

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO MESTRADO PROFISSIONAL EM
ENGENHARIA DE PRODUÇÃO

Heitor Augusto Vianna Carazza

INTEGRAÇÃO DE FERRAMENTAS DE CLUSTERIZAÇÃO E MODELOS
QUANTITATIVOS DE PREVISÃO DE DEMANDA: UMA APLICAÇÃO NO SETOR
ALIMENTÍCIO

Porto Alegre

2020

Heitor Augusto Vianna Carazza

**Integração de ferramentas de clusterização e modelos quantitativos de previsão de
demanda: uma aplicação no setor alimentício**

Dissertação submetida ao Programa de Pós-Graduação em Engenharia de Produção da Universidade Federal do Rio Grande do Sul como requisito parcial à obtenção do título de Mestre em Engenharia de Produção, modalidade Profissional, na área de concentração de Sistemas de Produção.

Orientador: Michel José Anzanello, Ph.D.

Porto Alegre

2020

Heitor Augusto Vianna Carazza

Integração de ferramentas de clusterização e modelos quantitativos de previsão de demanda: uma aplicação no setor alimentício

Esta dissertação foi julgada adequada para a obtenção do título de Mestre em Engenharia de Produção na modalidade Acadêmica e aprovada em sua forma final pelo Orientador e pela Banca Examinadora designada pelo Programa de Pós-Graduação em Engenharia de Produção da Universidade Federal do Rio Grande do Sul.

Prof. Michel José Anzanello

Orientador PMPEP/UFRGS

Profa. Christine Tessele Nodari

Coordenador PMPEP/UFRGS

Banca Examinadora:

Prof. Alessandro Kahmann, Dr. (IMEF/FURG)

Prof. Ricardo Augusto Cassel, PhD. (PMPEP/UFRGS)

Prof. Guilherme Luz Tortorella, Dr. (PPGEPS/UFSC)

AGRADECIMENTOS

Gostaria de agradecer a Deus por mais esta oportunidade que me proporcionou nesta caminhada da vida.

A minha família, Priscila e Sara pelo apoio incondicional que me deram para que este sonho se tornasse realidade.

Aos meus pais, pelos princípios e valores que me ensinaram. Por me mostrarem que a vida é uma busca constante de aprendizado.

A Bia, pessoa que levo em um lugar especial do meu coração. Obrigado por tudo que sempre fez por mim.

Ao meu amigo/irmão Gustavo, por me incentivar a buscar este título tão sonhado e por me permitir fazer este trabalho utilizando as informações de sua empresa.

Ao meu orientador, Prof. Michel José Anzanello, pela confiança, atenção e pelos ensinamentos valorosos que me deu ao longo deste trabalho.

A Universidade Federal do Rio Grande do Sul (UFRGS), em especial aos professores do Programa de Pós-Graduação em Engenharia de Produção, pela excelência no ensino.

Aos meus colegas do Programa de Pós Pós-Graduação em Engenharia de Produção da UFRGS, em especial a Alexandre Coser, Iuri Kiriya e Marco Stail, pelos conhecimentos compartilhados ao longo destes anos.

A todos, meu muito obrigado!

Carazza, H. **Integração de ferramentas de clusterização e modelos quantitativos de previsão de demanda: uma aplicação no setor alimentício**. 2020. Dissertação (Mestrado em Engenharia) - Universidade Federal do Rio Grande do Sul, Brasil.

RESUMO

A competição acirrada nos mercados e a demanda dos clientes por maior agilidade nos serviços de entrega e qualidade nos produtos têm pressionado as empresas na busca de diferenciais competitivos. Vários estudos e investimentos têm sido direcionados ao aprimoramento da gestão de produção visando maximizar as receitas e reduzir os seus custos operacionais. Neste sentido, a adequada utilização de técnicas de previsão de demanda pode ajudar as empresas a aumentarem sua previsibilidade sobre eventos futuros. Tal entendimento é fundamental em setores alimentícios, onde a eficiente gestão de insumos perecíveis não só repercute em termos financeiros, mas também na saúde do cliente. Este estudo tem como intuito utilizar ferramentas de agregação de dados históricos de demanda e de agrupamento de produtos com características similares para aumentar a precisão de modelos de previsão de demanda. Para tanto, inicialmente propõe uma análise de clusterização para agrupar produtos similares com base em variáveis que descrevem seus comportamentos e características. A ideia é reduzir o volume de modelagens quando comparado à avaliação dos produtos isolados. Na sequência, estrutura-se um método de agregação dos dados históricos de demanda de produtos inseridos no mesmo cluster previamente à modelagem de previsão. Com a agregação, objetiva-se reduzir ruídos da série e aumentar a aderência dos modelos aos dados. Por fim, realiza-se a desagregação das predições. As proposições são ilustradas em dados reais de uma pizzaria do ABC Paulista, e potenciais implicações gerenciais são apresentadas.

Palavras-chave: Clusterização; seleção de variáveis; previsão de demanda; setor alimentício.

Carazza, H. **Integration of clustering tools and quantitative demand forecasting models: an application in the food sector.** 2020. Dissertation (Master in Engineering) - Federal University of Rio Grande do Sul, Brazil.

ABSTRACT

The fierce competition on the market and a growing customer demand for quality and prompt delivery of goods have been urging businesses to seek out solutions in order to maintain a competitive edge. Several studies and investments aim at the improvement of production management to maximize revenues and reduce operational costs. In this regard, the correct application of demand forecasting techniques can support companies and improve the predictability of future events. This understanding is fundamental in the food sector, where an efficient management of perishable goods not only impacts the financial results of companies, but also the health of the clients. This study is intended to use tools to aggregate historical data and group products in order to increase the predictability of demand forecasting models. Therefore, it initially proposes a clustering analysis to group similar products based on variables that describe their behaviors and characteristics. The idea is to reduce the volume of modeling when it is compared with the evaluation of isolated products. Then, a method is structured to aggregate the historical data of product demand inside the clusters previously to forecasting modeling. The objective of the aggregation is to reduce any series deviations and increase the model adherence to the data. Lastly, disaggregation predictions are made. The propositions in the study illustrate real data of a pizza parlor in the country side of Sao Paulo and present potential managerial implications.

Palavras-chave: Clusterization, variables selection, demand forecasting and food sector.

LISTA DE FIGURAS

Figura 1 – Padrões de demanda regular e irregular	17
Figura 2 – Métodos qualitativos de previsão de demanda	25
Figura 3 – S&OP Junction Box	27
Figura 4 – Exemplos de Processos de Forecasting de Vendas	28
Figura 5 – Etapas propostas para previsão de demanda utilizando ferramentas de clusterização	31
Figura 6 – Previsão de Demanda Quinzenal – Suavização Exponencial Dupla (Pizza Capri) ...	42

LISTA DE TABELAS

Tabela 1 – Classificação de previsões de demanda em função de períodos futuros e unidades de tempo	18
Tabela 2 – Silhouette Index Médio para cada unidade temporal e variáveis utilizadas na clusterização	37
Tabela 3 – Distribuição da partição da porção treino/teste para os períodos de tempo.....	38
Tabela 4 – MAPE médio segundo modelos de previsão de demanda e bases temporais avaliadas	40
Tabela 5 – Comparação entre MAPE médio de previsões isoladas e desagregadas	41
Tabela 6 – Demonstrativo de resultado da Pizzaria abordada neste estudo - 2019	43
Tabela 7 – Perdas por insumo da Pizzaria abordada neste estudo	44
Tabela 8 – Evolução do Demonstrativo de Resultado Pizzaria abordada neste estudo, tendo como base os benefícios esperados com o exercício de previsão de demanda.....	49

LISTA DE ABREVIATURAS E SIGLAS

ABC	Siglas cidades Grande São Paulo (Santo André, São Bernardo e São Caetano)
ARIMA	<i>Auto-regressive Integrated Moving Average</i>
FMI	Fundo Monetário Internacional
IPEA	Instituto de Pesquisa Econômica Aplicada
MAPE	<i>Mean Absolute Percentage Error</i>
MRP	<i>Material Requirement Planning</i>
PIB	Produto Interno Bruto
SI	Silhouette Index
S&OP	Sales & Operations Planning
WSNs	<i>Wireless Sensor Networks</i>

SUMÁRIO

1. INTRODUÇÃO	1
1.1. CONSIDERAÇÕES INICIAIS	1
1.2. JUSTIFICATIVA DO TEMA E OBJETIVOS	3
1.3. PROCEDIMENTOS METODOLÓGICOS E ESTRUTURA DO TRABALHO	4
1.4. DELIMITAÇÕES DO TRABALHO	5
2. REVISÃO DA LITERATURA	7
2.1. O SETOR ALIMENTÍCIO	7
2.2. FUNDAMENTOS DE CLUSTERIZAÇÃO	9
2.2.1. Clusterização hierárquica (dendrograma)	10
2.2.2. Método não hierárquico: particionamento (K-Means)	10
2.2.3. Técnicas para análise de clusters e aplicações práticas	11
2.3. SILHOUETTE INDEX	13
2.4. PREVISÃO DE DEMANDA	14
2.4.1. Elementos dos modelos de previsão	15
2.4.2. Modelos quantitativos de previsão de demanda	18
2.4.2.1. Suavização exponencial simples	18
2.4.2.2. Suavização exponencial dupla (suavização exponencial linear de Holt) 19	
2.4.2.3. Suavização exponencial tripla (método de Holt-Winters)	20
2.4.2.4. Média móvel	22
2.4.2.5. Modelo Arima	23
2.5. Modelos qualitativos de previsão de demanda	24
2.6. Previsão de demanda no setor alimentício	25
2.7. Previsão de demanda e sua importância para o processo de S&OP	26
2.8. SISTEMÁTICAS DE AGREGAÇÃO/DESAGREGAÇÃO DE DADOS HISTÓRICOS DE DEMANDA	28
3. MÉTODO	31
3.1. FASE 1 – AGRUPAMENTO DOS PRODUTOS DE ACORDO COM SUAS SIMILARIDADES	31
3.1.1. Etapa 1: Identificar os produtos a serem analisados	32
3.1.2. Etapa 2: Definir e coletar variáveis para a formação dos grupos	32
3.1.3. Etapa 3: Definir número de clusters via dendrograma e formar os agrupamentos de produtos	33

3.2. FASE 2 - PREVISÃO DE DEMANDA	33
3.2.1. Etapa 1: Agregação das demandas de acordo com os clusters gerados na fase anterior	34
3.2.2. Etapa 2: Definir o melhor modelo de previsão de demanda agregada para cada cluster	34
3.2.3. Etapa 3: Desagregação das previsões agregadas na etapa 2	35
4. ESTUDO DE CASO	36
4.1. FASE 1 - AGRUPAMENTO DAS PIZZAS DE ACORDO COM SUAS SIMILARIDADES	36
4.2. FASE 2 – PREVISÃO DE DEMANDA DAS PIZZAS.....	38
5. POTENCIAIS IMPLICAÇÕES DO MÉTODO PROPOSTO	43
6. CONCLUSÕES	50
REFERÊNCIAS	52

1. INTRODUÇÃO

1.1. CONSIDERAÇÕES INICIAIS

Em um mercado cada vez mais competitivo e com recursos escassos, elevar a acurácia sobre a previsão de demanda pode gerar um importante diferencial competitivo para as empresas, alavancando seus resultados. Uma criteriosa avaliação quanto às diretrizes para o futuro (horizontes de curto, médio e longo prazos) é um balizador essencial para a tomada de decisões gerenciais, levando-se em conta fatores que incluem redução de riscos associados à operação, manutenção de diferenciais de mercado, escolhas e priorização de investimentos e melhor aproveitamento de oportunidades (GEORGOFF; MURDICK, 1986; MAKRIDAKIS, 1998).

Com os clientes cada vez mais interessados em uma maior agilidade nos serviços de entrega e na qualidade dos produtos, as empresas se veem pressionadas a buscarem constantemente diferenciais competitivos, os quais devem estar aliados a uma sistemática estruturada de previsão de demanda voltada tanto a evitar estoques excessivos quanto a escassez de insumos/produtos (principalmente em se tratando de produtos perecíveis). No setor alimentício, em específico, vários estudos e investimentos têm sido realizados com o intuito de aprimorar a gestão de capacidade e o planejamento de produção, de forma a melhorar o prazo de entrega para os clientes, reduzir os custos operacionais e maximizar as receitas (ALTENDORFER; KLAUS, 2014).

Este estudo de análise de previsão de demanda é conduzido em uma pizzaria de médio porte, cuja atuação tem como foco as classes A e B. De acordo com a Associação das pizzarias do Estado de São Paulo (2018), o perfil dos consumidores neste mercado tipicamente se caracteriza por pessoas que possuem renda mensal igual ou superior a R\$8.000, sendo em geral empresários ou funcionários de média ou alta gerência das empresas em que atuam, com idade entre 25 e 45 anos. As empresas que atuam neste setor, normalmente, procuram trabalhar em raio de atuação de 4 quilômetros de suas instalações, tendo como foco bairros novos e tradicionais de alto poder aquisitivo.

A Associação das pizzarias do Estado de São Paulo (2018) coloca que o tamanho deste mercado girou em torno de 300 mil unidades de pizzas vendidas por ano em 2017, havendo um potencial de expansão para aproximadamente 400 mil unidades até 2020. Nos últimos 3 anos, estima-se que o crescimento médio anual deste mercado tenha sido de 8% ao ano. Ainda de acordo com a mesma fonte, em média, para cada pizzaria de pequeno e médio porte, estima-se que sejam investidos anualmente R\$50.000,00 em máquinas, softwares, consultorias de melhorias de processos e marketing. Somado a isto, os gastos com matérias-primas e insumos respondem

por aproximadamente R\$500.000,00 anuais. Considerando margens cada vez mais justas devido ao aumento do preço das matérias primas, é fundamental evitar desperdícios, fazendo com que previsões precisas de demanda assumam papel crucial. Segundo a Associação das pizzarias do Estado de São Paulo (2018), o desperdício no setor pode variar entre 5% e 20%, dependendo do grau de maturidade das pizzarias e níveis de investimentos.

De acordo com a mesma associação, é importante também ressaltar algumas características deste mercado, tendo como base pesquisas de satisfação de clientes e estudos sobre concorrência, tais como: a) o atendimento é visto como um diferencial para os clientes; b) a qualidade dos produtos é um fator fundamental para tomada de decisão; c) oferta de programas de fidelização (clube de vantagens – promoções) tem forte impacto na decisão do cliente; d) há uma dificuldade de aceitação do novo (barreira à entrada); e) uso crescente e intensivo de tecnologia (cardápios eletrônicos, etc.); f) apelo por produtos artesanais; g) oferta de produtos de alto valor agregado; h) forte apelo pela marca; i) necessidade de mão de obra qualificada para forneiro e pizzaiolo; e j) alta rotatividade de mão de obra.

Embora se perceba elevada maturidade em estudos relacionados à previsão de demanda nos mais diversos segmentos industriais e de serviços (incluindo o alimentício) (MONTGOMERY; JOHNSON; GARDINER, 1990), uma parcela limitada destes estudos aborda a importância de análises de agrupamento de produtos e agregação de demanda. A previsão de demanda por ser uma técnica matemática/estatística, depende da qualidade dos dados para gerar resultados satisfatórios. Como dados reais de vendas tipicamente carregam ruído e perfis com elevada variabilidade devido ao caráter probabilístico da demanda, faz-se necessário utilizar técnicas para pré-processamento dos dados históricos com vistas ao aumento da acurácia das previsões.

Segundo Webby, O'Connor e Edmundson (2004), a agregação de dados históricos de demanda tendem a facilitar o processo de modelagem das séries históricas, visto que a agregação de dados reduz a instabilidade normalmente verificada nas séries históricas de produtos individuais. No que diz respeito aos produtos, o agrupamento de itens com características similares, não só reduz o esforço de modelagem (visto que um único modelo pode prever o comportamento de demanda futura de um conjunto de produtos), como também se beneficia da redução de ruído da série decorrente do agrupamento dos dados. De tal forma, essa dissertação faz uso de sistemáticas de agregação de dados com vistas à previsão de demanda de produtos do setor alimentício (pizzas).

1.2. JUSTIFICATIVA DO TEMA E OBJETIVOS

As justificativas para realização deste trabalho se apoiam em duas frentes, uma prática e outra teórica. No âmbito prático, este estudo reforça a importância da aplicação eficaz de modelos de previsão de demanda nos mais diversos segmentos industriais/comerciais, de forma a permitir a identificação de eventuais ineficiências na cadeia de suprimentos e em relação aos fornecedores. Segundo Chase Jr. (2013), o estabelecimento de um modelo estruturado de previsão de demanda possibilita uma melhor estratégia de planejamento de compras de matérias-primas e a identificação da quantidade necessária de inventário para realizar a gestão das operações. Este é um ponto crucial, principalmente em setores que trabalham com grande concentração de produtos perecíveis, exigindo maiores cuidados relacionados às políticas de compra, armazenagem e gestão dos insumos. A previsão de demanda ainda impacta na determinação do número ideal de produtos a serem ofertados, na necessidade de contratação de mão de obra, bem como no correto dimensionamento da capacidade produtiva e níveis de investimentos de capital para atender a demanda esperada. Acrescenta-se que o processo básico de transformação de matéria-prima em produto acabado e sua entrega aos clientes leva tempo e, a previsão de demanda tem um papel importante neste contexto. As empresas não podem apenas esperar que a demanda ocorra para então reagir.

Já no seu âmbito teórico, a seleção adequada de um modelo de previsão de demanda, segundo Lindberg e Zackrisson (1991), é um dos maiores desafios para as organizações. Diante da existência de uma vasta alternativa de modelos qualitativos e quantitativos (bem como a combinação destes), o correto entendimento e estudo sobre qual modelo utilizar, pode se constituir em importante diferencial (Armstrong, 2001). Neste sentido, a literatura ainda oferece espaço para o desenvolvimento de novas abordagens de previsão de demanda, especialmente quando aliadas a ferramentas multivariadas de técnicas de clusterização, no caso deste estudo. É bastante comum encontrar trabalhos que abordam o tema de previsão de demanda apenas mostrando a melhor forma de utilização de modelos qualitativos, quantitativos ou da combinação destes, mas não explorando o pré-processamento dos dados históricos (através de agrupamento e agregação, por exemplo) e seu impacto acerca do aumento da precisão de modelos gerados. Alguns benefícios oriundos da agregação de dados em estudos de previsão podem ser encontrados em Jain e Malehorn (2013), Murray, Agard e Barajas (2015), Baig, Blau, Sabah (2019) e Chen (2019).

No que diz respeito aos objetivos, pode-se dividir os mesmos em geral e específico. Quanto ao seu objetivo geral, esta dissertação propõe-se uma sistemática de previsão de demanda apoiada

em técnicas de agregação de dados, visando tanto agrupar os tipos de produtos para simplificar e agilizar a modelagem, quanto agregar os dados históricos de demanda para reduzir flutuações e aumentar a sua aderência aos modelos de previsão. Quanto aos seus objetivos específicos, pode-se citar:

- i. Avaliar potenciais ganhos do agrupamento de produtos para previsão de demanda quando comparado à modelagem individual de produtos;
- ii. Propor uma sistemática estruturada para seleção do melhor modelo quantitativo de previsão de demanda;
- iii. Propor uma sistemática para desagregação das previsões obtidas através da modelagem dos dados históricos;
- iv. Avaliar desempenho da abordagem por meio da sua aplicação em um setor alimentício.

1.3. PROCEDIMENTOS METODOLÓGICOS E ESTRUTURA DO TRABALHO

Este trabalho tem natureza aplicada, uma vez que os estudos realizados serão voltados para um problema real do meio empresarial: como construir um método para aprimoramento da precisão de modelos de previsão de demanda. Quanto à abordagem, serão utilizados tanto dados quantitativos, com a análise de uma série histórica de dados, quanto qualitativos, através da validação das previsões geradas por intermédio da opinião de especialistas de processo (SILVA; MENEZES, 2005).

Na sua essência, este estudo será de caráter explicativo, uma vez que propõe o uso de métodos já existentes com a realização de testes de hipóteses para comprovar a teoria. Contudo, este trabalho também apresentará aspectos normativos, já que terá o intuito de propor uma metodologia para seleção de modelos de previsão de demanda (SILVA; MENEZES, 2005).

Em termos de sua estrutura, o trabalho em questão se apoia em 6 capítulos agora descritos. No primeiro capítulo são abordadas as justificativas de mercado, que buscam elevar a acurácia de previsão de demanda, aprimorar a estratégia de compras de matéria prima e gerir de forma eficiente a operação das empresas, bem como as justificativas de literatura que suportam a estruturação deste trabalho, dentre elas: a utilização de técnicas de clusterização, a seleção adequada de modelos de previsão de demanda e a proposição de uma sistemática de agregação/desagregação de demanda.

No segundo capítulo será conduzida uma análise de clusterização com o intuito de formar grupos de produtos com características similares utilizando variáveis que descrevem características destes produtos (demanda semanal, preço médio, custo médio, margem média, etc.). A formação de grupos se destina a reduzir o volume de modelagens necessárias, visto que as previsões serão geradas para grupos de produtos e não para produtos isoladamente. No terceiro capítulo, será realizado um levantamento de modelos quantitativos de previsão de demanda, os quais serão avaliados em termos de sua aptidão para modelagem dos dados históricos de demanda.

Já o quarto capítulo traz a modelagem de demanda para os grupos definidos no segundo capítulo, apoiando-se nos seguintes passos: a) agregação das demandas dos produtos inseridos em cada cluster; b) separação dos dados históricos agregados de demanda de cada cluster em porções de treino e teste; c) modelagem e definição do melhor modelo quantitativo de previsão para cada cluster através do *Mean Absolute Percentage Error* (MAPE) (MAKRIDAKIS, 1993); e d) desagregação do somatório das demandas encontradas para os produtos em cada cluster.

Por fim, o quinto e sexto capítulos conduzem à previsão de demanda por grupos (clusters) de pizzas em um restaurante localizado no ABC Paulista. O intuito é não apenas agilizar as análises de previsão de demanda, uma vez que esta é feita por grupos, mas também elevar a precisão da predição de demanda futura para cada tipo de pizza e avaliar as potenciais implicações gerenciais desta análise para este estudo de caso.

1.4. DELIMITAÇÕES DO TRABALHO

As seguintes limitações são identificadas neste estudo:

- Este estudo não foca na análise financeira dos resultados obtidos através da previsão de demanda realizada, propondo apenas uma análise superficial dos custos e benefícios esperados com base na acurácia gerada pelos modelos de previsão de demanda recomendados para cada cluster.
- Modelos mais complexos de previsão de demanda, como redes neurais e filtro de Kalman, não são considerados. Também não há menção a modelos causais, sendo utilizados exclusivamente modelos temporais. No que diz respeito a modelos causais, percebeu-se disponibilidade de um conjunto de variáveis que poderiam ser relevantes para este estudo, incluindo elasticidade de demanda, fatores cambiais e avaliação de adoção de promoções sobre os produtos, entre

outros. Contudo, as especificidades e o tamanho do setor, bem como a ausência de dados estruturados que pudessem justificar a utilização das variáveis mencionadas anteriormente limitaram a aplicação das mesmas neste trabalho.

- Neste estudo também não serão abordadas questões relacionadas ao planejamento de necessidade de materiais (*MRP*) e custos relacionados a este processo.
- O estudo de caso deste trabalho tem como foco o setor alimentício, sendo realizado em uma pizzaria do ABC paulista. Sendo assim, generalizações e aplicações em outros segmentos deverão ser consideradas de acordo com as especificidades de cada setor.

2. REVISÃO DA LITERATURA

Nesta seção, será apresentada uma visão geral sobre o contexto do cenário do setor alimentício brasileiro, dando destaque ao segmento de pizzarias que será utilizado para elaboração do estudo de caso deste trabalho. Também serão abordadas as definições de clusterização e previsão de demanda, bem como seus tipos e aplicações práticas.

2.1. O SETOR ALIMENTÍCIO

As fortes mudanças no cenário externo causaram instabilidade na economia brasileira em 2018. Somado a isto, houve uma piora nas condições internas do país. Segundo relatórios de conjuntura econômica do IPEA realizados em 2018, o crescimento desacelerou, mas a retomada econômica continua. Neste contexto, esperava-se que as incertezas externas e internas fossem dissipadas gradualmente até o final de 2018, e que o PIB atingisse um crescimento de 1,7%. Com relação ao comércio internacional, em volume, apesar de algumas turbulências, segundo o Fundo Monetário Internacional (FMI), em 2018, a expectativa era de um crescimento de 5% a.a.

De acordo com estudos do IPEA (2018), em relação ao cenário externo, é fundamental salientar dois importantes fatores associados aos Estados Unidos, que impactaram a economia brasileira: 1º) a perspectiva de uma elevação da taxa de juros americana, dada a redução da taxa de desemprego do país e à aceleração da inflação e; 2º) a implantação de medidas protecionistas contra importações, afetando principalmente os setores de aço e alumínio. Já no âmbito interno, a principal influência sobre a economia brasileira foi relacionada à pressão sobre a taxa de câmbio. Outro ponto importante a se frisar é que, embora tenha havido um crescimento da percepção de risco dos países emergentes, riscos de calote de dívidas soberanas, esta percepção de risco aumentou de forma mais significativa no Brasil.

No cenário interno, a causa raiz da instabilidade esteve ligada às indefinições sobre os problemas fiscais. O déficit esperado para o governo era de 2,2% do PIB em 2018, versus 1,8% em 2017. Situação esteve agravada pela greve dos caminhoneiros, restringindo a oferta de produtos e causando aumento de preços. De acordo com o IPEA em 2018, além dos efeitos diretos desta greve sobre a economia, esta situação pode ter piorado a percepção de risco país, já agravada pelas indefinições do cenário eleitoral, deixando ainda mais cautelosas as decisões de consumo e investimento. No setor de pizzarias, segundo a opinião de especialistas da Associação das pizzarias do Estado de São Paulo em 2018, apesar de um cenário econômico

ainda bastante incerto, mas, já refletindo uma retomada do crescimento, em 2018, era esperado um investimento 36% maior em Marketing e 33% maior em infraestrutura frente ao ano anterior. Quanto aos níveis de receita, margem e unidades vendidas, era esperado um crescimento de 13%, 22% e 20% respectivamente frente a 2017.

Estudos do IPEA de 2018 também mostram que, no mercado de trabalho, a taxa desemprego que apresentava uma queda desde 2017 estabilizou-se em 12,5%. O que ainda é um patamar bastante alto se comparado ao período anterior à crise. Ao considerar-se especificamente o setor de alimentos, segundo a Associação das pizzarias do Estado de São Paulo (2018), o alto nível de desemprego e as incertezas com relação à manutenção deste frente ao cenário econômico no geral acabaram por criar uma nova dinâmica para o setor, visto que as pessoas passaram a ajustar seu padrão de consumo. Os consumidores passaram a privilegiar o consumo de produtos que pudessem atender a família como um todo, otimizando o gasto por pessoa.

Quanto à inflação, conforme análises do IPEA em 2018, embora a greve dos caminhoneiros tenha causado um aumento de preços, principalmente para os insumos mais afetados (tais como leite, frango, carne de porco e ovos) não era esperado que a inflação ultrapasse a meta estipulada para 2018, fixada em 4,5% a.a. Referente ao setor de pizzarias, visando a manutenção dos níveis de demanda, muitas empresas acabaram segurando o repasse de preços no 1º semestre de 2018. Contudo, foi inevitável o repasse de preços no 2º semestre do ano de uma parte dos incrementos dos custos de insumos produtivos.

Referente à questão cambial, o efeito da desvalorização sobre a inflação foi minimizado pelo fato da economia brasileira ainda apresentar altos níveis de capacidade ociosa, permitindo um aumento da produção para compensar uma possível maior demanda externa, uma vez que os produtos locais ficam mais baratos (IPEA, 2018).

Mais especificamente sobre o setor de pizzarias abordado neste trabalho, de acordo com a Associação das pizzarias do Estado de São Paulo, em 2018, no Brasil foram produzidas mais de um milhão de pizzas por dia. Deste número, 572 mil unidades foram consumidas no estado de São Paulo e estima-se que em todo o país sejam gastos mais de R\$22 bilhões por ano com o consumo de pizzas. Os sabores preferidos pelos consumidores no Brasil permanecem sendo Mussarela, Calabresa, Portuguesa e Marguerita. Um desafio para os empresários que investem neste setor tem sido a concorrência. Atualmente existem mais de 36 mil pizzarias espalhadas por todo o Brasil, sendo que 80% destas pizzarias trabalham apenas com o sistema de *delivery*, que demanda baixo investimento para início das atividades.

Outro desafio para os empresários do setor de pizzarias, segundo a Associação das pizzarias do Estado de São Paulo (2018), tem sido a concorrência com as pizzas vendidas no varejo. Com a desaceleração da economia brasileira nos últimos anos, gerando um alto índice de desemprego, os brasileiros têm mudado seu padrão de consumo, optando por comer mais em casa. Porém, estes consumidores continuam buscando manter a qualidade do consumo dos produtos em seus lares. Nesta linha, várias marcas que comercializam pizzas no varejo têm se especializado em oferecer pizzas que buscam transmitir um conceito Premium aos consumidores, utilizando ingredientes e massas de alta qualidade, trabalhando com a diversificação de sabores e tamanhos das pizzas e, além disto, oferecendo o diferencial de não cobrarem o valor de entrega.

2.2. FUNDAMENTOS DE CLUSTERIZAÇÃO

De acordo com Rencher (2002) e Everitt *et al.* (2011), o objetivo da análise de cluster é realizar o agrupamento de uma base de dados, formando grupos cujas observações possuam características semelhantes e permitam interpretações coerentes.

Para agrupar as observações, as comparações são feitas entre pares de observações, seja levando em conta a distância entre elas, utilizando a escolha preliminar de centros de cluster (centroides) ou através de uma medida de variação dentro e entre os clusters. Também é possível agrupar as observações por medições de correlação entre elas (EVERITT; LEESE; LANDAU; STAHL, 2011; RENCHER, 2002). Os autores apontam que as técnicas de clusterização têm sido amplamente aplicadas em vários campos, tais como medicina, antropologia, geologia, geografia, pesquisa de mercado, economia, engenharia, etc.

As duas abordagens mais utilizadas para agrupar observações são o agrupamento hierárquico e o particionamento. No agrupamento hierárquico, começa-se com k clusters (um para cada observação) e termina-se com um único cluster contendo todas as observações. Em cada nova etapa, como afirmam Rencher (2002) e Everitt *et al.* (2011), uma observação ou cluster é absorvida por outro cluster. Já no particionamento, simplesmente dividem-se as observações em clusters. Isso pode ser feito iniciando-se com um particionamento inicial ou com centros de clusters; na sequência, realocam-se as observações de acordo com algum critério de otimização. Existem duas formas tradicionais de formação de cluster: hierárquica e não hierárquica, as quais são detalhadas na sequência.

2.2.1. Clusterização hierárquica (dendrograma)

Métodos hierárquicos de clusterização buscam clusters consistentes com base nas observações disponíveis, utilizando técnicas computacionais eficientes. Normalmente não é possível examinar todas as possibilidades de agrupamento, especialmente quando se tem uma grande base de observações (GAN; MA; WU, 2007; RENCHER, 2002).

Os métodos hierárquicos permitem encontrar uma solução razoável sem testar todos os agrupamentos possíveis, apoiando-se em um processo sequencial. Na abordagem hierárquica aglomerativa, uma observação ou um cluster de observações é agrupado dentro de outro cluster. Neste processo, o número de clusters diminui e os próprios clusters crescem. Começa-se com um número de clusters igual ao número inicial de observações (dados individuais) e termina-se com um único cluster contendo todo conjunto de dados. Uma abordagem alternativa, chamada método divisivo, começa com um único cluster contendo todas as observações e particiona um cluster em dois clusters a cada etapa. O resultado final da abordagem divisiva é a obtenção de vários clusters contendo uma única observação cada. O método aglomerativo é mais comumente usado do que o método divisivo e, em ambos os métodos, a decisão principal está relacionada ao número ideal de agrupamentos que devem ser utilizados (RENCHE, 2002).

Os resultados de uma clusterização hierárquica podem ser representados graficamente usando o diagrama de árvore, também conhecido como dendrograma, que representa todas as etapas do procedimento hierárquico incluindo as distâncias que os clusters serão agrupados (GAN; MA; WU, 2007; RENCHER, 2002).

2.2.2. Método não hierárquico: particionamento (K-Means)

Na abordagem de particionamento, as observações são separadas em k clusters sem a utilização da abordagem hierárquica, baseada na matriz de distâncias ou nas similaridades entre todos os pares de observações. Este método também é chamado de método da otimização, pois realiza o somatório das distâncias Euclidianas entre as observações. A estratégia neste caso é examinar todas as possíveis maneiras de particionar as n observações em k clusters e encontrar clusters otimizados com base em algum critério.

Uma abordagem bastante utilizada no método de particionamento é o método K-Means. De acordo com Rencher (2002) e Everitt *et al.* (2011), este método permite mover uma observação de um cluster para o outro, o que não é válido no método hierárquico. Neste caso, primeiro selecione n itens para servir de amostra. Estes depois serão substituídos por centroides dos

clusters. Há várias maneiras de se escolher a amostra: a) selecionar n itens de forma aleatória (talvez separados por uma distância mínima); b) selecionar o primeiro n item de um conjunto de dados, novamente associado a uma distância mínima; c) selecionar os n pontos que estão mais distantes; d) encontrar os pontos de densidade máxima ou; e) especifique pontos regularmente espaçados em um padrão de grade. Neste método, o número de cluster, k , deve ser especificado.

Depois de escolhida a amostra, todos os pontos restantes são atribuídos à amostra mais próxima. Tão logo o cluster tenha mais de um membro, esta amostra de cluster é substituída por um centroide. Após todos os pontos restantes serem atribuídos a um cluster, cada item é examinado para ver se ele está mais próximo do centroide de outro cluster ou do próprio cluster. Se este estiver mais próximo de outro cluster, o item se moverá para o cluster cujo está mais próximo, atualizando ambos os clusters. Este processo continua até que não haja benefício adicional. Vale ressaltar que, se ao revisar-se as escolhas das amostras feitas inicialmente e obter-se clusters diferentes, ou se a convergências das informações forem lentas, podem não haver cluster naturais nos dados (GAN; GUOJUN; CHAOQUN MA; JIANHONG WU, 2007; EVERITT; LEESE; LANDAU; STAHL, 2011; RENCHER, 2002).

O método de particionamento K-Means também pode ser usado para aperfeiçoamento em técnicas hierárquicas. Primeiro agrupam-se as observações usando o método hierárquico (usando dendrograma) e, na sequência, utilizam-se os centroides destes clusters como amostras para uma abordagem K-Means, permitindo que os pontos sejam realocados de um cluster para outro (GAN; GUOJUN; CHAOQUN MA; JIANHONG WU, 2007; EVERITT; LEESE; LANDAU; STAHL, 2011; RENCHER, 2002).

2.2.3. Técnicas para análise de clusters e aplicações práticas

Everitt *et al.* (2011) aponta algumas técnicas para a construção e análise de clusters hierárquicos e não hierárquicos, os quais são expostos a seguir: i) Definição dos objetos (dados/produtos) do cluster: seleção de uma amostra representativa de dados para os quais se deseja realizar o agrupamento por grau de similaridade; ii) Definição das variáveis: estas só poderão ser selecionadas se realmente forem importantes para a definição dos clusters; iii) Acomodação de valores: que consiste na acomodação dos dados que ficaram isolados ou equidistantes dos centros de clusters por critérios de correlação com seus pares mais próximos, identificando em qual cluster estes deveriam se enquadrar; iv) Padronização de variáveis: de forma a facilitar a

comparação dos dados e conseqüentemente seu agrupamento por similaridade; v) Definição dos números de cluster e interpretação dos resultados: embora os softwares recomendem o número de clusters a serem gerados, este é um passo complexo e que requer uma avaliação qualitativa para verificar se o número de clusters faz sentido frente ao cenário analisado. Estes passos são utilizados na aplicação do conceito de clusterização para os mais variados casos, os quais alguns serão expostos a seguir.

Shahraki *et al.* (2020), realizaram um estudo sobre redes de sensores sem fio (Wireless Sensor Network – WSNs) com o intuito de melhorar a transferência de dados entre máquinas remotas. Embora as WSNs sejam altamente flexíveis, atualmente existem vários desafios relacionados a gerenciamento destas redes visando melhoria da qualidade, escalabilidade e confiabilidade dos sinais. Para isto, os autores propuseram estudos de clusterização para tornar mais eficiente a utilização dos recursos disponíveis (para execução de várias tarefas de maneira distribuída) e melhorar o consumo de energia e conseqüentemente a qualidade do sinal.

No mercado financeiro, Baig *et al.* (2019) apontam que agregação de preços têm sido cada vez mais utilizados para entender a volatilidade de preços de moedas digitais, tais como o Bitcoin. Estes estudos têm buscado evidenciar as relações entre o comportamento dos preços ao longo dos dias da semana e no decorrer do próprio dia, além de avaliar a sua relação com o sentimento dos investidores (especialmente no que tange ao refinamento das negociações de preços para compra da moeda e seus custos associados).

De acordo com Arango e Ukkusuri (2015), há uma tendência mundial em realizar estudos de forma a agrupar a demanda de fretes logísticos em regiões específicas e por tipo de carga, a fim de detectar potenciais economias de escalas no transporte de mercadorias e desenvolver estratégias de aumento de receitas, especialmente para novos negócios. No estudo dos autores acima, foi encontrada uma interdependência na série histórica de dados que permitiu a associação entre a variável volume transportado e preço do frete; objetivava-se a otimização das rotas logísticas disponíveis, de maneira a tornar a operação mais rentável.

Outro exemplo de aplicação de técnicas de clusterização referem-se à avaliação da demanda de turismo. Jun *et al.* (2018) propuseram agrupamentos com o intuito de identificar similaridades no comportamento da demanda por turismo na região da Ásia, agrupando os turistas em grupos de clusters e facilitando a previsão de demanda de turismo na região. Os resultados obtidos guiam a definição das políticas de investimentos em infraestrutura tanto no setor privado quanto no setor público na região.

2.3. SILHOUETTE INDEX

A eficiência dos agrupamentos encontrados através da clusterização podem ser mensuradas através do Silhouette Index (SI), índice que analisa o quão semelhantes são as observações dentro do seu cluster, levando-se em conta as observações contidas em outros clusters (Kaufman e Rousseeuw, 2005). Cada observação apresenta um SI_n , podendo este variar entre $[-1;1]$; sendo n a observação analisada. Valores de SI_n próximos a 1, indicam que há uma grande semelhança entre a observação analisada e as demais observações contidas dentro do cluster onde estas se encontram, ou seja, a observação foi adequadamente alocada no cluster atual. Já SI_n próximos a -1 sinalizam que a observação foi possivelmente alocada em um cluster inadequado. Kaufman e Rousseeuw (2005), com base nos estudos realizados em seus trabalhos, propõe a seguinte interpretação para os valores encontrados de SI para avaliar o grau de semelhança das observações dentro do cluster onde se encontram:

- $0,70 < SI_n \leq 1,00 \rightarrow$ forte evidência de semelhança entre as observações contidas no cluster;
- $0,50 < SI_n \leq 0,70 \rightarrow$ evidência razoável de semelhança entre as observações contidas no cluster;
- $0,25 < SI_n \leq 0,50 \rightarrow$ fraca evidência de semelhança entre as observações contidas no cluster;
- $SI_n \leq 0,25 \rightarrow$ sem sinal de evidência de semelhança entre as observações contidas no cluster;

O SI_n pode ser calculado através da seguinte equação (ANZANELLO; FOGLIATTO, 2011):

$$\frac{b(n) - a(n)}{\max\{b(n), a(n)\}} \quad (1)$$

sendo $a(n)$ a média das distâncias da n -ésima observação em relação a todas as demais observações dentro do mesmo cluster, e $b(n)$ a média das distâncias da n -ésima observação comparada as observações alocadas no cluster mais próximo.

Como o SI é um índice baseado em distâncias, não apresentará dependência a técnica de clusterização utilizada, podendo ser utilizado para mensurar a qualidade geral do método de clusterização pela média de SI_n de acordo com a equação abaixo:

$$\overline{SI} = \frac{\sum_{n=1}^N SI_n}{N} \quad (2)$$

sendo n o índice da observação e N representando o total de observações.

2.4. PREVISÃO DE DEMANDA

A previsão de demanda de produtos e serviços tem um papel cada vez mais importante para a tomada de decisão das empresas, fornecendo informações fundamentais para um bom planejamento e controle de todas as áreas das organizações (MURDICK; GEORGOFF, 1993; MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998; BALLOU, 2001).

Nas organizações, a expressão previsão de demanda (*forecast*) é frequentemente confundida com os conceitos de planejamento (*planning*) e objetivos (*goals*). Vale ressaltar que o processo de *forecast* trata da capacidade de se prever eventos futuros de forma acurada, considerando toda base de dados históricos disponíveis e o conhecimento sobre eventos futuros que podem impactar a previsão de demanda. Já os *goals*, devem estar associados aos processos de *forecast* e *planning* e, se estão relacionados às metas estabelecidas pelas empresas. E, por fim, o processo de *planning* é uma resposta aos processos de *forecast* e aos *goals* da empresa, determinando um plano de ações para garantir que a previsão de demanda esteja alinhada com os objetivos da empresa (HYNDMAN; ATHANASOPOULOS, 2018). Quanto mais acurado for o processo de previsão de demanda, mais informações as empresas terão para construir um bom plano de ações para garantir que suas metas sejam atingidas (THOMOPOULOS, 2015).

Dentre os principais fatores que têm impulsionado o desenvolvimento de sistemas de previsão de demanda e a incorporação destas previsões para a tomada de decisões dentro das organizações, estão o aumento da complexidade da gestão das empresas e do mercado, a necessidade de se sistematizar modelos para a tomada de decisão, o avanço no desenvolvimento de métodos de previsão e a facilidade de aplicação prática dos métodos de previsão por parte dos tomadores de decisão (MAKRIDAKIS; WHEELWRIGHT; McGEE apud WINKLHOFER; DIAMANTOPOULOS; WITT, 1996; KOLASSA; SIEMSE, 2018; JAIN; MALEHORN, 2013; MICHAEL; LEN; UDO, 2017). Pode-se citar também que o curto ciclo de vida de produtos, o aumento da concorrência e as agressivas ações de marketing também têm tornado o processo de previsão de demanda cada vez mais complexo (TRAPERO, *et al.* 2013).

Previsões acuradas colaboram para o desenvolvimento de estratégias, definição de prioridades e alocação de recursos (THOMAS, 1987; LYNN; SCHNAARS; SKOV, 1999), além de possibilitar, através da operacionalização eficiente da produção e serviços, que as organizações ofereçam altos níveis de serviços aos clientes, forneçam informações futuras mais precisas aos fornecedores, planejem expansões de capacidade e evitem perdas nas vendas e estoques (KOTLER, 1991; MOON et al., 1998; KAHN, 2002). A acurácia de uma previsão está

relacionada à habilidade do método em estimar mais precisamente os valores futuros (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998). Realizar a previsão de demanda valendo-se apenas de uma técnica, no entanto, pode não gerar resultados satisfatórios. Desta forma, cada vez mais são utilizados a combinação de métodos contendo o maior número de informações relevantes para a realização de um exercício de previsão visando um maior grau de acurácia (WERNER, 2004).

Segundo Hyndman e Athanasopoulos (2018), a previsibilidade de eventos futuros ou quantidades dependem de três fatores: i) o quanto se conhece sobre os estes fatores; ii) o quanto de dados se tem disponível; e iii) se o modelo de previsão de demanda que se pretende utilizar realmente pode contribuir para uma previsão acurada dos eventos futuros (sazonalidades) e das quantidades.

É importante salientar que erros são inevitáveis no processo preditivo, sendo este limitado pela acurácia das suposições nas quais ele se baseia (EVANS, 1982). A acurácia da previsão está relacionada à precisão dos dados de entrada do sistema, à estabilidade no processo gerador dos dados, ao horizonte de previsão, às flutuações de demanda e do método de previsão a ser utilizado (ELSAYED; BOUCHER, 1994). Quanto mais instável a demanda, mais criteriosa se torna a escolha do sistema necessário para a elaboração do processo de previsão (KOTLER, 1991). Muitas pessoas assumem erroneamente que não é possível realizar previsões de demanda em ambientes em constante mudança. Todo e qualquer ambiente está em mudança e, bons modelos de previsão de demanda devem ser capazes de capturar estas volatilidades de cenário. São raros os modelos de previsão de demanda que não assumem cenários de mudanças, o comum é tentar identificar em que nível estas mudanças continuarão a ocorrer no futuro (HYNDMAN; ATHANASOPOULOS, 2018).

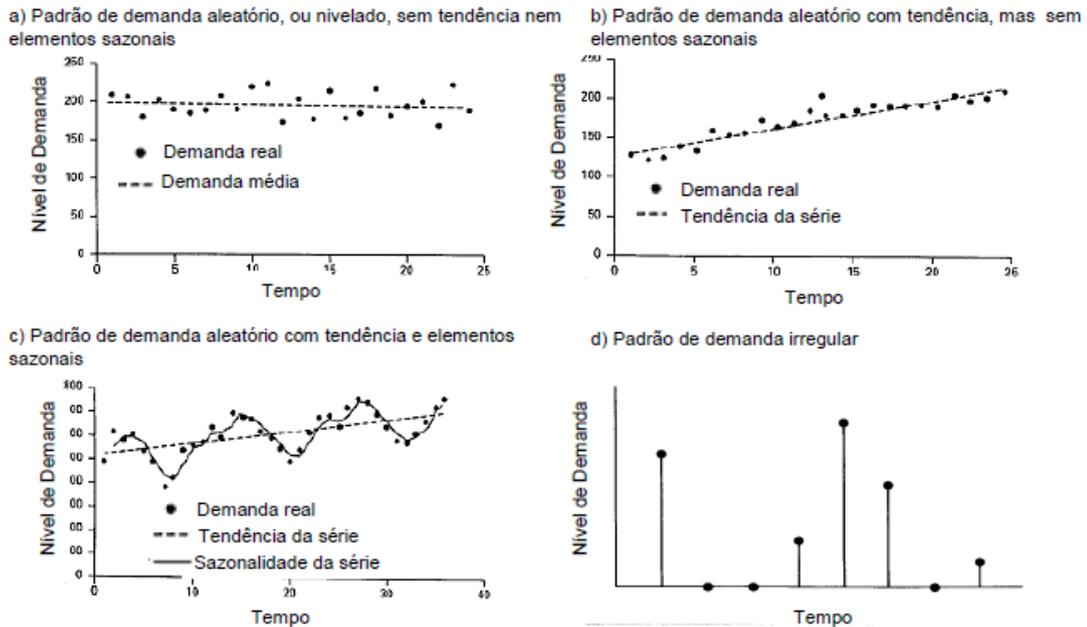
2.4.1. Elementos dos modelos de previsão

Existem dois tipos de padrões de demanda, os padrões de demanda regular e de demanda irregular. Com relação aos padrões de demanda regular, estes podem ser segmentados em cinco componentes (MENTZER; GOMES, 1989; MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998):

- i) Demanda média para o período (Figura 1a): sem elementos de tendência ou sazonais na sua composição (Ballou, 2001);

- ii) Tendência (Figuras 1b e 1c): há uma tendência de crescimento ou decréscimo de longo prazo na série de dados. Vale salientar que esta tendência não necessariamente precisa ser linear, podendo às vezes ser representada por uma tendência de mudança de direção (de crescimento para queda e vice-versa) (HYNDMAN; ATHANASOPOULOS, 2018);
- iii) Sazonalidade (Figura 1c): quando a série temporal é afetada por fatores sazonais em um período de tempo do ano (Black Friday, Natal, etc.) ou dia da semana (promoções semanais para uma linha específica de produtos). Um aspecto importante relacionado a fatores sazonais são que eles possuem uma frequência fixa e conhecida (HYNDMAN; ATHANASOPOULOS, 2018);
- iv) Fatores cíclicos: ocorrem quando se observa picos e vales em uma série de dados, mas, que ao contrário do que ocorre em séries de comportamento sazonal, não possuem uma tendência fixa de frequência. Neste caso, as flutuações normalmente estão relacionadas ao cenário econômico ou a períodos de ciclos do negócio (HYNDMAN; ATHANASOPOULOS, 2018);
- v) Variação aleatória (erro aleatório): referem-se às parcelas da demanda que não são explicadas pelos outros componentes mencionados (KOTLER, 1991; BALLOU, 2001). Do ponto de vista estatístico, quando se subtrai da demanda total todos os fatos conhecidos, como a média, tendência, sazonalidade e ciclos, o que remanesce é uma parte inexplicável. Caso não seja possível identificar as suas causas, isto é presumido como algo puramente aleatório (DAVIS; AQUILANO; CHASE, 2001).

Figura 1: Padrões de demanda regular e irregular (Fonte: Ballou, 2001)



Fonte: Ballou *apud* Lemos (2006)

O padrão de demanda irregular, evidenciado pelo último gráfico na Figura 1, é observado em casos de demandas intermitentes ou por um alto grau de incerteza referente ao momento e nível de ocorrência da demanda. Estes tipos de padrões de demanda são difíceis de prever e ocorrem por vários motivos, tais como: a) quando o padrão de demanda é determinado por pedidos de clientes representativos não-frequentes; b) caso a demanda seja derivada da demanda de outros produtos e serviços; c) quando o padrão de demanda é resultado de dados espúrios ou de eventos especiais; entre outros (BALLOU, 2001). Este tipo de comportamento de demanda pode causar problemas de capacidade ociosa ou a necessidade de horas extras (não planejadas, dado a falta de visibilidade da demanda). Para corrigir este tipo de desvio, normalmente, são aplicadas ações de preços, promoções entre outros incentivos ou ações que possam equilibrar a demanda (BARNES, 2001).

É possível classificar o horizonte de previsão em função de períodos futuros ou através de unidades de tempo, dependendo do cenário da previsão conforme pode-se observar na Tabela 1.

Horizonte de previsão de demanda	Classificação em função de períodos futuros	Classificação em função de unidades de tempo	Aplicabilidade ao negócio
Curto Prazo	Se o horizonte for de até 3 períodos no futuro	Variando de horas a 3 meses	Realizar a programação de mão de obra, produção e transporte (HYNDMAN; ATHANASOPOULOS, 2018);
Médio Prazo	Se o horizonte for de 3 a 20 períodos no futuro	Abrangendo um período de 3 meses a 2 anos	Preparar fontes de recursos futuros no que tange compra de matéria prima, contratação de mão de obra e compra de equipamentos (HYNDMAN; ATHANASOPOULOS, 2018)
Longo Prazo	Se o horizonte considera mais de 20 períodos no futuro (JOHNSON; KING apud WERNER, 2004)	Sendo um período de tempo superior a 2 anos (CHAMBERS; MULLICK; SMITH, 1971; MAKRIDAKIS, 1998)	Realizar o planejamento estratégico das empresas, levando-se em conta oportunidades de mercado, ambiente externo e recursos internos.

Tabela 1: Classificação de previsões de demanda em função de períodos futuros e unidades de tempo (Fonte: Lemos, 2006 adaptada pelo autor)

2.4.2. Modelos quantitativos de previsão de demanda

2.4.2.1. Suavização exponencial simples

Neste método, se obtém a previsão de demanda para um período futuro através do ajuste da previsão do período atual utilizando o erro de previsão. A previsão do período $t + 1$ será igual à previsão do período t somado o ajuste para o erro que ocorreu na previsão do período t , como se pode observar na equação (3). Pela sua forma geral, o método de Suavização Exponencial Simples é apresentado pela equação (4), onde é acrescentado um parâmetro de suavização α aos valores mais recentes Y_t , e um peso $1-\alpha$ para as previsões mais recentes (WINTERS, 1960; MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998; HOLT, 2004). Na equação (5), obtém-se a forma expandida da equação (4), na qual a previsão está representada em função de todos os dados da série temporal (WINTERS, 1960).

$$F_{t+1} = F_t + \alpha(Y_t - F_t) \quad (3)$$

$$F_{t+1} = \alpha Y_t + (1 - \alpha)F_t \quad (4)$$

$$F_{t+1} = \alpha \sum_{i=0}^n (1 - \alpha)^i Y_{t-i} + (1 - \alpha)^t F_1 \quad (5)$$

sendo F_{t+1} a previsão para o período $t + 1$, F_t a previsão para o período t , Y_t a demanda realizada no período t , n o tamanho da série temporal e α a constante de suavização com valor entre 0 e 1.

Quanto mais próximo de 1 for o valor de α , maior o ajuste do erro na previsão anterior, ou seja, o modelo dá ênfase a demandas recentes, sendo mais sensível a mudanças. Por outro lado, quanto mais próximo de 0 for α , menor o ajuste do erro na previsão anterior, fazendo com que o modelo considere as demandas históricas mais uniformemente e gere previsões mais estáveis (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998; KRAJEWSKI; RITZMAN, 2002; LUSTOSA *et al.*, 2008).

Para inicializar o método é necessário se ter o valor de F_1 , podendo-se proceder de duas maneiras para obtê-lo: 1) considerar F_1 igual a Y_1 ou; 2) utilizar um valor obtido através da média das primeiras observações da série temporal. Um problema deste modelo é a definição de um α ótimo, podendo isto ser feito pela minimização de erros. Para isto, definem-se determinados valores de α , gera-se o método e o erro é obtido para diferentes valores de α . O parâmetro de suavização (α) ótimo será aquele que apresentar o menor valor de erro nas previsões (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998; RASMUSSEN, 2004; ANZANELLO; FERNANDES, 2010).

Ainda segundo Makridakis, Wheelwright, Hyndman (1998), o método de Suavização Exponencial Simples com taxa de resposta adaptável se coloca com uma alternativa ao método tradicional, permitindo a alteração do parâmetro de suavização α , de maneira controlada, quando ocorrem mudanças nos padrões dos dados. Havendo uma grande quantidade de itens envolvidos no processo preditivo, este método se torna bastante útil.

Por fim, o método de Suavização Exponencial Simples considera que o padrão de demanda histórica possui somente componentes de nível e ruído. Caso haja componentes de tendência e sazonalidade nos dados históricos, a Suavização Exponencial Simples passa a não ser o método de extrapolação mais indicado (MENTZER; GOMES, 1989; MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998; ANZANELLO; FERNANDES, 2010).

2.4.2.2. Suavização exponencial dupla (suavização exponencial linear de Holt)

O método da Suavização Linear de Holt, também conhecido como Suavização Exponencial Dupla, amplia o método de Suavização Exponencial Simples para previsões que contemplam dados que apresentam tendência linear, mas que não possuem sazonalidade (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998; RASMUSSEN, 2004; LUSTOSA *et al.*, 2008).

Pode-se obter uma previsão com Suavização Exponencial Linear de Holt através do uso de duas constantes de suavização, α e β (com valores entre 0 e 1, e não relacionados), e das equações (6), (7) e (8) a seguir (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998; TAYLOR, 2003; RASMUSSEN, 2004; LUSTOSA *et al.*, 2008):

$$\text{Previsão: } F_{t+m} = L_t + b_t m \quad (6)$$

$$\text{Nível: } L_t = \alpha Y_t + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad (7)$$

$$\text{Tendência: } b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \quad (8)$$

onde F_{t+m} representa a previsão para o período $t + m$, m é o horizonte da previsão, L_t é a estimativa do nível da série temporal no período t , b_t é a estimativa de tendência da série temporal para o período t e, α e β são as constantes de suavização.

Através da equação (6) obtém-se a previsão de demanda, sendo que o valor base L_t é somado à tendência (b_t) e multiplicado pelo número de períodos futuros a serem previstos (horizonte de previsão – m). Já a equação (7) ajusta diretamente L_t para a tendência do período anterior, pela adição de b_{t-1} ao último valor suavizado de nível L_{t-1} . Este procedimento auxilia a eliminar o atraso na incorporação de ajustes do padrão de demanda e direciona o valor de L_t para um nível próximo do valor da demanda atual da série temporal. Por fim, a equação (8) atualiza a tendência pela diferença entre os últimos dois valores suavizados de nível (L_t e L_{t-1}) (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998; LUSTOSA *et al.*, 2008; ANZANELLO; FERNANDES, 2010).

A estruturação do método de Holt demanda duas estimativas, onde a primeira é o valor suavizado para L_1 e segunda a tendência para b_1 . Uma alternativa seria considerar L_1 igual a Y_1 e b_1 igual a zero ou a diferença entre os dois primeiros valores da série ($Y_2 - Y_1$). Assim como no método de Suavização Exponencial Simples, os valores de α e β podem se obtidos através da minimização do erro da previsão (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998; KRAJEWSKI; RITZMAN, 2002; RASMUSSEN, 2004; ANZANELLO; FERNANDES, 2010).

2.4.2.3. Suavização exponencial tripla (método de Holt-Winters)

O método de Holt-Winters é utilizado quando as séries temporais apresentam padrão de demanda com tendência linear e sazonalidade. Este método utiliza equações de suavização para

estimar o nível, a tendência e a sazonalidade da série temporal analisada no processo de previsão (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998; LUSTOSA *et al.*, 2008).

Este método também apresenta duas abordagens diferentes, estando estas atreladas à forma como é modelada a sazonalidade. A primeira, forma multiplicativa, é recomendada para séries temporais onde a amplitude da sazonalidade varia de acordo com o nível da demanda. Já a segunda, forma aditiva, é indicada para séries temporais na qual a amplitude não é dependente do nível de demanda (WINTERS, 1960).

As equações básicas do método multiplicativo de Holt-Winters são (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998; HOLT, 2004; RASMUSSEN, 2004):

$$\text{Previsão: } F_{t+m} = (L_t + b_t m) S_{t-s+m} \quad (9)$$

$$\text{Nível: } L_t = \alpha \frac{Y_t}{S_{t-s}} + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad (10)$$

$$\text{Tendência: } b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \quad (11)$$

$$\text{Sazonalidade: } S_t = \gamma \frac{Y_t}{L_t} + (1 - \gamma)S_{t-s} \quad (12)$$

sendo s o número de períodos por ciclo sazonal, S_t a estimativa do componente sazonal da série temporal no período t e α , β e γ seriam as constantes de suavização (com valores entre 0 e 1, e não relacionados).

Através da equação (9), pode-se obter a previsão de demanda, sendo esta obtida pela multiplicação da estimativa de um componente sazonal (S_{t-s+m}) à previsão do método linear de Holt [equação (6)]. A equação (10) tem a função de ajustar L_t para a tendência do período anterior, pela adição de b_{t-1} ao último valor suavizado de nível L_{t-1} . O primeiro termo da equação (10) é dividido por um termo sazonal (S_{t-s}) com o intuito de eliminar flutuações sazonais no cálculo do nível L_t . A equação (11) tem como finalidade atualizar a tendência através da diferença entre os últimos dois valores suavizados de nível (L_t e L_{t-1}). Por fim, a equação (12) prevê o componente sazonal pela ponderação, utilizando uma constante de suavização γ , da razão de Y_t e L_t (que representa a sazonalidade do período t) com a sazonalidade S_{t-s} , correspondente à sazonalidade do período analisado do ciclo sazonal anterior (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998; KRAJEWSKI; RITZMAN, 2002).

O método aditivo de Holt-Winters é menos comum que o método multiplicativo e trata o componente sazonal de forma aditiva. As equações básicas deste método são (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998; HOLT, 2004; RASMUSSEN, 2004):

$$\text{Previsão: } F_{t+m} = L_t + b_t m + S_{t-s+m} \quad (13)$$

$$\text{Nível: } L_t = \alpha(Y_t - S_{t-s}) + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad (14)$$

$$\text{Tendência: } b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \quad (15)$$

$$\text{Sazonalidade: } S_t = \gamma(Y_t - L_t) + (1 - \gamma)S_{t-s} \quad (16)$$

A diferença básica entre as formas aditiva e multiplicativa do método de Holt-Winters dizem respeito ao fato dos índices sazonais e de nível serem somados ou subtraídos ao invés de multiplicados ou divididos (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998; RASMUSSEN, 2004).

Para iniciar o método de Holt-Winters são necessários os valores iniciais de L_t , b_t e S_t , apresentados em Makridakis, Wheelwright e Hyndman (1998). Os parâmetros α , β e γ podem ser determinados de forma a minimizar o erro de previsão (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998; KRAJEWSKI; RITZMAN, 2002).

2.4.2.4. Média móvel

O método da média Móvel é vastamente utilizado por conta de sua facilidade de implementação, manutenção e pelo fato de necessitar de poucos dados históricos para sua aplicação. Contudo, este método é recomendado apenas para previsões de curto prazo e para dados históricos irregulares, onde o padrão da série temporal não apresenta tendência e sazonalidade (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

A Média Móvel calcula uma média aritmética ou ponderada das n observações mais recentes da série, sempre desprezando a observação mais antiga e incluindo a observação mais recente (CHAMBERS; MULLICK; SMITH, 1971; ARCHER, 1980; MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

Em cada média, o número de observações permanece constante e é apresentado de tal forma que os efeitos de sazonalidade ou aleatoriedade ou ambos sejam eliminados. As médias movem-se através da série temporal até que o componente de média seja considerado para cada período i da série temporal. As previsões para períodos anteriores à última observação da série temporal

serão iguais ao valor da última média calculada (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

As desvantagens deste método de previsão estão associadas ao fato do método não funcionar satisfatoriamente com séries com tendência e sazonalidade, pois a previsão para um novo período contempla sempre a adição de novos dados e a exclusão de dados anteriores (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998; DAVIS; AQUILANO; CHASE, 2001). Uma alternativa para endereçar essa falha é a média móvel ponderada; nesta, ao invés das observações entrarem e saírem abruptamente do intervalo de períodos usado na média, elas são gradativamente ponderadas dentro da média (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998; KRAJEWSKI; RITZMAN, 2002). A utilização da média móvel ponderada possui como desvantagem a necessidade de conhecimento para estabelecer os pesos a serem utilizados (DAVIS; AQUILANO; CHASE, 2001).

2.4.2.5. Modelo Arima

Os modelos ARIMA (*Auto-regressive Integrated Moving Average*) tem como propósito entender a correlação seriada ou a autocorrelação entre os dados da série temporal, e com base neste comportamento realizar previsões futuras. Segundo Morettin e Toloí (2006), estes modelos são recomendados para séries temporais cujo processo estocástico não é estacionário, ou seja, abordam séries que não apresentam uma média constante ao longo do tempo, mas que podem ser diferenciadas para se tornarem estacionárias. Estes modelos são flexíveis, uma vez que permitem ajustes nos seus parâmetros permitindo que diferentes tipos de séries temporais sejam utilizadas, havendo assim uma estrutura de correlação linear entre os valores das séries temporais (MORETTIN; TOLOI, 2006).

A utilização destes modelos é baseada em ações repetitivas cujos dados demonstram a estrutura do modelo. Estas ações repetitivas são realizadas até que o modelo ideal seja encontrado (cada novo ciclo a repetição se inicia pela fase 2). A seguir são representadas as 4 fases deste processo:

- Fase 1 (especificação) → deve-se escolher um grupo de modelos a serem analisados;
- Fase 2 (identificação) → observa-se a autocorrelação e autocorrelações parciais dos modelos;
- Fase 3 (estimação) → estima-se os parâmetros necessários dos modelos identificados;

- Fase 4 (verificação) → estando o modelo já ajustado nesta fase, realiza-se a análise dos resíduos. O resultado obtido nesta fase irá determinar se o modelo é ideal, ou não, para a previsão.

2.5. Modelos qualitativos de previsão de demanda

Dado ao aumento de fatores que podem afetar o desempenho das empresas, as previsões de demanda têm se tornado cada vez mais complexas (TRAPERO *et al.*, 2013), principalmente em situações onde há uma base de dados limitada ou não se tenha referência histórica (CHAMBERS; MULLICK; SMITH, 1971; GEORGOFF; MURDICK, 1986). Um dos grandes desafios das organizações tem sido encontrar formas para realizar a previsão de demanda que apresentem o menor erro (CHASE, 2013). De tal forma, modelos qualitativos combinados a modelos quantitativos têm sido frequentemente usados com vistas ao aumento da acurácia das previsões (BOPP, 1985; ROSSETTO *et al.*, 2011; CASAGRANDE; HOSS, 2010). Um dos diferenciais da adição de métodos qualitativos no processo de previsão de demanda se deve ao fato deste se valer da experiência de especialistas ou da opinião de entrevistados para buscar um consenso nas previsões (SANDERS; MANRODT, 1994; GOODWIN, 2002; ELSAYED; BOUCHER, 1994; ARMSTRONG, 2001).

Para realização adequada da combinação de modelos quantitativos e qualitativos, recomenda-se que primeiro seja realizada a previsão de demanda quantitativa e, logo após, que os dados sejam analisados considerando a opinião de especialistas, associando assim informações matemáticas e subjetivas, de forma a se obter maior acurácia nas previsões (WERNER; RIBEIRO, 2006; DIAS, 2004; CASAGRANDE; HOSS, 2010; ANZANELLO; FERNANDES, 2010). A Figura 2 traz alguns métodos qualitativos de previsão de demanda, bem como recomendações acerca de sua utilização.

Figura 2: Métodos qualitativos de previsão de demanda (Adaptado de ARMSTRONG, 2001)

Método	Quando utilizar	Como aplicar
Jogos de Representação (Role Playing)	<ul style="list-style-type: none"> - Situações em que os indivíduos não interagem diretamente; - Para simular interações entre partes conflitantes que possuem objetivos distintos; - Prever situações que envolvem grandes mudanças. 	<ul style="list-style-type: none"> - Coletar o máximo de informações sobre o assunto; - Selecionar os participantes e separá-los em dois grupos e separá-los; - Descrever o papel de cada participante antes de apresentá-los a situação: i) solicitar que hajam de acordo como eles mesmos agiriam ou como acreditam que as pessoas que estão representando agiriam; e ii) estimular os participantes a improvisar, porém sem sair de suas funções; - Apresentar a situação aos participantes de forma clara, abrangente e breve (oferecendo um ambiente realista); - Distribuir questionário e assegurar que os grupos estão prontos para a interação; - Autorizar a interação nos grupos até que se chegue a um consenso; - Separar os grupos e apresentar os resultados.
Pesquisa de intenções	<ul style="list-style-type: none"> - Realizar pesquisas para avaliar o compartimento futuro de variáveis (previsão de demanda) através da preferência dos consumidores; - Pontos de atenção: i) selecionar bem as pessoas que responderão o questionário de forma que elas demonstrem sua real intenção e não tenham receio de fornecer as respostas; ii) garantir que os participantes da pesquisa serão consumidores dos produtos/serviços pesquisados; e iii) recomendável para previsões de curto prazo pelo fato de estarem menos suscetíveis a mudanças de cenários. 	<ul style="list-style-type: none"> - Utilizar escalas de probabilidade de compras: de (0-5) ou (0-10), deixando claro o seu significado, como por exemplo: 0 = sem a intenção de compra e 5 = compra certa. OBS.: escalas de (0-10) são mais recomendadas pois, capturam maior uma maior variedade de informações; - A pesquisa pode ser realizada por telefone, email ou entrevista pessoal.
Opinião de especialistas (Delphi)	<ul style="list-style-type: none"> - Coletar a opinião de especialista no assunto analisado de forma a validar os resultados obtidos estão alinhados com a realidade, visando otimizar as previsões; - O especialista deve possuir conhecimento profundo sobre o assunto abordado; - Preserva o anonimato dos participantes; - Não utiliza reuniões por considerá-las improdutivas; - Elaboração de checklist para coleta de feedback dos participantes, pautado em interações repetitivas até que se tenha convergência das respostas; - Analisa os dados de forma gráfica para fazer os julgamentos. 	<ul style="list-style-type: none"> - Elaboração dos questionário; - Identificação e escolha dos especialistas; - Aplicação do questionário; - Análise gráfica dos resultados obtidos; - Verificação se os resultados obtidos são satisfatórios ou se é necessário a realização de novas perguntas; - Se informações forem satisfatórias, elaborar conclusões gerais e apresentá-las aos especialistas para validação e elaboração de um relatório final.

Fonte: Armstrong (2001) - Adaptado pelo autor

2.6. Previsão de demanda no setor alimentício

Artigos recentes têm mostrado a importância de estudos de previsão de demanda para se obter uma melhor eficiência no setor alimentício. Segundo Gruzauskas, Gimzauskiene e Navickas (2019), o constante crescimento urbano (é esperado que 70% das pessoas passem a viver nos centros urbanos em 2050), o aumento da demanda por produtos orgânicos (produtos com prazos de validade mais curtos, que precisam ser entregues mais rapidamente aos consumidores), a expansão dos canais *e-commerce* para a distribuição de alimentos (visando atender o constante crescimento populacional: é estimado que a população mundial alcance 9 bilhões de pessoas em 2050), somado a maior competição nos mercados, tem contribuído para uma maior pressão sobre a cadeia de suprimentos, uma vez que, os comportamentos de demanda têm se tornado

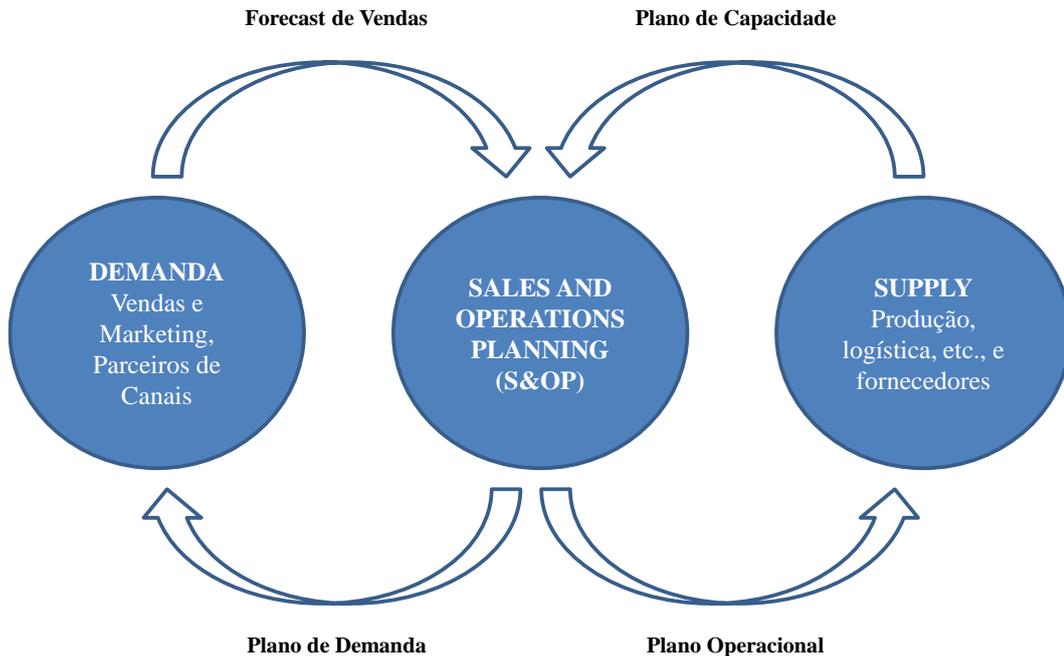
mais complexos e instáveis, gerando uma maior perda de alimentos. No intuito de evitar esta maior perda de alimentos, vários estudos estão sendo realizados visando melhorar a acuracidade da previsão de demanda e otimizar os níveis de inventário, promovendo um melhor equilíbrio entre as necessidades de demanda e a capacidade da cadeia de suprimentos.

Nesta linha, o conceito de resiliência da cadeia de suprimentos tem ganhado bastante relevância. Este conceito consiste na habilidade da cadeia de suprimentos em reduzir as probabilidades de ruptura e acelerar o tempo de resposta para sua recuperação caso haja algum desequilíbrio. De acordo com Gruzauskas, Gimzauskiene e Navickas (2019), as duas principais formas de se alcançar este objetivo são: i) garantir a flexibilidade de cadeia de suprimentos, de forma que possa haver uma redefinição ágil de estratégias diante cenários adversos; e ii) fomentar o compartilhamento das informações de demanda entre os membros da cadeia de suprimentos, de maneira que todos tenham maior visibilidade sobre o comportamento de demanda e possam adequar rapidamente suas capacidades conforme as flutuações de mercado. Flies, Brook, Blomqvist e Buettel (2018), também ressaltam o ponto de que bons modelos para a realização da previsão de demanda de alimentos devem levar em consideração uma série de avaliações, tais como: a opinião de especialistas de processos, preços futuros ou influência das condições climáticas nas previsões e o período de tempo que se deseja analisar.

2.7. Previsão de demanda e sua importância para o processo de S&OP

Muitas empresas têm na sua rotina discussões associadas a cancelamento de ordens de clientes, níveis altos de inventário, problemas com o fluxo de caixa, atraso de embarque de mercadorias, desbalanceamento entre planejamento da cadeia de suprimentos (*Supply / Capacity Plan / Operational Plan*) e o planejamento de vendas (*Demand / Sales forecast / Demand Plan*). Com o intuito de tentar mitigar estes tipos de problemas, muitas empresas têm adotado um processo chamado S&OP (*Sales & Operations Planning*). Conforme se pode observar através da Figura 3, este processo busca criar um consenso de ponta a ponta, ou seja, desde a área de operações até a alta gestão da empresa, criando um time de trabalho com representantes de cada uma dessas áreas de forma a fornecer um único sinal de demanda (WALLACE, 2004; MENTZER; MOON, 2005).

Figura 3: S&OP Junction Box

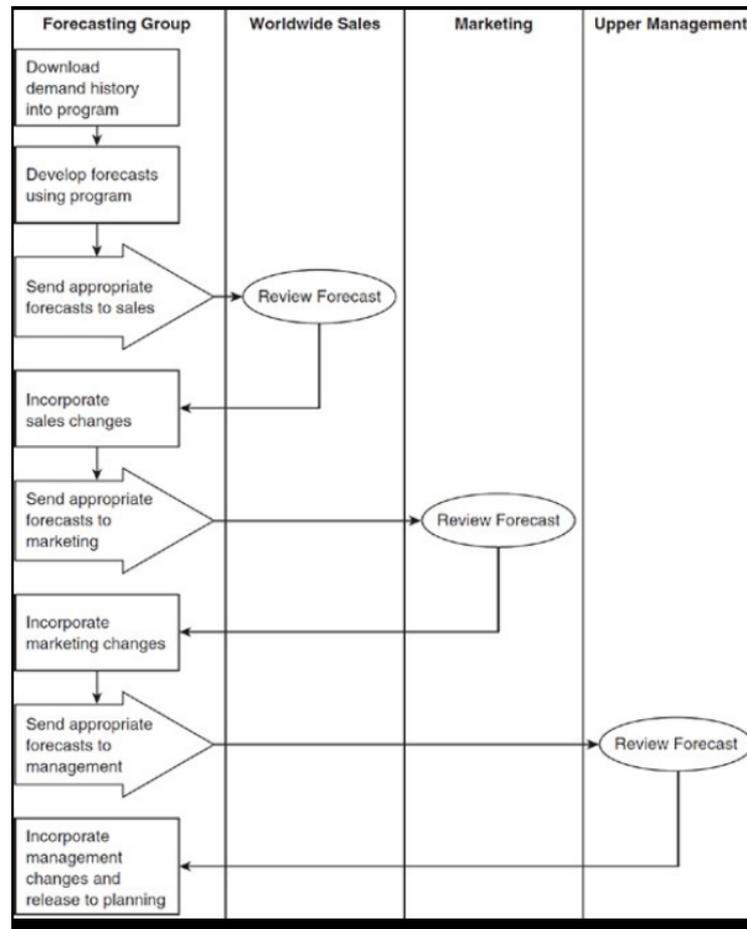


Fonte: Mentzer e Moon (2005) adaptada pelo autor

Dentre os benefícios esperados deste processo pode-se citar: i) Para empresas *Make-to-Stock*: um melhor nível de atendimento (satisfação) dos clientes e um menor nível de inventário; ii) Para empresas *Make-to-Order*: um melhor nível de atendimento (satisfação) dos clientes e menores prazos de entregas para os clientes; iii) otimização da capacidade de fábrica evitando capacidade ociosa ou horas extras; iv) melhoria no trabalho em equipe em todas as áreas, incluindo o grupo executivo; e v) criação de um senso de responsabilidade entre todas as áreas no processo de construção do plano de demanda e acompanhamento de desvios versus a performance efetiva de vendas (WALLACE, 2004; MENTZER; MOON, 2005).

O processo de previsão de demanda tem um papel muito importante neste contexto. Como exposto na Figura 4, o processo de S&OP tem na sua essência a utilização de dados históricos para elaboração de um plano de previsão de demanda através de modelos matemáticos, iniciando na área de *Planning*. A partir daí, realiza-se uma série de interações com as mais diversas áreas da empresa (Sales, Marketing e Upper Management) a fim de que o plano de demanda gerado pelos modelos matemáticos seja ponderado de acordo com a opinião de especialistas e as tendências de mercado (fatores externos), até que se obtenha um plano consensual que será utilizado como guia para dimensionar a capacidade de produção, necessidade de compra de matérias primas, contratação de mão de obra, etc. (DA SILVA; PEDROSO, 2015; JOSÉ FILHO, 1999).

Figura 4: Exemplos de Processos de Forecasting de Vendas



Fonte: Mentzer and Moon (2005)

No Brasil, ainda existem oportunidades para a realização de mais estudos sobre o processo de S&OP. Embora o processo de S&OP tenha suas complexidades, dado o dinamismo das relações no mercado atual, é inevitável sua implementação pelas empresas, visando uma maior competitividade (DA SILVA; PEDROSO, 2015; JOSÉ FILHO, 1999).

2.8. SISTEMÁTICAS DE AGREGAÇÃO/DESAGREGAÇÃO DE DADOS HISTÓRICOS DE DEMANDA

Cada vez mais tem se dado importância para ferramentas que permitam a geração de uma previsão de demanda rápida e com menor erro. Um dos métodos utilizados para agilizar a previsão de demanda consiste na agregação de dados históricos para a realização da previsão de demanda agregada. A sistemática de agregação dos dados históricos tem como objetivo reduzir a dispersão das informações, facilitando a aderência dos modelos aos dados. Estando os dados agregados, os modelos de previsão de demanda conseguem captar com mais facilidade o

comportamento das variáveis com relação à sazonalidade e linhas de tendência, entre outros pontos (KOURENTZES; ROSTAMI-TABAR; BARROW, 2017; ROSTAMI-TABAR; BABAI; ALI; BOYLA, 2019).

O estudo de séries temporais possibilita uma flexibilidade relacionada à unidade temporal com a qual se deseja trabalhar durante a construção dos modelos de previsão de demanda. Desta forma, pode-se transformar uma série de dados diários em uma base semanal para que seja realizada a previsão para cenários futuros (TIAO, 1972). Esta agregação de dados visa melhorar a aderência do modelo aos dados. A equação (17) abaixo, retrata uma série temporal hipotética escrita em função de possíveis desagregações.

$$X_T = \sum_{t=m(T-1)+1}^{mT} \frac{x_t}{m} = \frac{(1 + B + \dots + B^{m-1})x_{mT}}{m} \quad (17)$$

Sendo X_T uma série temporal agregada, representada pelo somatório das m agregações de x_t . 't' simboliza a unidade de tempo de dia e o termo 'm' representa a quantidade de observações agregadas. Em um exemplo onde deseja realizar uma agregação na base semanal, 'm' assumiria o valor de 7. Segundo Wei (2005), uma série temporal agregada pode ser formulada através da média aritmética de séries temporais de maior frequência.

Considerando-se que X_T é uma série temporal de menor frequência, por ser uma agregação da série x_t de maior frequência, a previsão para as próximas observações da série agregada pode se basear em duas abordagens: a) aplicação das previsões utilizando as observações de x_t e posterior agregação dos valores; e b) previsão direta utilizando os dados já agregados (TIAO, 1972).

É importante que ambas as abordagens sejam realizadas para que se verifique qual apresenta maior eficiência, uma vez que a agregação temporal normalmente aumenta a variabilidade de baixa frequência em séries temporais (NELSON e PLOSSER, 1982). Tiao (1972) mostra que a previsão para séries estacionárias valendo-se de dados agregados deve apresentar maior precisão quanto maior for o valor de 'm'. Vale salientar que um banco de dados que corresponde a um ano de coleta contém 365 observações considerando a unidade de tempo em dia, 52 observações em semanas e 12 observações quando o horizonte utilizado é mensal.

Depois de realizada a previsão de demanda na base agregada, faz-se necessário desagregar as previsões, desdobrando-as nas séries individuais (ou produtos) originais. A realização desta desagregação deve ocorrer de forma estruturada e através do estabelecimento de um índice de desagregação, ou seja, um critério para que novamente se possa retornar a demanda ao seu nível mais básico (séries individuais originais). Normalmente, o índice de desagregação é estruturado utilizando como base o comportamento, ou a distribuição, que os dados tinham na sua origem (base original), antes de serem agregados. Por exemplo, para realizar a desagregação da demanda de dados preditos pelos modelos matemáticos, pode-se se valer da distribuição dos dados históricos de demanda ao longo do tempo da seguinte forma:

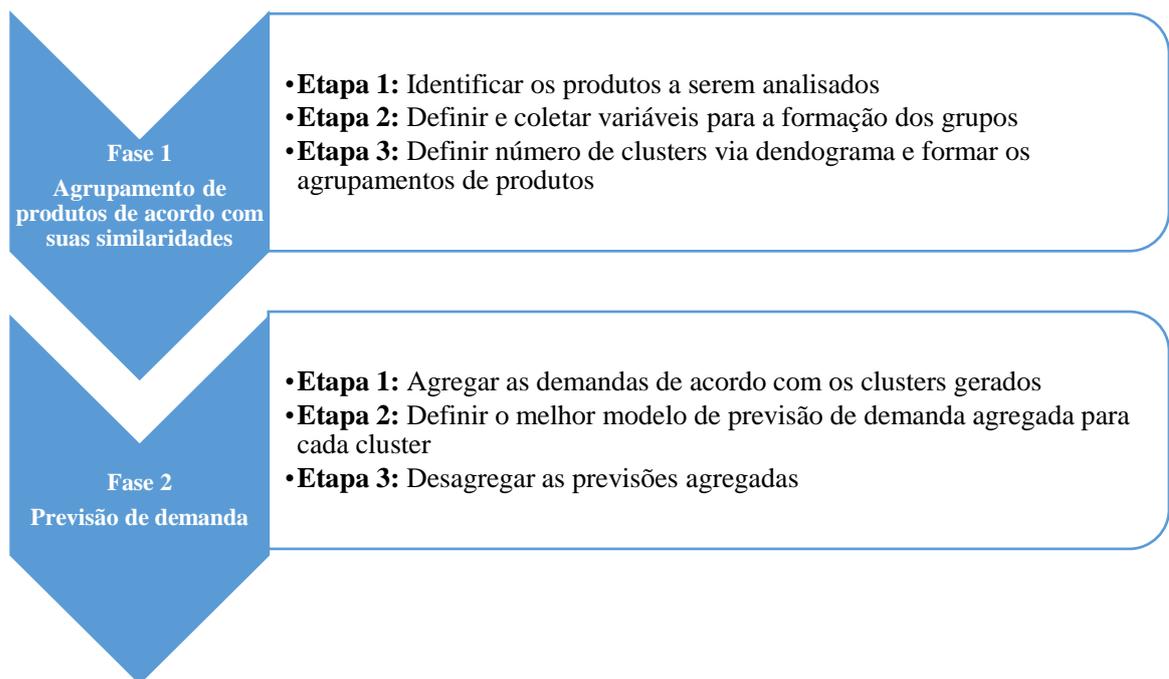
- Etapa 1: obtendo a distribuição percentual da demanda das pizzas para cada um dos períodos (dividindo a demanda original de cada pizza pelo volume total do período analisado);
- Etapa 2: multiplicando a distribuição percentual da demanda das pizzas encontrada na primeira etapa, pela demanda agregada predita para os clusters através dos modelos matemáticos para o período analisado.

3. MÉTODO

Nesta seção serão detalhadas as etapas operacionais em que se apoia o método proposto, o qual será constituído de 2 fases. Na primeira fase, são gerados agrupamentos (clusters) de produtos de acordo com suas similaridades em termos do comportamento das suas demandas. Na segunda fase, os produtos inseridos em cada cluster têm suas demandas agregadas e modeladas através de técnicas quantitativas de previsão; os valores preditos são então desagregados para gerarem previsões individuais para os produtos.

O método proposto contempla um total de 6 etapas que serão explicadas detalhadamente no decorrer deste capítulo, sendo 3 etapas associadas à primeira fase e 3 à segunda fase, conforme exposto na Figura 5.

Figura 5: Etapas propostas para previsão de demanda utilizando ferramentas de clusterização



Fonte: Elaborado pelo Autor

3.1. FASE 1 – AGRUPAMENTO DOS PRODUTOS DE ACORDO COM SUAS SIMILARIDADES

A primeira fase deste estudo consiste na clusterização dos produtos de acordo com suas similaridades. A clusterização permite reduzir o número de produtos a serem analisados,

simplificando a geração de modelos de previsão de demanda (uma vez que a modelagem passa a ser feita para um grupo de produtos e não para cada produto de forma individual). A consistência dos agrupamentos gerados pela clusterização é avaliada qualitativamente por especialistas de processo. A seguir serão detalhadas as etapas desta fase.

3.1.1. Etapa 1: Identificar os produtos a serem analisados

A primeira etapa desta fase é a identificação dos produtos a serem considerados na análise. Os produtos são escolhidos levando-se em conta sua representatividade em termos de volume de vendas, retorno financeiro e contribuição estratégica para o negócio (por exemplo, inclusão na análise de produto que os concorrentes não possuam ou que são utilizados como base de comparação entre as empresas no mercado). A identificação dos produtos mais representativos vale-se ainda da opinião de especialistas de processo.

Concluída a definição dos produtos, é importante entender em qual etapa do ciclo de vida está cada um dos produtos, a fim de que seja possível realizar eliminações (produtos em final de vida ou com baixa aceitação), bem como estabelecer associações entre produtos (junção de produtos que, por ventura, tenham apenas mudado de nome) para a obtenção de uma base de dados confiável, facilitando também a geração dos modelos de previsão de demanda nas etapas posteriores.

3.1.2. Etapa 2: Definir e coletar variáveis para a formação dos grupos

Definidos os produtos a serem analisados, é preciso identificar variáveis que sejam relevantes para o agrupamento dos produtos em famílias. É importante também realizar a padronização das unidades de medidas atreladas aos produtos para facilitar o exercício futuro de previsão de demanda, de forma que seja possível fazer uma comparação rápida e eficaz entre os produtos (ex.: homogeneizar tamanhos de produtos). Operacionalmente, além da representatividade das variáveis para a análise e sua contribuição para a formação dos agrupamentos, é fundamental a utilização da opinião de especialistas, de forma a validar se as variáveis escolhidas realmente são relevantes para o agrupamento dos produtos de acordo com suas similaridades. Exemplos de variáveis passíveis de utilização para a realização do agrupamento dos produtos em clusters incluem demanda, preço, custo, margem, entre outras. O agrupamento de produtos apoiados em perfis semelhantes está alinhado com o propósito de se gerar um modelo agregado de previsão

de demanda, ou seja, produtos que pertencem ao mesmo grupo têm perfis similares de demanda, logo podem ser descritos pelo mesmo modelo de previsão.

Para a definição das variáveis, recomenda-se a análise de uma base de dados históricos de pelo menos três anos, de forma a assegurar a robustez dos dados.

3.1.3. Etapa 3: Definir número de clusters via dendrograma e formar os agrupamentos de produtos

Escolhidas as variáveis a serem utilizadas na formação de grupos de produtos, a definição do número de clusters se dá através da avaliação de dendrogramas. A análise visual do dendrograma, cuja representação teórica foi representada na seção 2.2.1, possibilita identificar um intervalo apropriado de número de clusters (k) que geram uma satisfatória separação dos produtos em famílias. O número de clusters definido é então utilizado para efetiva formação dos agrupamentos via análise não-hierárquica (através do método K-Means). A validação do melhor número de clusters a ser considerado apoia-se: (i) na avaliação do Silhouette Index, cujos valores próximos a 1 sugerem a formação de grupos robustos de produtos, e (ii) na opinião de especialistas de processo, os quais podem apontar que a formação de determinado número de clusters facilita decisões gerenciais. O Silhouette Index, que avalia a consistência dos agrupamentos gerados, pode variar entre -1 e 1. Quanto maior o Silhouette Index, maior será a similaridade entre os dados. O Silhouette Index permite ainda determinar se há algum benefício em adicionar/remover variáveis na geração das famílias de produtos.

A efetiva inserção dos produtos em agrupamentos se dá através da técnica não-hierárquica K-Means, a qual insere cada produto em seu cluster de destino com base na distância Euclidiana. Espera-se que, ao final deste processo, produtos com perfis semelhantes de demanda façam parte de um mesmo agrupamento, facilitando o tratamento de seus dados históricos de demanda na Fase 2 do método proposto (explicada a seguir).

3.2. FASE 2 - PREVISÃO DE DEMANDA

A segunda fase deste trabalho tem como intuito realizar a previsão de demanda para os produtos inseridos em cada um dos clusters gerados pela fase anterior. Através de uma análise sobre o comportamento da demanda de cada cluster, são definidos os modelos matemáticos a serem utilizados para a previsão de demanda, bem como identificada a melhor unidade de tempo para

modelagem (por exemplo, dados históricos na base diária ou semanal). A avaliação dos melhores modelos e unidades de tempo a serem consideradas é balizada pelo MAPE (*mean absolute percentage error*) que determina o erro percentual entre os valores reais e os preditos para cada modelo. Na sequência serão detalhadas as etapas desta fase.

3.2.1. Etapa 1: Agregação das demandas de acordo com os clusters gerados na fase anterior

Cada cluster é constituído de uma série de produtos agrupados por similaridades em termos dos seus padrões de demanda. Para tanto, em cada cluster, somam-se as demandas verificadas para cada produto em cada instante de tempo avaliado (por exemplo, se uma base mensal é considerada, as demandas de janeiro de todos os produtos para o primeiro ano analisado são somadas e assim sucessivamente para todos os meses e anos avaliados). Este procedimento de agregação das demandas cumpre dois propósitos: (i) simplificar e agilizar a análise dos dados, fazendo com que um único modelo de previsão seja gerado para cada cluster; e (ii) potencialmente melhorar a aderência dos modelos de previsão aos dados históricos de demanda, visto que a agregação tende a reduzir a dispersão da série resultante frente às séries individuais dos produtos. A agregação é operacionalizada conforme descrito na seção 2.7.

3.2.2. Etapa 2: Definir o melhor modelo de previsão de demanda agregada para cada cluster

De acordo com Montgomery, Johnson e Gardiner (1990), para definir o melhor modelo de previsão de demanda para cada cluster, realiza-se um procedimento de partição da porção treino/teste para os dados agregados de cada cluster. Para tanto, os dados históricos agregados de demanda são separados em duas porções: treino (representando 75% dos dados) e teste (representando 25% dos dados), sendo a porção teste composta pelos dados mais recentes da série. A porção de treino é utilizada para construção do modelo de previsão, o qual deve levar em consideração elementos de sazonalidade e tendência da série. O modelo obtido é utilizado para predição de valores reais de demanda pertencentes à porção de teste, os quais não foram considerados durante a geração do modelo. A qualidade da predição é avaliada através do Mean Absolute Percentage Error (MAPE); valores reduzidos de MAPE são desejados, visto que denotam predições mais precisas pelos modelos gerados.

3.2.3. Etapa 3: Desagregação das previsões agregadas na etapa 2

Realizadas as previsões agregadas pelo melhor modelo (conforme passo acima), passa-se à desagregação da demanda para o nível de produto através de um índice de desagregação. O índice de desagregação apoia-se nos seguintes procedimentos: para cada cluster, avalia-se a participação percentual em volume (número de unidades) de cada produto ao longo do horizonte de tempo analisado. Na sequência, o percentual de cada produto é utilizado para desdobrar a demanda prevista de forma agregada (por exemplo, se um produto A tem a participação de 15% nos dados históricos considerados e a previsão agregada para dado instante foi de 1.000 unidades, a previsão de demanda para o produto A é de 150 unidades). Vale salientar que este índice deve ser validado por especialistas, de forma a verificar se o racional estabelecido está correto, tendo como intuito evitar inconsistências ao desmembrar a demanda agregada.

Na sequência, é importante avaliar o incremento (ou eventuais decréscimos) de acurácia na previsão de demanda ao se realizar a agregação e posterior desagregação dos dados. Duas formas de validação são executadas. Primeiramente, compara-se o erro absoluto de previsões isoladas versus o erro absoluto da previsão agregada seguindo os seguintes passos: (i) dentro de cada cluster são identificados os produtos mais representativos e é feita a partição de seus dados originais de demanda, de forma a obter-se a porção de treino e de teste destes produtos; (ii) com base na porção de treino encontrada, realiza-se a previsão de demanda isolada dos produtos, utilizando-se os melhores modelos matemáticos definidos para os seus clusters originais; e (iii) os resultados preditos são comparados às demandas originais destes mesmos produtos para o horizonte de tempo analisado, de forma a se obter o MAPE médio das previsões isoladas. O objetivo desta primeira análise é evidenciar que o erro absoluto das previsões isoladas é superior ao gerado pelas previsões das famílias de produtos, visto que, ao agregar a demanda dos produtos, se reduz as dispersões entre os dados e, conseqüentemente, a tendência é que se obtenha um menor erro absoluto.

Uma segunda análise de validação se baseia na comparação entre o MAPE médio da demanda isolada dos principais produtos selecionados dentro dos clusters versus o MAPE médio destes mesmos produtos obtidos através da desagregação da demanda dos clusters em que estavam inseridos através do índice de desagregação. O principal objetivo desta etapa é verificar se houve perda de acurácia em decorrência da desagregação da demanda de cada cluster, quando trazida novamente para o nível de produto isolado.

4. ESTUDO DE CASO

4.1. FASE 1 - AGRUPAMENTO DAS PIZZAS DE ACORDO COM SUAS SIMILARIDADES

O estudo de caso deste trabalho foi realizado no setor alimentício, mais especificamente em uma pizzaria do ABC Paulista com foco nas classes A e B, tendo como objetivo a proposição de um modelo de previsão de demanda baseado em técnicas de agrupamento.

A primeira etapa desta fase baseou-se na clusterização das pizzas de acordo com suas similaridades em termos de comportamento de demanda. Para tanto, foram selecionados 91 sabores de pizzas que fizeram parte do cardápio da pizzaria no período de 2015 a 2017. Para realizar esta seleção, avaliou-se a etapa do ciclo de vida de cada sabor de pizza, a fim de realizar exclusões (para o caso de pizzas com baixa representatividade de vendas) ou fazer associações entre pizzas que ao longo deste período mudaram de nome ou foram substituídas (mas que são idênticas). Ao final de tal análise, foram mantidos 76 sabores de pizzas para fins deste estudo.

Na sequência, converteram-se os dados de demanda referentes aos 3 tamanhos de pizzas disponíveis (pequena ou 4 pedaços; média ou 6 pedaços; e grande ou 8 pedaços) para tamanho grande. Esta conversão foi realizada da seguinte forma: multiplicou-se o número de pedaços da pizza escolhida pela quantidade solicitada através do pedido feito pelos clientes e, na sequência, dividiu-se este resultado por 8 (número de pedaços de uma pizza grande). Tal conversão visa normalizar a demanda em um único tamanho de pizza, facilitando comparações e a própria modelagem de previsão de demanda.

A segunda etapa da primeira fase consistiu na identificação de variáveis para o agrupamento das pizzas, de forma a identificar características similares entre elas. Com o suporte do gerente da pizzaria, foram selecionadas as seguintes variáveis: i) demanda de cada sabor de pizza entre 2015 a 2017 (nas bases semanal, quinzenal e mensal), bem como preço, custo e margem (média anual entre o período de 2015 a 2017).

Na sequência, utilizou-se o software Matlab para definir o número de clusters e a quantidade de variáveis a serem consideradas neste estudo de caso, valendo-se tanto da observação gráfica dos dendrogramas, quanto dos resultados do Silhouette Index, conforme mostrado na Tabela 2. Este exercício foi realizado considerando os dados históricos de vendas de pizzas nas bases mensal, quinzenal e semanal, de forma a verificar também em qual base temporal seria obtido o melhor Silhouette Index (a fim de se identificar a melhor forma para o agrupamento de dados e, conseqüentemente, a melhor base para a previsão de demanda futura).

Base	Número de Variáveis	Variáveis utilizadas	Número de Clusters			
			2	3	4	5
Mensal	1	Demanda	0,9414	0,8343	0,6663	0,6125
	2	Demanda + Preço	0,9413	0,8330	0,6619	0,6003
	3	Demanda + Preço + Custo	0,9412	0,8318	0,6584	0,5906
	4	Demanda + Preço + Custo + Margem	0,9411	0,8315	0,6571	0,5961
Quinzenal	1	Demanda	0,9399	0,8224	0,6356	0,5776
	2	Demanda + Preço	0,9396	0,8196	0,6272	0,5578
	3	Demanda + Preço + Custo	0,9393	0,8172	0,6205	0,5426
	4	Demanda + Preço + Custo + Margem	0,9393	0,8164	0,6180	0,5377
Semanal	1	Demanda	0,9370	0,8016	0,5917	0,5087
	2	Demanda + Preço	0,9364	0,7964	0,5778	0,4805
	3	Demanda + Preço + Custo	0,9359	0,7919	0,5668	0,4602
	4	Demanda + Preço + Custo + Margem	0,9358	0,7905	0,5628	0,4534

Tabela 2: Silhouette Index Médio para cada unidade temporal e variáveis utilizadas na clusterização

Os resultados da Tabela 2 conduziram às seguintes observações: i) a partir de quatro clusters, os valores de Silhouette Index não se mostraram interessantes, tendo como seu valor máximo 0,67 na previsão mensal (SI 0,28 menor quando comparado ao maior valor obtido para 2 clusters e 0,17 menor quando comparado ao maior valor obtido para 3 clusters); ii) o maior Silhouette Index foi encontrado utilizando apenas a variável demanda em todas as bases de previsão, sugerindo que variáveis de cunho financeiro não contribuem na formação de agrupamentos nítidos; iii) a utilização de 2 clusters (SI médio = ~0,94) ou 3 clusters (SI médio = ~0,82) com uma variável (demanda) se mostraram as alternativas mais interessantes; iv) considerando-se uma variável (demanda) e 2 ou 3 clusters, as variações entre as bases de previsão semanal, quinzenal e mensal não foram significativas; v) se utilizados 2 clusters, a distribuição das pizzas se daria da seguinte forma: Cluster 1 - pizzas *top sellers* (Calabresa, Portuguesa, Marguerita e Mussarela); e Cluster 2 - demais pizzas; vi) se utilizados 3 clusters, a distribuição das pizzas se daria da seguinte forma: Cluster 1 – pizzas com vendas intermediárias; Cluster 2 - pizzas *top sellers* (Calabresa, Portuguesa, Marguerita e Mussarela); e Cluster 3 - pizzas com vendas baixas.

Tais alternativas foram levadas para a validação de especialistas. Segundo o gerente da pizzaria, os agrupamentos de pizzas gerados estavam coerentes e foi sugerido que se trabalhasse com três clusters, pois este agrupamento está mais alinhado com a realidade de operação da pizzaria, a qual considera os seguintes grupos de pizzas: a) pizzas *top sellers*, b) pizzas com vendas intermediárias, e c) pizzas com vendas baixas.

4.2. FASE 2 – PREVISÃO DE DEMANDA DAS PIZZAS

A segunda fase deste estudo de caso teve como intuito a elaboração da previsão de demanda para os clusters estabelecidos na Fase 1. Valendo-se do comportamento das variáveis escolhidas na segunda etapa da primeira fase desta seção, foram definidos os melhores modelos matemáticos e a base temporal mais adequada para a geração dos modelos de previsão. Estas escolhas apoiaram-se no MAPE (*Mean Absolute Percentage Error*) da porção de teste, que determina o erro percentual referente à previsão de demanda para cada tipo de modelo.

A primeira etapa da segunda fase consistiu na agregação da demanda dos clusters de pizzas para a realização da previsão de demanda consolidada. Então, respeitando os períodos de tempo escolhidos (semanal, quinzenal ou mensal), foi realizado o somatório das demandas das pizzas contidas nos clusters 1 e 3 (separadamente para cada cluster), de forma a simplificar e agilizar a análise dos dados. Referente ao cluster 2, dada a representatividade da demanda das pizzas que o compõe, preferiu-se realizar a previsão de demanda isolada para cada um dos sabores pertencentes a este cluster. Desta forma, foram definidas 6 bases de dados, divididas em três clusters, para a modelagem de previsão de demanda, sendo elas: Cluster 1 → 1ª base de dados) composto pelo somatório das demandas de pizzas com vendas intermediárias; Cluster 2 → 2ª base de dados) demanda de pizza mussarela, 3ª base de dados) demanda de pizza marguerita, 4ª base de dados) demanda de pizza calabresa e 5ª base de dados) demanda de pizza portuguesa; Cluster 3 → 6ª base de dados) composto pelo somatório das demandas de pizzas com baixas vendas.

Na sequência, como segunda etapa da segunda fase, para cada um dos períodos de tempo (semanal, quinzenal ou mensal) foi realizada a partição da porção treino/teste da demanda das 6 bases de dados definidas no passo anterior desta fase. Estes dados foram distribuídos em duas porções: treino (representando 75% dos dados) e teste (representando 25% dos dados). Abaixo seguem detalhes da distribuição da partição da porção treino/teste para cada um dos períodos de tempo (considerando vendas do período de 2015 a 2017):

Distribuição da Partição Treino/Teste	Total de Períodos	Porção Treino	Porção Teste
Base Semanal	157 semanas	118 semanas	39 semanas
Base Quinzenal	78 quinzenas	59 quinzenas	19 quinzenas
Base Mensal	36 meses	27 meses	9 meses

Tabela 3: Distribuição da partição da porção treino/teste para os períodos de tempo

A modelagem de previsão de demanda para as bases acima foi realizada através do software estatístico NCSS valendo-se dos seguintes modelos de previsão de demanda: Holt's linear, LS Linear Trend, Double Exp Smooth e Arima. Escolhidos os modelos a serem utilizados, foram inseridos no NCSS os dados da porção treino de cada uma das 6 bases de dados definidas na primeira etapa desta fase, sinalizando quantos períodos futuros seriam preditos (39 períodos futuros para a base semanal, 19 períodos para a base quinzenal e 9 períodos para a base mensal).

Os resultados pelo NCSS foram comparados como os dados originais (porção teste) de cada uma das 6 bases de dados a fim de obter-se o MAPE. Esta comparação foi feita como segue: diferença entre o valor absoluto entre os dados originais apresentados pela porção teste das 6 bases de dados definidas na primeira etapa e os dados preditos pelos modelos de previsão de demanda, dividindo-os pelos dados originais apresentados pela porção teste das 6 bases de dados definidas na primeira etapa em um determinado período. Após obter o MAPE de cada período da porção teste, foi calculada a média destes valores, tendo como objetivo encontrar o erro percentual médio da previsão de demanda realizada pelos modelos matemáticos. Na Tabela 4 seguem os resultados obtidos, sendo destacados os melhores modelos e base temporal onde se observou o menor MAPE. Pode-se observar que os melhores MAPEs médios de cada cluster foram encontrados na base quinzenal, ficando entre 6,23% e 9,28%.

Clusters	Modelos de Previsão de Demanda	Semanal	Quinzenal	Mensal	Média
Cluster 1	Holt's Linear	13,49%	8,04%	11,46%	11,00%
	LS Linear Trend	8,79%	7,89%	10,72%	9,13%
	Double Exp Smooth	7,41%	6,23%	12,16%	8,60%
	Arima	12,58%	11,36%	15,02%	12,99%
	Média	10,57%	8,38%	12,34%	
Cluster 2 - Calabresa	Holt's Linear	13,22%	7,99%	16,76%	12,66%
	LS Linear Trend	12,38%	9,74%	11,89%	11,34%
	Double Exp Smooth	12,25%	8,36%	11,97%	10,86%
	Arima	13,41%	13,11%	17,74%	14,75%
	Média	12,82%	9,80%	14,59%	
Cluster 2 - Marguerita	Holt's Linear	33,15%	13,73%	56,09%	34,32%
	LS Linear Trend	68,07%	64,09%	65,75%	65,97%
	Double Exp Smooth	72,43%	61,39%	43,27%	59,03%
	Arima	14,69%	9,28%	17,40%	13,79%
	Média	47,09%	37,12%	45,63%	
Cluster 2 - Mussarela	Holt's Linear	12,40%	9,18%	11,72%	11,10%
	LS Linear Trend	14,40%	12,33%	13,42%	13,38%
	Double Exp Smooth	13,73%	12,23%	16,11%	14,02%
	Arima	17,56%	16,57%	15,49%	16,54%
	Média	14,52%	12,58%	14,18%	
Cluster 2 - Portuguesa	Holt's Linear	11,82%	8,11%	14,71%	11,55%
	LS Linear Trend	11,99%	10,35%	12,01%	11,45%
	Double Exp Smooth	10,12%	7,08%	10,93%	9,38%
	Arima	14,15%	13,71%	18,32%	15,39%
	Média	12,02%	9,81%	13,99%	
Cluster 3	Holt's Linear	8,19%	7,13%	12,73%	9,35%
	LS Linear Trend	8,15%	6,77%	10,41%	8,44%
	Double Exp Smooth	8,13%	6,94%	10,12%	8,40%
	Arima	10,02%	7,59%	11,86%	9,82%
	Média	8,62%	7,11%	11,28%	
Melhores resultados					

Tabela 4: MAPE médio segundo modelos de previsão de demanda e bases temporais avaliadas

Na sequência, como parte da terceira etapa desta fase, foi realizada a desagregação da demanda dos clusters para o nível de pizzas (especificamente dos clusters 1 e 3, uma vez que, a demanda do cluster 2 já se encontrava desagregada), utilizando um índice de desagregação. Para estruturar este índice de desagregação, foi observado o comportamento da demanda das pizzas entre 2015 e 2017, tendo como base o período de tempo onde se obteve o menor MAPE (período quinzenal). Para estruturar o índice de desagregação, procedeu-se da seguinte forma: i) para cada cluster, avaliou-se a participação percentual em volume (número de unidades vendidas) de cada pizza ao longo do horizonte de tempo analisado; e ii) o percentual de cada pizza foi utilizado para desdobrar a demanda predita na forma agregada (através da multiplicação entre a participação percentual de uma determinada pizza em um determinado instante e a previsão

de demanda agregada obtida através do melhor modelo matemático no mesmo instante de tempo).

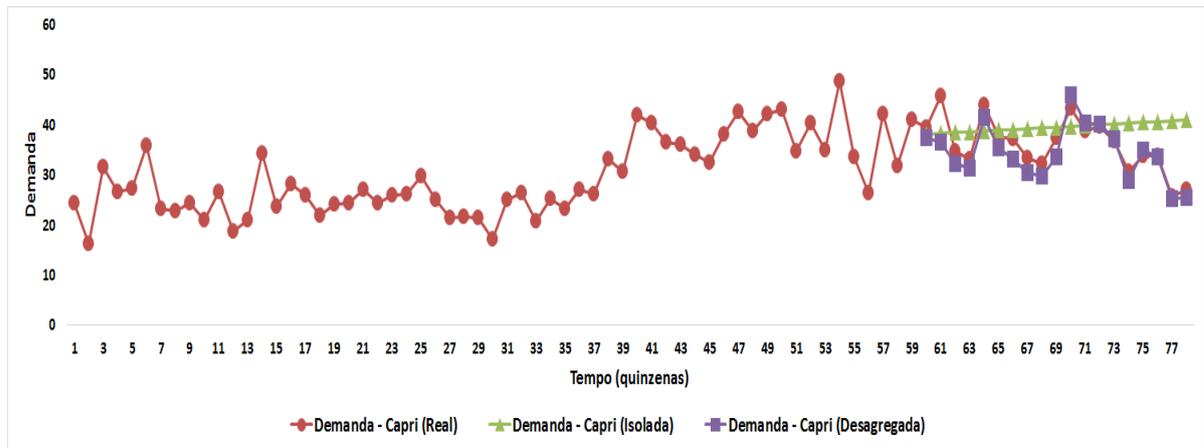
Realizada a desagregação da demanda, foi necessário validar a precisão da previsão pós desagregação para cada pizza individualmente. Para tanto, comparou-se o erro absoluto de previsões individuais das pizzas versus o erro absoluto obtido após a desagregação da demanda dos clusters de pizzas, seguindo os passos: i) Dentro dos clusters que consolidaram a demanda de várias pizzas, foram identificadas as pizzas mais representativas e feita a partição de seus dados originais de demanda, de forma a obter-se a porção de treino e de teste destas pizzas; ii) Realizou-se a previsão de demanda individual das pizzas através do software NCSS na porção de treino, utilizando-se os melhores modelos matemáticos definidos para os seus clusters originais; iii) Os resultados preditos foram comparados às demandas originais dessas mesmas pizzas para o horizonte de tempo analisado, de forma a se obter o MAPE médio das previsões isoladas; iv) Na sequência, foi realizada a partição da porção treino/teste dos dados destas mesmas pizzas, porém, utilizando agora os dados obtidos através da desagregação da demanda dos clusters onde estas pizzas estavam inseridas, de forma a identificar MAPE médio da demanda desagregada.

O MAPE médio da previsão desagregada das pizzas foi então comparado com o MAPE médio da previsão isoladas das pizzas. Verificou-se que o erro absoluto das previsões isoladas das pizzas foi superior ao das previsões de demanda desagregadas, o que confirma que, ao agrupar os produtos, se reduz as dispersões dos dados e gera-se menor erro absoluto. Mesmo depois dos procedimentos de agregação e desagregação de demanda, o MAPE obtido pela desagregação foi melhor, conforme mostrado na Tabela 5. A Figuras 6 evidencia que a demanda predita através da desagregação apresenta comportamento mais próximo ao da demanda real das pizzas analisadas.

Clusters	Modelos de Previsão de Demanda (base quinzenal)	Previsão Isolada	Desagregação
Cluster 1 (pizza Capri)	Double Exp Smooth	16,54%	6,23%

Tabela 5: Comparação entre MAPE médio de previsões isoladas e desagregadas

Figura 6: Previsão de Demanda Quinzenal – Suavização Exponencial Dupla (Pizza Capri)



Fonte: Elaborado pelo Autor

5. POTENCIAIS IMPLICAÇÕES DO MÉTODO PROPOSTO

No segmento de pizzarias, onde se trabalha com uma grande quantidade de produtos perecíveis, ter a visibilidade adequada sobre a previsão de demanda contribui de forma significativa para a gestão eficiente do negócio. A seguir serão elencados os potenciais benefícios gerados por este estudo para uma Pizzaria do ABC paulista, fazendo uma comparação com as práticas de operação do segmento e da pizzaria em questão.

Primeiramente, é importante se ter a visão do Demonstrativo de Resultados da empresa, no intuito de mensurar os potenciais ganhos oriundos deste trabalho. Com isto, será possível avaliar mais facilmente os resultados esperados (e alguns já alcançados) através da aplicação das proposições desta dissertação na pizzaria.

Perdas médias	
- Pizzarias em geral	5% - 20%
- Villare	5% - 7%
Venda Média anual (unidades)	
	25.000
	P&L Atual
Receita Média Anual	R\$ 1.900.000,00
Custo Médio Anual do produto vendido	R\$ 983.300,00
- Matéria-Prima	R\$ 475.000,00
- Perdas de Matéria-Prima	R\$ 25.000,00
- Mão de Obra direta	R\$ 423.300,00
- Salários	R\$ 281.200,00
- Encargos, Férias, Transporte, Funcionários Extras (cobrir férias de funcionários e necessidades de demanda aos finais de semana e feriados)	R\$ 102.600,00
- Premiações	R\$ 35.000,00
- Hora-Extra	R\$ 4.500,00
- Outros Gastos de fabricação	R\$ 60.000,00
Margem Bruta Média Anual	R\$ 916.700,00
Gasto Médio Anual (outras despesas)	R\$ 410.700,00
- Salários / Pro-labore	R\$ 360.000,00
- Manutenções e Reformas	R\$ 21.000,00
- Gastos com Consultorias	R\$ 16.700,00
- Gastos com Capacitação de Pessoal	R\$ 10.000,00
- Gastos com Manutenção de Sistemas e Softwares	R\$ 3.000,00
Margem Líquida Média Anual	R\$ 506.000,00
Margem % Líquida sobre a Receita	27%

Tabela 6: Demonstrativo de resultado da Pizzaria abordada neste estudo - 2019

Com relação ao desperdício de matéria-prima neste setor, segundo a Associação das pizzarias do Estado de São Paulo (2018), estima-se que haja uma perda entre 5% e 20% levando-se em conta as pizzarias em geral, sendo que as perdas da pizzaria abordada neste estudo (ver Tabela 7) giram em torno de 5% a 7% (a perda no ano de 2019 foi de 5%). Na Tabela 6, percebe-se que as principais perdas de matérias-primas estão relacionadas a pizzas perdidas durante o processo (45%), perdas de massa tradicional (18,1%) e perdas de Mussarela (9,1%).

Perda Consolidada				
Produto	Perda Total ano (kg ou un)	Representatividade % perda por produto	Valor kg ou un (R\$)	Perda Total (R\$)
Pizzas perdidas durante processo	416,00	45,0%	R\$ 27,05	R\$ 11.252,80
Massa Tradicional	517,56	18,1%	R\$ 8,75	R\$ 4.528,62
Mussarela	109,50	9,1%	R\$ 20,70	R\$ 2.266,65
Massa Integral	97,55	4,9%	R\$ 12,50	R\$ 1.219,38
Lombo	46,96	4,4%	R\$ 23,50	R\$ 1.103,61
Calabresa	62,05	3,2%	R\$ 12,95	R\$ 803,55
Palmito	26,98	2,9%	R\$ 27,00	R\$ 728,35
Morango	46,15	2,2%	R\$ 12,00	R\$ 553,80
Tomate Fatiado, Salada, Salada pontas	187,51	2,1%	R\$ 2,80	R\$ 525,03
Tomate para Molho	181,62	1,6%	R\$ 2,20	R\$ 399,56
Rucula	14,28	1,4%	R\$ 25,20	R\$ 359,86
Cebola	160,32	1,3%	R\$ 2,00	R\$ 320,65
Embalagens	100,00	0,7%	R\$ 1,76	R\$ 176,00
Escarola	60,17	0,5%	R\$ 2,00	R\$ 120,34
Borda Cream Cheese	31,58	0,4%	R\$ 3,35	R\$ 105,79
Rucula Talos/pontas	28,38	0,3%	R\$ 3,00	R\$ 85,13
Alho Poró	80,82	0,3%	R\$ 1,00	R\$ 80,82
Berinjela	13,25	0,2%	R\$ 4,00	R\$ 53,00
Alface Americana	29,35	0,2%	R\$ 1,50	R\$ 44,03
Queijo Fresco	2,16	0,2%	R\$ 19,00	R\$ 41,04
Ovos	12,96	0,2%	R\$ 3,00	R\$ 38,87
Peito de Peru	1,43	0,2%	R\$ 27,00	R\$ 38,61
Cebola inteira	18,81	0,2%	R\$ 2,00	R\$ 37,63
Pimentão	5,15	0,1%	R\$ 7,00	R\$ 36,08
Manjericão	24,20	0,1%	R\$ 1,00	R\$ 24,20
Abobrinha	5,93	0,1%	R\$ 4,00	R\$ 23,73
Ovos cozido	3,62	0,0%	R\$ 3,00	R\$ 10,85
Tomate Cereja	1,35	0,0%	R\$ 6,00	R\$ 8,10
Banana	2,51	0,0%	R\$ 3,00	R\$ 7,53
Escarola Pontas	63,95	0,0%	R\$ 0,10	R\$ 6,40
Total		100%		R\$ 25.000,00

Tabela 7: Perdas por insumo da Pizzaria abordada neste estudo

A venda média anual da Pizzaria analisada nesta dissertação é de cerca de 25.000 pizzas, a um ticket médio aproximado de R\$ 63,33, o que gera uma receita média anual de R\$ 1.900.000,00. Nos últimos anos, embora a econômica brasileira tenha passado por períodos de crise, a receita da pizzaria tem crescido. Houve um aumento do consumo pela aquisição de novos clientes e também por parte de clientes já existentes. Tal aumento decorre da transferência dos gastos de

consumo em outros setores de alimentação, como restaurantes japoneses e churrascarias, tendo em vista que o gasto médio por pessoa ao se considerar pizza se torna mais atraente (mais baixo) frente aos outros mencionados. Nesta mesma linha, os repasses de preços decorrentes da inflação nestes últimos anos conseguiram ser realizados sem que houvesse prejuízo nas vendas da empresa.

Os custos médios anuais do produto vendido totalizam R\$ 983.300,00 tendo como seus principais formadores o custo de matéria-prima (R\$ 475.000,00 ou 48% do custo total) e mão de obra direta (R\$ 423.000,00 ou 43% do custo total), que representam conjuntamente 91% do custo médio do produto vendido. Segundo o proprietário da pizzaria, a sustentabilidade e o sucesso da operação da pizzaria são justificados pela qualidade dos produtos comprados e pela qualidade dos serviços prestados. Embora regularmente sejam realizados trabalhos com intuito de reduzir os custos de produção, há muito cuidado para que isto não impacte a qualidade do produto vendido (são utilizados sempre os melhores ingredientes) e do serviço prestado (valorização dos colaboradores, salários e bônus diferenciados, havendo um baixo índice de rotatividade de funcionários). De acordo com a Associação das pizzarias do Estado de São Paulo (2018), pizzarias do mesmo segmento optaram por ajustar seus custos adquirindo produtos mais baratos, tendo em média uma queda de suas vendas de 10% a 30%. Consequentemente, a rotatividade nestas pizzarias aumentou de 10% a 20%. Demais gastos para suportar a operação totalizam R\$ 410.700,00, contemplando pro-labore, gastos com reforços e manutenções, gastos com consultorias técnicas, capacitação de pessoal e manutenção de sistemas e softwares.

A margem líquida média anual da Pizzaria é de cerca de R\$506.000,00 (27% versus a receita da pizzaria). No geral, a margem média no setor gira em torno de 18%. Os diferenciais de margens da Pizzaria abordada neste trabalho frente à média da concorrência se devem aos seguintes fatores: i) preço de venda premium; ii) eficiência na utilização de mão de obra (otimizando as contratações); iii) baixo valor de aluguel do espaço ocupado pela pizzaria; e iv) gestão eficiente de custos diretos e indiretos de produção. A expectativa do proprietário é que atingir uma margem líquida de 30% nos próximos anos e, para isto, um trabalho de previsão de demanda mais estruturado terá um papel fundamental.

Na sequência, são confrontados “contextos atuais” versus “potenciais implicações gerenciais” em quatro frentes em função da aplicação da sistemática proposta para a previsão de demanda na Pizzaria analisada neste estudo de caso. Enfatiza-se que o impacto de diversas ações derivadas da aplicação da sistemática proposta será sentido ao longo de um horizonte mais

extenso da operação. De tal forma, utilizou-se a experiência do proprietário da pizzaria para estimativa dos potenciais ganhos decorrentes, conforme detalhado abaixo.

1. Observação da necessidade de reavaliação do portfólio de produtos na oferta e melhor planejamento de compra de matéria-prima:
 - a. Contexto atual: A pizzaria não utiliza sistemáticas estruturadas para geração de sua previsão de demanda. Com isto, as tentativas de reduções de perdas de matéria-prima se dão basicamente por dois fatores: a) experiência adquirida ao longo do tempo sobre a quantidade de matéria-prima necessária para suportar a demanda esperada; e b) utilização de câmaras frias para armazenar produtos perecíveis, em caso de compras maiores que o necessário. Grande parte das perdas, entre 3% a 4%, ocorre em produtos de hortifrúti (tomate, rúcula, morango, cebola, manjericão, entre outros). Mesmo com a experiência na seleção de bons produtos e trabalhando apenas com bons fornecedores, alguns fatores podem afetar estas perdas: a) o produto muitas vezes pode aparentar estar bom, mas na verdade não está; b) há diferença entre o prazo de validade versus durabilidade real dos produtos; c) necessidade de compras em lotes (volume / quantidade maior do que a necessária); e d) variações das perdas dado a época do ano (ex.: entre safras). Também se observa que um percentual das perdas, entre 1% a 2%, ocorre em pizzas que são lançamentos, pizzas com baixo volume de vendas, pizzas que atendem a nichos específicos e que apresentam itens que não são compartilhados (ou são pouco compartilhados) com as demais pizzas. Há também perdas oriundas de erros de produção, em torno de 1%, relacionadas a produtos perecíveis que por erro de planejamento (compra demasiada, acomodação/manuseio inadequado) acabam estragando. Atualmente, todo planejamento de compras de matéria-prima é feito tendo como base unicamente a experiência prática dos gestores. Estima-se que cerca de 1% a 10% das perdas das matérias-primas sejam oriundas de inconsistências entre as previsões de vendas feitas pelos gestores versus a demanda efetiva.
 - b. Potenciais implicações gerenciais deste estudo de caso: i) O estudo reforçou a necessidade da empresa realizar uma rigorosa avaliação para decidir entre manter um determinado produto na oferta versus aumentar a perda de matéria-prima, dada a incerteza de consumo. O estudo de previsão de demanda ajudará a empresa a otimizar suas compras, a fim de reduzir perdas geradas pelo excesso

de compras de matéria-prima e maior exposição dos mesmos ao manuseio inadequado. Tendo como base a Tabela 7, referente à incidência de perdas de matéria, considera-se que um ganho de acurácia na previsão de demanda gere uma redução de, pelo menos, 25% (R\$ 6.250,00) como evidenciado na Tabela 8 pelo item (1); e ii) Embora não seja objeto de estudo deste trabalho, o exercício de previsão de demanda contribuirá para a realização de um planejamento das necessidades de materiais mais acurado para a pizzaria. Uma consultoria já havia sido contratada para ajudar na elaboração de uma ficha técnica para utilização nas pizzas, visando minimizar desperdícios e garantir uma padronização das pizzas. Porém, a quantidade de cada insumo a ser adquirida ainda estava unicamente ao encargo dos gestores da pizzaria. Agora, com base no método proposto, é possível ter um embasamento quantitativo para a realização da compra de matéria-prima, uma vez que, através da previsão do número de pizzas que se estima vender e da utilização da ficha técnica, rapidamente é possível ter uma noção da quantidade demandada de cada insumo.

2. Otimização de contratação de mão de obra:

- a. Contexto atual: embora a pizzaria abordada neste estudo concentre sua operação na modalidade *delivery*, ainda assim há uma necessidade de mão de obra de motoboys, pizzaiolos, auxiliares de pizzaiolo e funcionários para atendimento de ligações e demanda eventual em mesas.
- b. Potenciais implicações gerenciais deste estudo de caso: São necessários 9 motoboys, 6 funcionários do setor de produção (pizzaiolo e ajudantes; sendo 1 utilizado apenas nos finais de semana) e 5 funcionários para atendimento (sendo 2 utilizados apenas nos finais de semana), totalizando 20 funcionários para a produção média anual de 25.000 pizzas. O método proposto permitirá aprimorar o processo de contratação da empresa (em média se leva 3 meses para se contratar/treinar funcionários), visando evitar perdas de vendas. Nesta mesma linha, é possível otimizar a contratação de mão de obra e utilização de horas extras para atendimento em datas específicas (Natal; período de férias escolares – vendas maiores durante semana; Black Friday; e feriados em geral), no intuito de evitar gastos desnecessários com pessoal. Entre salários, encargos e hora-extra, o proprietário da empresa estima redução de 5% ou R\$ 19.415,00,

conforme evidenciado na Tabela 8 item (2), contando com uma melhor gestão do processo de contratação de pessoal oriundo de uma melhor visibilidade sobre as expectativas de vendas.

3. Otimização do fluxo de demanda ao longo do dia:

- a. Contexto atual: atualmente a distribuição dos pedidos ao longo do dia ocorre da seguinte forma (no período das 18h às 23h): 18h-19h → 6% das vendas; 19h-20h → 40% das vendas; 20h-21h → 40% das vendas; 21h-22h → 10% das vendas; e 22h-23h → 4% das vendas. Estima-se que haja uma perda de, pelo menos, 3% das vendas diárias ou 2 pizzas por dia por limitações de capacidade produtiva decorrente da concentração do fluxo de demanda em alguns períodos específicos. Melhorar as vendas entre 18h-19h e 21h-22h é fundamental para que a empresa atinja seus objetivos de margem (embora seja difícil mudança de hábitos de consumo);
- b. Potenciais implicações gerenciais deste estudo de caso: i) também amparada pelos resultados do estudo, a empresa trocou seu software de controle de vendas visando ter um maior detalhamento sobre as mesmas, de forma a realizar campanhas estratégicas. Criar mecanismos para otimizar a demanda ao longo do período da operação (principalmente através de promoções em dias da semana específicos – ex.: quarta-feira → dia de futebol; e sexta-feira → dia em que as pessoas normalmente saem mais cedo do trabalho), será um dos focos da empresa visando ampliar sua receita. Com esta iniciativa, o proprietário da empresa estima um ganho de receita de R\$ 56.700,00 ou 895 pizzas (com base no ticket médio da pizzeria), como pode-se observar na Tabela 8 pelo item (3).

4. Melhor programação da necessidade de gastos operacionais:

- a. Contexto atual: atualmente o planejamento dos gastos da empresa se dá apenas pela expectativa dos empresários com relação ao futuro das vendas. As decisões de gastos sem um planejamento mais prévio são vistas como algo que necessita de uma mudança rápida. Estima-se que sejam gastos adicionalmente entre 5% a 15% por conta do tempo curto para tomada de decisão e da ausência de visibilidade quanto à necessidade real dos gastos ao longo do período.

- b. Potenciais implicações gerenciais deste estudo de caso: i) tendo um estudo sólido quantitativo sobre previsão de demanda, o proprietário poderá programar melhor seus gastos operacionais (realizando-os em módulos, por exemplo). Isto também trará uma melhora no fluxo de caixa da empresa, uma vez que se buscará mais eficiência na realização dos gastos de acordo com a real necessidade da empresa. Espera-se reduzir em pelo menos 10% (R\$ 2.100,00) os gastos destinados a manutenções e reformas destacados na Tabela 8 item (4).

	P&L Atual	Ganhos esperados c/ previsão de demanda	P&L Projetado	Item
Receita Média Anual	R\$ 1.900.000,00	R\$ 56.700,00	R\$ 1.956.700,00	(3) ✓
Custo Médio Anual do produto vendido	R\$ 983.300,00	R\$ 25.665,00	R\$ 957.635,00	
- Matéria-Prima	R\$ 475.000,00		R\$ 475.000,00	
- Perdas de Matéria-Prima	R\$ 25.000,00	R\$ 6.250,00	R\$ 18.750,00	(1) ✓
- Mão de Obra direta	R\$ 423.300,00	R\$ 19.415,00	R\$ 403.885,00	(2) ✓
- Salários	R\$ 281.200,00	R\$ 14.060,00	R\$ 267.140,00	
- Encargos, Férias, Transporte, Funcionários Extras (cobrir férias de funcionários e necessidades de demanda aos finais de semana e feriados)	R\$ 102.600,00	R\$ 5.130,00	R\$ 97.470,00	
- Premiações	R\$ 35.000,00		R\$ 35.000,00	
- Hora-Extra	R\$ 4.500,00	R\$ 225,00	R\$ 4.275,00	
- Outros Gastos de fabricação	R\$ 60.000,00		R\$ 60.000,00	
Margem Bruta Média Anual	R\$ 916.700,00	R\$ 82.365,00	R\$ 999.065,00	
Gasto Médio Anual (outras despesas)	R\$ 410.700,00	R\$ 2.100,00	R\$ 408.600,00	
- Salários / Pro-labore	R\$ 360.000,00		R\$ 360.000,00	
- Manutenções e Reformas	R\$ 21.000,00	R\$ 2.100,00	R\$ 18.900,00	(4) ✓
- Gastos com Consultorias	R\$ 16.700,00		R\$ 16.700,00	
- Gastos com Capacitação de Pessoal	R\$ 10.000,00		R\$ 10.000,00	
- Gastos com Manutenção de Sistemas e Softwares	R\$ 3.000,00		R\$ 3.000,00	
Margem Líquida Média Anual	R\$ 506.000,00	R\$ 84.465,00	R\$ 590.465,00	
Margem % Líquida sobre a Receita	27%		30%	

Tabela 8: Evolução do Demonstrativo de Resultado Pizzaria abordada neste estudo, tendo como base os benefícios esperados com o exercício de previsão de demanda

Obtendo sucesso nestas 4 frentes, como nota-se na Tabela 8, a Pizzaria analisada nesta dissertação conseguirá alcançar uma margem percentual líquida sobre sua receita de 30%, o que permitirá a busca de outras metas previstas pelo seu proprietário para desenvolvimento do negócio, as quais incluem estruturar um modelo de franquia para a pizzaria; e abrir novas filias no ABC Paulista.

6. CONCLUSÕES

Esta dissertação teve como objetivo principal a utilização de métodos de clusterização para realizar o agrupamento de produtos por similaridades e, à partir daí, propor uma sistemática de previsão de demanda apoiada em técnicas de agregação e desagregação de dados. Seja no segmento industrial ou de serviços, a utilização de modelos de previsão de demanda tem sido fundamental para a identificação de possíveis ineficiências na cadeia de suprimentos.

Para apoiar a estruturação e propósito deste trabalho, foram utilizados dados fornecidos pela análise de conjuntura econômica do IPEA (2018) e Associação das pizzarias do Estado de São Paulo (2018), no intuito de contextualizar o cenário econômico para o período de análise, tendo como foco principal os reflexos no setor alimentício.

Com base em estudos de Rencher (2002) e Everitt et al. (2011), foram abordados métodos de clusterização a fim de realizar o agrupamento de dados, formando grupos cujas observações possuíssem características semelhantes, reduzindo assim o número de modelagens necessárias, visto que as previsões são feitas para grupos de produtos. Na sequência, através de trabalhos de vários autores, foram analisados métodos quantitativos e qualitativos de previsão de demanda, bem como as sistemáticas de agregação e desagregação de dados, tendo como intuito agilizar e aumentar a precisão da predição de demanda futura, reduzindo a dispersão de dados históricos e facilitando a captura do comportamento das variáveis por parte dos modelos de previsão de demanda.

Foi construído também um método contemplando as etapas utilizadas para o embasamento deste trabalho, as deixando de uma forma genérica e flexível, de modo que o texto pudesse ser adaptado a outros contextos. Já a aplicabilidade da metodologia foi verificada através de um estudo de caso em uma pizzaria do ABC Paulista e, sua aplicação em outros segmentos deve considerar as especificidades de cada setor.

A primeira fase do estudo de caso apresentado neste trabalho, consistiu no agrupamento das pizzas de acordo com suas similaridades, baseando-se no conceito de ciclo de vida produtos para realizar exclusões e associações (foram trabalhados com 76 sabores de pizzas). Neste momento realizou-se também a padronização do tamanho das pizzas (em pizzas grandes) facilitando comparações e a modelagem de previsão de demanda. Ainda nesta fase, utilizou-se o software estatístico Matlab para definir o número de clusters (sendo 3 no total) e seleção de variáveis que deveriam ser consideradas nesta análise (neste caso a demanda de cada sabor entre 2015 a 2017), valendo-se tanto da observação gráfica de dendrogramas, quanto dos

resultados obtidos através do Silhouette Index. Todos estes resultados foram validados por especialistas de processo com o intuito de garantir a coerência das informações. Já na segunda fase, valendo-se do MAPE da porção teste das previsões de demanda, foram selecionados os melhores modelos matemáticos e bases temporais para o exercício de previsão de demanda dos clusters de pizzas. Trabalhando com os modelos Holt's Linear, LS Linear Trend, Double Exponential Smoothing e Arima no software NCSS, observou-se que os melhores MAPES médios da previsão agregada dos clusters foram encontrados na base quinzenal (ficando entre 6,23% e 9,28%). Complementarmente, com a finalidade de validar a acurácia das previsões de demanda das pizzas, foi realizada a comparação entre o MAPE médio da demanda desagregada das pizzas e o MAPE médio da demanda isolada das pizzas. Verificou-se que o erro absoluto das previsões isoladas das pizzas foi superior ao das previsões de demanda desagregadas, evidenciando que o agrupamento das pizzas reduziu as dispersões dos dados e gerou um menor erro absoluto.

Tendo como base o atual demonstrativo de resultados da pizzaria, foram identificados os seguintes benefícios trazidos por este estudo de caso: i) necessidade de reavaliação do portfólio de produtos para um melhor planejamento de compra de matéria-prima, ii) a necessidade de otimização da contratação de mão de obra; iii) a importância da otimização do fluxo de demanda ao longo do dia; e iv) a melhor programação das necessidades de gastos operacionais.

Como outras possibilidades de aplicações deste trabalho em estudos futuros pode-se citar: i) utilização em outros segmentos, levando-se em conta as suas especificidades, uma vez que os exercícios de previsão de demanda são fundamentais para todos os tipos de empresas; ii) a utilização de técnicas alternativas de clusterização, como *Self Organized Maps*, com o intuito de aprimorar a formação dos agrupamentos de produtos com características similares; iii) utilização de outros tipos de desagregação de demanda, caso os resultados obtidos através da execução de um índice de desagregação simples não sejam satisfatórios; e iv) a extrapolação dos resultados obtidos neste estudo para trabalhos de *MRP (Material Requirements Planning)*, visando assegurar a disponibilidade de materiais no tempo e quantidade necessária, bem como a realização de uma gestão eficiente dos níveis de inventário e a discussão sobre outros pontos importantes como políticas de dimensão de lote, estoque de segurança e *lead time*.

REFERÊNCIAS

- ALTENDORFER, Klaus. **Capacity and Inventory Planning for Make-to-Order Production Systems: the impact of a customer required lead time distribution**. Switzerland: Springer International Publishing, 2014.
- ANZANELLO, M. J; FOGLIATTO, F. S.. Selecting best clustering variables for grouping mass-customized products involving workers learning. **International Journal of Production Economics**. 130 (2), 268-276, 2011.
- ARANGO, M. R.; UKKUSURI, S. V.; Demand clustering in freight logistics networks. **Transportation Research Part E**. v. 81, p. 36-51, 2015.
- ARCHER, B. Forecasting Demand: Quantitative and Intuitive Techniques. **International Journal of Tourism Management**. v. 1, n. 1, p. 5-12, 1980.
- ARMSTRONG, J. Selecting Forecasting Methods. In: ARMSTRONG, J. **Principles of Forecasting: a Handbook for Researchers and Practitioners**. Boston: Kluwer Academic Publishers, 2001.
- Associação das Pizzarias Unidas do Estado de São Paulo**. Disponível em: <www.pizzariasunidas.org.br/portal/>. Acesso em 07 Jul. 2018.
- BALLOU, R. H. **Gerenciamento da Cadeia de Suprimentos: Planejamento, Organização e Logística Empresarial**. 4. ed., Porto Alegre: Bookman, 2001.
- BARNES, David. **Understanding Business: Processes**. 1d. London: Routledge, 2001.
- BAIG, A.; BLAU, B. M.; SABAH, N. Price clustering and sentiment in bitcoin. **Finance Research Letters**, v.29, 111-116, 2019.
- BOPP, A. E. On Combining Forecasts: Some Extensions and results. **Management Science**, v.31, 1492-1498, 1985.
- CARAZZA, H. **Villare Pizzaria: planejamento estratégico e análise de oportunidades de negócio**. Porto Alegre: UFRGS, 2015. Dissertação (MBA em Marketing), Fundação Getúlio Vargas, 2015.
- CASAGRANDE, L. F; HOSS, O. Métodos de Forecasting Conjugado com um Método Qualitativo e um Método com a Média das Previsões Quantitativas e Qualitativas. **Revista CAP** - Número 04 - Ano 4 - Volume 4 – 2010.

CHAMBERS, J. C.; MULLICK, S. K.; SMITH, D. D. How to Choose the Right Forecasting Technique. **Harvard Business Review**. v. 49, July-August, p. 45-57, 1971.

CHASE JR., Charles W.. **Demand driven forecasting: a structured approach to forecasting**. 2ed. New Jersey: John Wiley & Sons, Inc., 2013.

CHEN, T. Trade-size clustering and price efficiency. **Japan & The World Economy**, v.49, 195-203, 2019.

DA SILVA, A. L; PEDROSO, C. B.. Dinâmica de implementação do Sales and Operations Planning: principais desafios. **Gestão e Produção**. v. 22, n.3, p. 662-677, 2015.

DAVIS, M.; AQUILANO, N.; CHASE, R. **Fundamentos da Administração da Produção**. Porto Alegre: Bookman, 2001.

DIAS, A. S. **Uso de conhecimento teórico e de especialista para previsão de demanda**. Trabalho de Conclusão submetido ao Curso de Graduação em Engenharia de Produção na Universidade Federal de São Carlos – UFSCar. São Carlos, 2004.

ELSAYED, E.; BOUCHER, T. **Analysis and Control of Production Systems**. 2. ed., New Jersey: Prentice-Hall, 1994.

EVANS, J. Psychological Pitfalls in Forecasting. **Futures**. v. 14, n. 4, p. 258-265, 1982.

EVERITT, Brian S.; LANDAU, Sabine; LEESE, Morven; STAHL, Daniel. **Cluster Analysis**. 5ed. New Jersey: John Wiley & Sons, Ltd., 2011.

JOSÉ FILHO. **Metodologia para implantação e melhoria do Planejamento e Controle de Produção em Pequenas e Médias Empresas**. Florianópolis: UFSC, 1999. Dissertação (Mestrado em Engenharia de Produção), Universidade Federal de Santa Catarina, 1999.

FERNANDES, F.; ANZANELLO, M. J.. **Integração de métodos quantitativos e qualitativos para previsão de demanda no setor de autopeças**. Trabalho de Conclusão submetido ao Curso de Engenharia de Produção na Universidade Federal do Rio Grande do Sul – UFRGS. Porto Alegre, 2010.

FLIES, E. J.; BROOK, B. W.; BLOMQUIST, L.; BUETTEL, J. C. Forecasting future global food demand: A systematic review and meta-analysis of model complexity. **Environment International**. v. 120, p. 93-103, 2018.

GAN, Guojun; MA, Chaoqun; WU, Jianhong. **Data Clustering: Theory, Algorithms, and Applications**. ASA-SIAM Series on Statistics and Applied Probability, SIAM, Philadelphia, ASA, Alexandria, VA, 2007.

GEORGOFF, D. M.; MURDICK, R. G. Manager's Guide to Forecasting. **Harvard Business Review**. v. 64, n. 1, p. 110-120, 1986.

GOODWIN, P. Integrating Management Judgment and Statistical Methods to Improve Short-term Forecasts. **Omega**. v. 30, n. 2, p. 127-135, 2002.

GRUZAUSKAS, V.; GIMZAUSKIENE, E.; NAVICKAS, V. Forecasting accuracy influence on logistic clusters activities: The case of the food industry. **Journal of Cleaner Production**. v. 240, 2019.

HYNDMAN, Rob J.; ATHANASOPOULOS, George. **Forecasting: Principles and Practice**. Melbourne: Otexts, 2018.

JAIN, Chamin L.; MALEHORN, Jack. Fundamentals of Demand Planning and Forecasting. **International Journal of Forecasting**. v. 29, p. 525-526, 2013.

JUN, W.; YUYAN, L.; LINGYU, T.; PENG, G. Modeling a combined forecast algorithm based on sequence patterns and near characteristics: An application for tourism demand forecasting. **Chaos, Solitons and Fractals**. v. 108, p. 136-147, 2018.

JÚNIOR, J. R. C. S. Crescimento Desacelera no Início do Ano, mas Retomada Continua. **IPEA**, 15 Mai 2018. Disponível em: <www.ipea.gov.br/cartadeconjuntura/index.php/tag/sintese-da-conjuntura/>. Acesso em 07 Jul. 2018.

KAUFMAN, L.; ROUSSEEUW, P.. **Finding Groups in Data: an Introduction to Cluster Analysis**. Willey Interscience, New Jersey, 2005.

KOTLER, P. **Marketing Management: Analysis, Planning, Implementation, and Control**. New Jersey: Prentice-Hall, 1991.

LEMOS, F. O. **Metodologia para seleção de métodos de previsão de demanda**. Porto Alegre: UFRGS, 2006. Dissertação (Mestrado em Engenharia de Produção), Departamento de Engenharia de Produção e Transportes, Universidade Federal do Rio Grande do Sul, 2006.

LINDBERG, E.; ZACKRISSON, U. Deciding about the Uncertain: The Use of Forecast as an aid to Decision-making. **Scandinavian Journal of Management**. v. 7, n. 4, p. 271-283, 1991.

LUSTOSA, L.; MESQUITA, M. A.; QUELHAS, O.; OLIVEIRA, R. J. **Planejamento e Controle da Produção**. Rio de Janeiro: Elsevier Editora, Ltda., 2008.

- LYNN, G.; SCHNAARS, S.; SKOV, R. Survey of New Product Forecasting Practices in Industrial High Technology and Low Technology Businesses. **Industrial Marketing Management**. v. 28, n. 6, p. 565-571, 1999.
- MAKRIDAKIS, S.; WHEEL WRIGHT, S.; HYNDMAN, R. **Forecasting: Methods and Applications**. 3. ed., New York: John Wiley & Sons, 1998.
- MAKRIDAKIS, S. Forecasting: Its Role and Value for Planning and Strategy. **International Journal of Forecasting**. v. 12, 1996.
- MENTZER, J. T.; GOMES, R. Evaluating a Decision Support Forecasting System. **Industrial Marketing Management**. v. 18, n. 4, 1989.
- MENTZER, J. T.; MOON, M. A.. **Sales and Forecasting Management: a Demand Management Approach**. 2^a ed. California: Sage Publications, Inc., 2005.
- MONTGOMERY, D.; JOHNSON L.; GARDINER, J. **Forecasting and Time Series Analysis**. New York: McGraw-Hill, 1990.
- MOON, M.; MENTZER, J.; SMIT, C.; GARVER, M. Seven Keys to Better Forecasting. **Business Horizons**. v. 41, n. 5, p. 44-52, 1998.
- MORETTIN, P. A.; TOLOI, C. M. C.. **Análise de séries temporais**. 2. Ed. São Paulo: Edgard Blücher, 2006, 538 p.
- MURDICK, R. G.; GEORGOFF, D. M. Forecasting: a Systems Approach. **Technological Forecasting and Social Change**. v. 44, n. 1, p. 1-16, 1993.
- NELSON, C. R. AND PLOSSER, C. R. (1982). **Trends and random walks in macroeconomic time series: Some evidence and implications**. Journal of Monetary Economics.
- RASMUSSEN, R. On Time Series Data and Optimal Parameters. **Omega**. v. 32, n. 2, p. 111-120, 2004.
- RENCHER, A. C. **Methods of Multivariate Analysis**. 2. ed., New York: John Wiley & Sons, 2002.
- ROSSETTO, M; DEIMLING, M. F; ZANIN, A. RODRIGUES, M. P; NETO, A. R. **Técnicas Qualitativas de Precisão de Demanda: um Estudo Multicasos com Empresas do Ramo de Alimentos**. VIII SEGeT – Simpósio de Excelência em Gestão e Tecnologia, outubro de 2011.
- SANDERS, N. R.; MANRODT, K. Forecasting Practices in US Corporations: Survey Results. **Interfaces**. v. 24, n. 2, p. 92-100, 1994.

SHAHRAKI, A.; TAHERKORDI, A.; HAUGEN, O.; ELIASSEN, F.. Clustering Objectives in Wireless Sensor Networks: A Survey and Research Direction Analysis, **Computer Networks**, 2020.

SILVA, E. L.; MENEZES, E. M. **Metodologia da pesquisa e elaboração de dissertação**, 5ª ed. Florianópolis: Editora UFSC, 2005.

TAYLOR, J. W. Exponential Smoothing with a Damped Multiplicative Trend. **International Journal of Forecasting**. v. 19, n. 4, p. 715-725, 2003.

THOMAS, R. J. Forecasting New Product Market Potential: Combining Multiple Methods. **The Journal of Product Innovation Management**. v. 4, n. 2, p. 109-119, 1987.

THOMOPOULOS, Nick T. **Demand Forecasting for Inventory Control**. Switzerland: Springer International Publishing, 2015.

TIAO, G. C. (1972). **Asymptotic behaviour of temporal aggregates of time series**.

TRAPERO, J. R.; PEDREGAL, D. J.; FILDES, R.; KOURENTZES, N. Analysis of judgmental adjustments in the presence of promotions. **International Journal of Forecasting**. v.29, 234-243, 2013.

WALLACE, T. F.. **Sales & Operations Planning**. 2ª ed. Cincinnati: T. F. Wallace & Company, 2004.

WEBBY, R.; O'CONNOR, M.; EDMUNDSON, B. Forecasting Support Systems for the Incorporation of Event Information: an Empirical Investigation. **International Journal of Forecasting**. v. 21, n. 3, p. 411-423, 2004.

WEI, W. W. S. (2005). **Time Series Analysis : Univariate and Multivariate Methods**. Pearson, Boston, 2 edition.

WERNER, L. **Um Modelo Composto Para Realizar Previsão de Demanda Através Da Integração da Combinação de Previsões e Do Ajuste Baseado na Opinião**. Porto Alegre: UFRGS, 2004. 166 f. Tese (Doutorado em Engenharia de Produção) – Programa de Pós-Graduação em Engenharia de Produção, Departamento de Engenharia de Produção e Transportes, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2004.

WERNER, L.; RIBEIRO, J. L. D. Modelo composto para prever demanda através da integração de previsões. UFRGS. **Produção**, v. 16, n. 3, p. 493-509, Set./Dez. 2006.

WINKLHOFER, H.; DIAMANTOPOULOS, A.; WITT, S. Forecasting Practice: a Review of Empirical Literature and na Agenda for Future Research. **International Journal of Forecasting**. v. 12, n. 2, p. 193-221, 1996.

WINTERS, P. R. Forecasting Sales by Exponentially Weighted Moving Average. **Management Science**. v. 6, p. 324-342, 1960.