Pin-type Tooling. **Procedia CIRP**, v. 37, p. 265–270, 2015.
- MACHADO, A. G. C.; MORAES, W. F. A. DE. Estratégias de customização em massa implementadas por empresas brasileiras. **Revista Produção**, v. 18, n. 1, p. 170–183, 2008.
- MAKRIDAKIS, S. G.; WHEELWRIGHT, S. C.; HYNDMAN, R. J. Forecasting: methods and applications. 3. ed. New York: John Wiley & Sons, 1998.
- MICHNIEWICZ, J.; REINHART, G.; BOSCHERT, S. CAD-Based Automated Assembly Planning for Variable Products in Modular Production Systems. **Procedia CIRP**, v. 44, p. 44–49, 2016.
- MIGUEL, P. A. C. et al. **Metodologia de pesquisa em engenharia de produção e gestão de operações**. 2. ed. Rio de Janeiro: Elsevier ABEPRO, 2012.

- MONTGOMERY, D. C.; JENNINGS, C. L.; KULAHCI, M. Introduction to time series analysis and forecasting. 2. ed. Hoboken, N.J: Wiley-Interscience, 2008.
- MOURTZIS, D. Challenges and future perspectives for the life cycle of manufacturing networks in the mass customisation era. **Logistics Research**, v. 9, n. 1, dez. 2016.
- MOURTZIS, D.; DOUKAS, M.; PSAROMMATIS, F. Design and operation of manufacturing networks for mass customisation. **CIRP Annals Manufacturing Technology**, v. 62, n. 1, p. 467–470, 2013.
- NOVAES, U. DA R. **Agrupamento De Dados Através De Algorítmos Swarm**. Rio de Janeiro: Universidade Federal Do Rio de Janeiro. Programa de Pós-Graduação em Engenharia, 2002.
- PAN, B.; HOLLAND, R. A mass customised supply chain for the fashion system at the design-production interface. **Journal of Fashion Marketing and Management: An International Journal**, v. 10, n. 3, p. 345–359, jul. 2006.
- PELLEGRINI, F. R.; FOGLIATTO, F. S. Passos para implantação de sistemas de previsão de demanda: técnicas e estudo de caso. **Production**, v. 11, n. 1, p. 43–64, 2001.
- PILINKIENĖ, V. Selection of market demand forecast methods: Criteria and application. **Engineering Economics**, v. 58, n. 3, p. 19–25, 2015.
- SHIH, H. M. Product structure (BOM)-based product similarity measures using orthogonal procrustes approach. **Computers & Industrial Engineering**, v. 61, n. 3, p. 608–628, out. 2011.
- SLACK, N.; CHAMBERS, S.; JOHNSTON, R. **Administração da produção**. 3. ed. São Paulo (SP): Atlas, 2009.
- TRENTIN, A.; PERIN, E.; FORZA, C. Sales configurator capabilities to avoid the product variety paradox: Construct development and validation. **Computers in Industry**, v. 64, n. 4, p. 436–447, maio 2013.
- ÜLKÜ, M. A.; HSUAN, J. Towards sustainable consumption and production: Competitive pricing of modular products for green consumers. **Journal of Cleaner Production**, v. 142, p. 4230–4242, jan. 2017.
- VIDOR, G. Modelos para implementação da qualidade em produtos e serviços customizados em massa. Tese (Doutorado em Engenharia de Produção)—Porto Alegre: Universidade Federal do Rio Grande do Sul, Programa de Pós-Graduação em Engenharia de Produção, 2014.
- VIDOR, G.; MEDEIROS, J. F. DE; CRUZ, C. M. L. Atributos determinantes e serviços customizados em massa: sistemática para realizar o ajuste ótimo da oferta. **Desenvolvimento em Questão**, v. 13, n. 29, p. 355, jan. 2015.
- VIDOR, G.; MEDEIROS, J. F. DE; RIBEIRO, J. L. D. Modelo para classificação de características de customização em massa para serviços. **Revista Produção Online**, v. 13, n. 3, p. 974–1001, 2013.

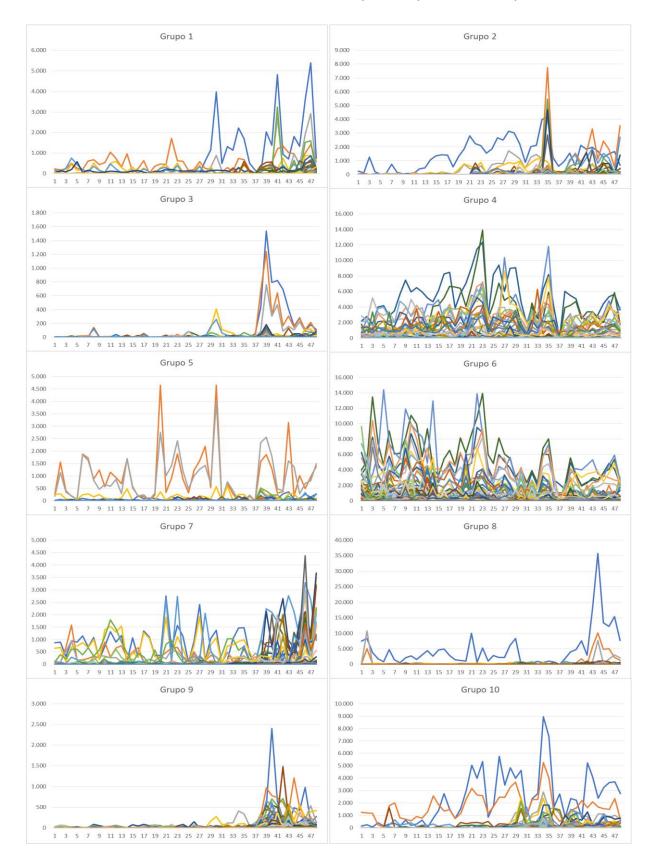
WERNER, L.; RIBEIRO, J. L. D. Previsão de demanda: uma aplicação dos modelos Box-Jenkins na área de assistência técnica de computadores pessoais. **Revista Gestão & Produção**, v. 10, n. 1, p. 47–67, 2003.

YOO, J.; PARK, M. The effects of e-mass customization on consumer perceived value, satisfaction, and loyalty toward luxury brands. **Journal of Business Research**, v. 69, n. 12, p. 5775–5784, dez. 2016.

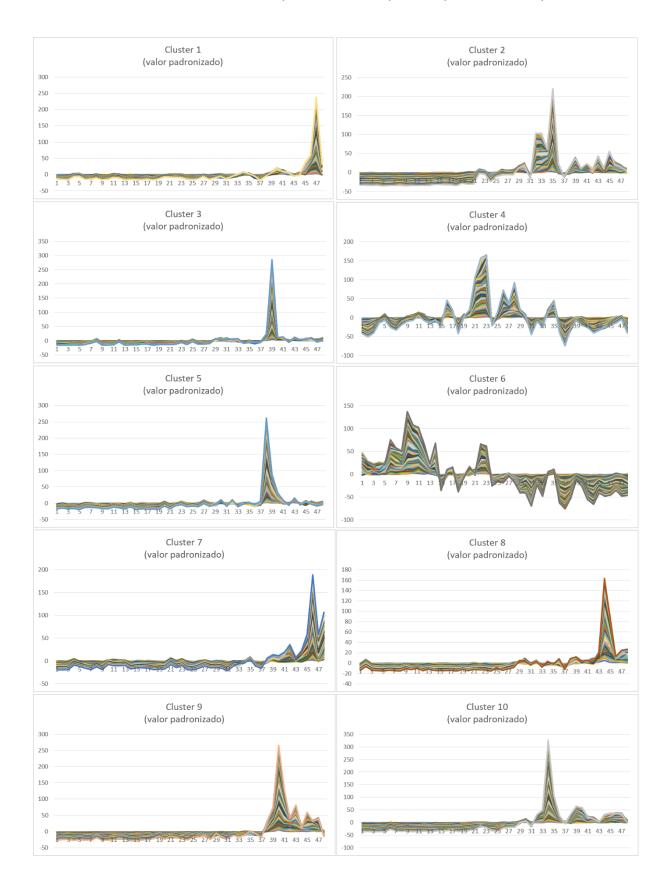
ZHANG, M. et al. Linking supply chain quality integration with mass customization and product modularity. **International Journal of Production Economics**, jan. 2017.

ZHANG, M.; ZHAO, X.; QI, Y. The effects of organizational flatness, coordination, and product modularity on mass customization capability. **International Journal of Production Economics**, v. 158, p. 145–155, dez. 2014.

APÊNDICE AGráficos das séries de itens que compõe cada Grupo



APÊNDICE BGráficos das séries padronizadas que compõe cada Grupo



APÊNDICE CResultado da Previsão para cada Grupo

