

ANÁLISE DO IMPACTO DAS TECNOLOGIAS DISRUPTIVAS DA QUARTA REVOLUÇÃO INDUSTRIAL UTILIZANDO MÉTODOS DE PREVISÃO DE DEMANDA: UM ESTUDO DE CASO EM UMA EMPRESA DO VAREJO ALIMENTÍCIO

ANALYSIS OF THE IMPACT OF DISRUPTIVE TECHNOLOGIES OF THE FOURTH INDUSTRIAL REVOLUTION USING DEMAND FORECAST METHODS: A CASE STUDY IN A FOOD RETAIL COMPANY

ANÁLISIS DEL IMPACTO DE LAS TECNOLOGÍAS DISRUPTIVAS DE LA CUARTA REVOLUCIÓN INDUSTRIAL UTILIZANDO MÉTODOS DE PRONÓSTICO DE LA DEMANDA: UN ESTUDIO DE CASO EN UNA EMPRESA DE ALIMENTOS MINORISTAS

Yasmim Lima Rangel¹
Gabriela de Melo Penna Braga²
Pedro Senna³
Dianna Vivório Cardoso Santos⁴

Artigo recebido em dezembro de 2021
Artigo aceito em março de 2022

RESUMO

A quarta revolução industrial, junto às tecnologias da informação, visa viabilizar maiores graus de customização em massa, bem como potencializar vantagens competitivas no âmbito industrial. Este trabalho objetiva apresentar os conceitos da quarta revolução industrial, os quais são: Indústria 4.0, Logística 4.0 e Gestão da Cadeia de Suprimentos 4.0 e realizar uma análise do impacto das tecnologias disruptivas que fazem parte dessa onda 4.0, comparando modelos de previsão de demanda. Nesse contexto, o projeto consiste em um estudo de caso em uma empresa do varejo alimentício para analisar e o impacto do uso das tecnologias na acuracidade da previsão da demanda em uma família de produtos. Como resultados, o método Amortecimento de Holt-Winters apresentou o menor erro e, a utilização desse modelo atrelado à adoção de tecnologias como *machine learning* e *IoT* possibilitariam um melhor abastecimento dos pontos de vendas e uma maior agilidade na gestão da cadeia de suprimentos.

Palavras-chave: Previsão de Demanda. Logística 4.0. Gestão da Cadeia de Suprimentos 4.0.

¹ Engenheira de Produção – Centro Federal de Educação Tecnológica Celso Suckow da Fonseca (CEFET/RJ). E-mail: yasmimrrgl@gmail.com.

² Engenheira de Produção – Centro Federal de Educação Tecnológica Celso Suckow da Fonseca (CEFET/RJ). E-mail: gabrielampbraga@hotmail.com.

³ Docente do Centro Federal de Educação Tecnológica Celso Suckow da Fonseca (CEFET/RJ). E-mail: pedro.senna@cefet-rj.br.

⁴ Discente do Centro Federal de Educação Tecnológica Celso Suckow da Fonseca (CEFET/RJ). E-mail: dianna.santos@aluno.cefet-rj.br.

ABSTRACT

The fourth industrial revolution, together with information technologies, aims to enable greater degrees of mass customization, as well as leverage competitive advantages in the industrial sphere. This work aims to present the concepts of the fourth industrial revolution, which are: Industry 4.0, Logistics 4.0 and Supply Chain Management 4.0 and to carry out an analysis of the impact of disruptive technologies that are part of this wave 4.0, comparing demand forecast models. In this context, the project consists of a case study in a food retail company to analyze the impact of the use of technologies on the accuracy of demand forecast in a family of products. As a result, the Holt-Winters Damping method showed the least error and the use of this model coupled with the adoption of technologies such as machine learning and IoT would enable a better supply of points of sale and greater agility in the management of the supply chain.

Keywords: Demand Forecast. Logistics 4.0. Supply Chain Management 4.0.

RESUMEN

La cuarta revolución industrial, junto con las tecnologías de la información, pretende posibilitar mayores grados de personalización masiva, así como potenciar las ventajas competitivas en el ámbito industrial. Este trabajo tiene como objetivo presentar los conceptos de la cuarta revolución industrial, los cuales son: Industria 4.0, Logística 4.0 y Supply Chain Management 4.0 y realizar un análisis del impacto de las tecnologías disruptivas que forman parte de esta ola 4.0, comparando modelos de pronóstico de demanda. En este contexto, el proyecto consiste en un estudio de caso en una empresa de retail de alimentación para analizar el impacto del uso de tecnologías en la precisión de la previsión de demanda en una familia de productos. Como resultado, el método Holt-Winters Damping presentó el menor error, y el uso de este modelo ligado a la adopción de tecnologías como machine learning e IoT permitiría una mejor oferta de puntos de venta y mayor agilidad en la gestión de los cadena de suministro.

Palabras clave: Pronóstico de la Demanda. Logística 4.0. Gestión de la cadena de suministro 4.0.

1 INTRODUÇÃO

As revoluções industriais começaram a ocorrer a partir do século XVIII e acarretaram uma série de avanços tecnológicos que aumentaram a produtividade das organizações, ao reduzir os custos de produção e aumentar a eficiência, por meio da introdução de tecnologias envolvendo a mecanização a vapor, a eletricidade, a eletrônica e a tecnologia de informação (TI).

Nas últimas décadas, os sistemas de TI apresentaram um progresso muito significativo, fazendo com que os processos produtivos fossem preparados para uma possível quarta revolução industrial, também conhecida como Indústria 4.0. Um dos avanços mais impactantes dessa quarta revolução é a introdução de dispositivos inteligentes na indústria, junto aos serviços de infraestrutura baseados em mineração e análises de dados e computação em nuvem (MIRAGLIOTTA et al., 2014).

A Indústria 4.0 não se concentra na substituição dos ativos e tecnologias de fabricação existentes, mas na criação de redes e alavancagem da conectividade entre esses ativos, utilizando, principalmente, as tecnologias da informação e comunicação disponíveis. Tendo isso em vista, este novo momento seria projetado por um conjunto de tecnologias como inteligência artificial, *Big Data*, impressão 3D e a chamada Internet das Coisas ou *Internet of*

Things (IoT), de maneira que cada vez mais dispositivos, equipamentos e objetos seriam conectados uns aos outros por meio da Internet (MIRAGLIOTTA et al., 2014).

A quarta revolução industrial, em conjunto com suas tecnologias, promete viabilizar maiores graus de customização em massa, bem como potencializar ainda mais vantagens competitivas. Assim, aumentando a flexibilidade, a velocidade, a qualidade e, consequentemente, a produtividade. Tudo isso, não apenas em ambientes de manufatura, mas também nos diversos níveis das cadeias e redes de suprimento a que estão relacionados.

Nesse sentido, dentro do conceito de Indústria 4.0, um termo que vem ganhando atenção é a logística 4.0. Os conceitos da logística 4.0 podem ajudar os profissionais a reduzir a perda de ativos, gerar economia de custos de combustível, garantir estabilidade de temperatura em transporte, gerenciar estoque do armazém, ter uma visão do usuário, criar eficiência de frotas e possibilitar uma melhor previsibilidade da sua demanda. Além disso, com foco nas operações nos diversos níveis de Cadeias de Suprimentos utilizando-se das tecnologias da Indústria 4.0, surge o estudo acerca das Cadeias de Suprimentos 4.0.

Nesse sentido, a previsão de demanda é um dos principais métodos utilizados para a gestão de processos e planejamento da produção. Como a Indústria 4.0 está relacionada a integração de novas tecnologias, esta possibilita a determinação do estado da organização na cadeia de abastecimento e a previsão da sua demanda, apoiando assim o objetivo geral de melhorar a acuracidade (BAR et al., 2018).

Sendo assim, o objetivo deste estudo é realizar um estudo de caso a partir de um fluxo metodológico já existente a fim de analisar e classificar algoritmos de previsão modernos e clássicos para melhorar a acuracidade da previsão. O estudo também aborda os conceitos da Indústria 4.0 para apoiar as análises.

2 REFERENCIAL TEÓRICO

Inicia-se o referencial teórico pela indústria 4.0.

2.1 Indústria 4.0

Com os desafios criados para a indústria por causa da globalização, as empresas devem aumentar constantemente a sua produtividade e flexibilidade, comercializar novos produtos e ainda aumentar os níveis de desempenho e eficiência em ciclos cada vez menores, para suportar o conseqüente aumento da concorrência global. O objetivo de uma indústria 4.0 é explorar o potencial resultante do uso extensivo da Internet e outras tecnologias, a integração de processos técnicos e processos de negócio, o mapeamento digital e a virtualização do mundo real, e a oportunidade de criar produtos inteligentes (VDE ASSOCIATION FOR ELECTRICAL, ELECTRONIC & INFORMATION TECHNOLOGIES, 2013).

O termo “Indústria 4.0” origina-se de um projeto do governo da Alemanha que visava o desenvolvimento de tecnologias voltadas para as indústrias, com o objetivo de aumentar a competitividade através de fábricas inteligentes. Tais unidades de produção seriam proporcionadas através da conexão de máquinas, sistemas e ativos, criando redes controladas de forma autônoma, ao longo do processo produtivo. A palavra-chave para o movimento da Indústria 4.0 é conexão.

Essa composição apresenta pré-requisitos básicos, como a introdução de (i) sistemas ciberfísicos (*Cyber Physical Systems - CPS*), sistemas automatizados que permitiam a conexão das operações da realidade física com infraestruturas de informática e comunicação, a (ii) Internet de Coisas (*Internet of Things - IoT*), uma rede que compunha objetos físicos, tais como edificações e veículos, estes que possuíam tecnologia embarcada de sensores que às conectavam a uma rede capaz de coletar e transmitir dados entre si, e também com os participantes da infraestrutura de serviços, a (iii) Internet dos Serviços (*Internet of Services - IoS*) (JAZDI, 2016).

Nesse sentido, as fábricas modificadas por esses pensamentos tornaram-se inteligentes: o CPS monitora processos físicos, cria cópias virtuais do mundo físico e toma decisões descentralizadas, se comunica com a IoTS (*Internet of Things and Services*) e ambos cooperam entre si e com os humanos em tempo real, contribuindo para o aprimoramento da cadeia de valor empresarial, o conceito de *Smart Factory*.

2.2 Cadeia de Suprimentos 4.0

A cadeia de suprimentos é responsável por controlar o fluxo existente entre as empresas, qualquer que seja o canal, e por fazer com que os produtos cheguem ao consumidor final, integrando os fornecedores primários, os processos produtivos, depósitos, distribuidores e o usuário final, garantido que suas necessidades sejam atendidas (LAMBERT et al., 1998; LUMMUS et al., 1999).

Heuser et al. (2008) já afirmava há uma década que o uso e a evolução das Tecnologias de Informação e Comunicação (TIC) na indústria tornaram-se inevitáveis, principalmente por serem vitais para aumentar a eficiência organizacional e seu nível de competitividade. Sua visão continua válida até os dias atuais, de forma que essa evolução tecnológica é evidenciada pelos aplicativos conhecidos e altamente utilizada pela maioria das organizações, como *Enterprise Resource Planning* (ERP), Sistemas de Gerenciamento de Armazém (WMS), Sistemas de Gerenciamento de Transporte (TMS), Sistemas Inteligentes de Transporte (ITS) (HASAN et al., 2013).

Nesse contexto, a gestão da cadeia de suprimentos ou *supply chain management* (SCM) tem papel importante para a constituição da Indústria 4.0 uma vez que a integração dos fornecedores requisitada pode trazer benefícios como previsibilidade, melhoria no atendimento dos recursos e ganhos em escala de fornecimento (PETRISOR; COZMIUC, 2017). A importância da cadeia de suprimentos se dá não só no relacionamento entre fornecedores e consumidores, ou seja, externos à organização, mas também na gestão dos elos internos da companhia, como por exemplo entre departamentos ou entre filiais.

2.3 Logística 4.0

A visão de que os processos de logística irão transformar a indústria que conhecemos atualmente (HOMPEL; KERNER, 2015), exige novas perspectivas sobre os processos. São necessários esforços científicos respectivos para orientar os profissionais em seu desafio de transformação para processos logísticos de Indústria 4.0. Dos conceitos propostos pela Indústria 4.0, a Internet das Coisas (IoT) é um dos que mais causará impacto na logística, pela sua capacidade de troca de informações.

Nesse cenário, a logística será abordada sob o termo “Logística 4.0”. O objetivo da Logística 4.0 é, portanto, evitar imprecisões e ter processos mais rápidos onde a informação

possa ser compartilhada sem esforço e em tempo real. No entanto, sempre será necessário o envolvimento de pessoas controlando os processos e assumindo o controle de qualquer falha do sistema.

Para FREITAS et al. (2016), o emprego da Logística 4.0 pode ajudar nos processos das seguintes formas: Mapeamento da perda de ativo; otimizar rotas; Estabilização da temperatura dos ativos; gerenciamento de estoque; Identificação da visão do usuário; e, criação da eficiência de frotas.

2.4 Internet das Coisas

A internet das coisas é uma infraestrutura baseada em protocolos de comunicação em que objetos físicos e inanimados possuem personalidades virtuais, tornando-se capazes de interagir com o meio ambiente a partir de dados coletados. Com a IoT, as coisas podem reagir aos eventos e situações sem que haja intervenção humana direta (LEMOS, 2012).

Segundo Corrêa (2019), a IoT traz três benefícios importantes:

- a) Praticidade ao consumidor final: os consumidores começam a poder controlar e programar seus objetos por meio da conectividade do celular estando a quilômetros de distância;
- b) Melhoria do relacionamento entre fabricante e consumidor: o fabricante pode enviar atualizações de softwares, pode coletar dados relativos ao funcionamento visando identificar possíveis falhas de processo e, ainda, identificar perfis e padrões de consumo, com o intuito de ser mais assertivo nos próximos lançamentos; e,
- c) Facilidade de detecção de causas de problemas: quando o produto começa a apresentar algum problema de funcionamento, a IoT facilita a constatação do problema, sem que seja necessário abrir o objeto e fazer um trabalho investigativo, tornando mais ágil o processo de reparo e diminuindo o retrabalho.

2.5 Inteligência Artificial e Big Data

Com a grande qualidade de dados acumulada, surge a necessidade do uso de técnicas de mineração de dados, *analytics* e inteligência artificial aliadas às demais tecnologias de informação, trazendo em conjunto maior dinamismo, eficiência e automatização às informações. O uso de técnicas mais robustas é necessário uma vez que as vantagens não estão apenas no acesso aos dados, mas também no tempo em que as informações levam para chegar até o destino.

A coleta de dados e a obtenção de informações como localização e status de um produto são facilitadas pela IoT, no entanto, sozinha, a IoT não é suficiente. Ela é capaz de tornar um objeto comum em um produto inteligente, mas deve estar aliada ao *Big Data* e *Cloud-computing* (forma de acessar servidores, armazenamento, bancos de dados e um conjunto amplo de serviços de aplicativos via internet) para que os dados possam ser coletados, armazenados, analisados e avaliados, com o objetivo de otimizar as operações e melhorar o desempenho do sistema como um todo, além de facilitar o acesso às informações (BAHRIN et al., 2016).

Entre os benefícios advindos da armazenagem de *Big Data* e inteligência artificial para melhor uso dos dados, que impactam em melhorias diretas e indiretas nos processos, Corrêa (2019) destaca:

- a) Rede de fornecedores mais complexa e colaborativa, passando a ter foco no compartilhamento de informações e conhecimentos, não apenas nas operações;

- b) Pesquisas avançadas integradas à análise de riscos e ferramentas de otimização, que incluem previsão de demanda, planejamento de negócios e comunicação entre fornecedores;
- c) Melhoria da qualidade do fornecimento, por meio de maior integração com fornecedor e melhoria dos processos de inspeção e auditoria;
- d) Agilidade na análise de dados a partir de algoritmos de *machine learning* e aplicativos de análises de dados; e,
- e) Melhoria da previsão de demanda, de forma a incluir fatores causais que também influenciam nas vendas.

2.6 Previsão de Demanda

Previsão de demanda é um processo, quantitativo ou qualitativo, de dimensionamento e planejamento de necessidades, desempenhando um papel fundamental de auxílio à tomada de decisões em diversas áreas de uma empresa, seja na área financeira, de recursos humanos, vendas ou produção e operações (PELLEGRINI; FOGLIATTO, 2001).

Conforme Ritzman; Krajewski (2004) destacam, uma série temporal normalmente pode ser desmembrada em 5 padrões: (i) horizontal, que representa a variação dos dados em torno de uma média, (ii) tendência, que representa um acréscimo ou decréscimo em torno da média em longos períodos de tempo, (iii) sazonalidade, que reflete os picos e vales padrões de acordo com determinado período, como meses ou estações do ano, (iv) cíclico, que indica também aumentos e diminuições, como a sazonalidade, mas menos previsíveis e em períodos mais longos e, por fim, (v) aleatório, que representa variações inexplicáveis pelos demais padrões e que são mais difíceis de serem previstos.

Associada às tecnologias da onda 4.0, uma boa previsão de demanda pode melhorar os resultados operacionais e financeiros de uma empresa, aumentando a acuracidade e confiabilidade do resultado à medida que se tem mais informações sobre o produto (TUBINO, 2009). O desenvolvimento de técnicas como *machine learnig*, IoT e inteligência artificial tem tornado possível o desenvolvimento e aplicação de melhores modelos, de forma a otimizar esses processos.

O detalhamento dos métodos de previsão utilizados nesse trabalho será tratado na seção de estudo de caso.

3 MÉTODO

O trabalho em questão traz uma proposta de natureza exploratória que consiste, inicialmente, em uma revisão bibliográfica acerca dos temas relacionados às tecnologias 4.0 e o impacto dessas tecnologias na quarta revolução industrial e na previsão de demanda. Por fim, é proposta a realização de um estudo de caso para se entender os impactos, positivos e negativos, que a onda 4.0 pode trazer, bem como uma comparação entre diferentes métodos de previsão de demanda.

O estudo é relevante pois se trata de um tema novo, principalmente no Brasil, ainda com poucas referências encontradas na literatura e, ao mesmo tempo, de extrema relevância para os avanços da indústria inteligente no país. Conforme Kupfer (2016) destaca, boa parte da indústria nacional ainda está no estágio 2.0, só agora conseguindo incorporar a produção enxuta, técnicas

instauradas 30 anos atrás, além de também apresentar deficiências em aspectos característicos da onda 3.0 no âmbito da tecnologia da informação e comunicação (KUPFER, 2016).

Foi organizado da seguinte forma o protocolo para o estudo em questão: (i) revisão de literatura acerca do tema, (ii) visão geral da pesquisa, (iii) definição da empresa a ser estudada, (iv) definição dos dados a serem coletados, (v) análise dos dados obtidos, (vi) caracterização do problema, (vii) discussões do estudo de caso e (viii) detalhamento dos resultados encontrados e conclusões obtidas.

Após a coleta dos dados, serão realizadas análises com o objetivo de identificar problemas e realizar previsões e classificações acerca dos resultados obtidos.

4 RESULTADOS E DISCUSSÃO

Este estudo de caso testará modelos estatísticos à realidade da série temporal de uma empresa, a fim de identificar o método de previsão com o menor erro para melhor embasar a gestão de compras e do estoque.

4.1 A Empresa


A empresa ABC em estudo é do setor do varejo de alimentos, sendo especializada na venda de produtos a granel. Localizada no estado do Rio de Janeiro, ela foi fundada em meados de 1930, possuindo apenas uma loja na época, que trabalhava com foco na venda de frutas. Aos poucos, foi diversificando seu portfólio de produtos e atualmente já possui mais de 40 lojas e 2.000 SKUs, continuando em constante expansão.

4.2 Coleta de Dados

A coleta de dados foi feita por meio da extração dos dados de venda através de relatórios gerenciais da área comercial da companhia. A base de dados coletada possui as informações de volume diário de vendas por categoria e subcategoria de SKU desde agosto de 2014 até outubro de 2020. Os dados até setembro de 2018 foram utilizados como histórico com o objetivo de projetar a previsão de demanda mensal no período de outubro de 2018 até outubro de 2020 e comparar com os dados reais desse mesmo período.

O primeiro passo para iniciar o estudo foi a escolha da família de SKU a ser trabalhada. Para isso, foram utilizados 2 critérios: (i) quantidade de dados, ou seja, quantidade de dias com venda de produtos da família e (ii) volume de vendas. Existem 38 famílias de produtos, sendo Lanchonete, Guloseimas e Massas & Panificação as mais representativas em quantidade vendida ao longo dos anos, conforme ilustrado na Figura 1.


Figura 1 - Famílias com maior volume de vendas
Volume de vendas por família de SKU - Top 15 famílias
Milhões - Agosto/14 a Outubro/20



Fonte: Autores (2021)

Conforme a Figura 2 ilustra, é possível perceber que a família Doceria é a categoria que possui o maior volume, sendo, por essa razão, a escolhida como objeto de estudo.

Figura 2 - Famílias com maior volume de dados de vendas
Volume de dados por família de SKU - Top 15 famílias
Mil - Agosto/14 a Outubro/20



Fonte: Autores (2021)

Analisando os itens e quantidades vendidas, foi considerado que a realização do estudo de previsão de demanda dessa categoria é uma escolha adequada por se tratar de produtos de grande destaque para a empresa.

4.3 Análise dos Resultados

Os métodos de previsão utilizados foram: decomposição clássica, média móvel, NAIVE, suavização exponencial, regressão linear e redes neurais. Quanto à medição da acuracidade de cada um dos métodos de previsão, os erros estudados estão detalhados na Tabela 1.

Tabela 1 - Fórmulas dos Erros de Previsão

TIPO DE ERRO	FÓRMULA
Raiz do erro médio quadrático (RMSE - Root Mean Square Error)	$\sqrt{\frac{\sum_{t=1}^n (F_t - Y_t)^2}{n}}$
Erro médio percentual (MPE - Mean Percentual Error)	$100 \times \frac{\sum_{t=1}^n F_t - Y_t }{n}$
Erro percentual absoluto médio (MAPE - Mean Absolute Percentual Error)	$\frac{\sum_{t=1}^n \frac{ e_t }{y_t} \times 100}{n}$

Fonte: Eaves (2002)

Nas equações e_t equivale ao erro de previsão do modelo, Y_t equivale a demanda real observada e F_t é a previsão de demanda para o período t .


Dentre as formas de medir a acurácia dos modelos de previsão, a mais utilizada é a MAPE. Dessa forma, neste trabalho, escolheu-se o método MAPE para avaliar o modelo adequado, identificando aquele que tiver o menor erro associado.

Ademais, na análise das séries temporais, foi utilizada a ferramenta Excel e o software RStudio, fazendo uso dos pacotes forecast, xts, ggfortify, tstools, astsa, tseries, dplyr, readxl, tidyverse, lubridate, ggplot2 e readr.

4.3.1 Cenário Atual

Após a coleta dos dados, inicialmente foi construído um gráfico representando a série temporal de vendas da família Doceria, conforme é possível observar na Figura 3. Analisando o gráfico, pode-se perceber que a série apresenta uma tendência de crescimento e possui alguns picos e vales em períodos específicos, apresentando sazonalidade.


Figura 3 - Série temporal de vendas



Fonte: Autores (2021)

A Figura 4, mostra detalhadamente o comportamento da constante sazonalidade ao longo dos anos. É possível observar que há sempre um crescimento no mês de dezembro e no mês de março e reduções nos meses de janeiro e fevereiro.

Figura 4 - Estratificação da série de vendas por mês



Fonte: Autores (2021)

4.3.2 Decomposição Clássica

O método de decomposição clássica auxilia em tomadas de decisões acerca da previsão por meio do comportamento de cada uma das componentes da série temporal: tendência, ciclo, sazonalidade e termo aleatório ou ruído.

Esse método utiliza fórmulas matemáticas básicas que separam a série temporal nas quatro componentes, por meio dos quais, é possível que as previsões sejam realizadas. A série pode ser escrita como uma soma ou uma multiplicação das componentes, assim, o método se divide em aditivo, no qual os dados são independentes, ou multiplicativo, quando os dados são proporcionais (MORETTIN; TOLOI, 2004). Dessa forma, a decomposição pode ser descrita por meio de uma das Equações 1 e 2, a seguir, sendo a primeira utilizada no método aditivo e a segunda, no método multiplicativo.


$$Z_t = T_t + S_t + C_t + A_t \quad (1)$$

$$Z_t = T_t \times S_t \times C_t \times A_t \quad (2)$$

Nas equações, Z_t representa o valor real, T_t representa a tendência, que pode ser estabelecida como uma modificação da variável no longo prazo (FISCHER, 1982), S_t é a componente sazonal, que, segundo PARMEZAN et al. (2016) descreve um comportamento próprio que se repete em determinados períodos, C_t é o ciclo, estabelecido como variações não aleatórias que se repetem com tempo, mas sem a periodicidade característica da sazonalidade, e, por fim, A_t é a componente aleatória, também chamado de ruído ou erro, que representa a parcela restante dos dados que não pode ser distinguível, após a decomposição das demais componentes (BOUZADA, 2012).

A Figura 5 mostra o resultado da previsão da demanda obtido a partir do método de composição clássica aditiva, na qual pode ser observada que tanto a tendência quanto a sazonalidade da série foram projetadas e foi obtido um MAPE equivalente a 6,12%.


Figura 5 - Previsão de demanda utilizando decomposição clássica aditiva



Fonte: Autores (2021)

O mesmo foi replicado ao método multiplicativo, conforme pode-se observar o resultado da previsão na Figura 6. Nesse caso, o MAPE obtido foi próximo do encontrado no método aditivo, com valor de 7,03%, indicando uma acuracidade do modelo multiplicativo inferior ao aditivo.

Figura 6 - Previsão de demanda utilizando decomposição clássica multiplicativa




Fonte: Autores (2021)

4.3.3 Médias Móveis

A média móvel possui esse nome, pois, embora seja uma média simples, à medida que os dados são atualizados, os dados mais antigos são substituídos por dados mais recentes. Assim, quanto menor for o volume de dados utilizados no método, maior é a variação do resultado.

O gráfico da Figura 7 apresenta a previsão de demanda calculada pelo método de média móvel. Pode-se perceber que a previsão apresenta um efeito oposto ao realizado, ou seja, quando temos um vale, a previsão apresenta um pico e vice-versa. Isto posto, a acuracidade do método não é muito elevada, apresentando um MAPE de 10,74%.

Figura 7 - Previsão de demanda utilizando o método de médias móveis para $n = 3$




Fonte: Autores (2021)

4.3.4 Naive

O método *Naive* consiste em repetir, para o instante futuro, o valor do instante atual, afirmando que a melhor estimativa para a previsão do valor em $t + 1$ é o valor no instante t . O modelo é dado pela Equação 3.

$$\hat{Y}_t = Y_{t-1} \quad (3)$$

A Figura 8 mostra a aplicação do método para a série temporal em estudo. De acordo com o gráfico, podemos perceber que o método NAIVE segue a linha de tendência da série, e não representa a sazonalidade. O MAPE observado para o método foi de 14,85%. Assim sendo, é um modelo que não possui uma acuracidade elevada. Analisando o gráfico da direta, que apresenta a comparação entre o previsto e realizado, podemos observar que o método apresenta erros significativos de previsão.

Figura 8 - Previsão de demanda utilizando o método *Naive*


Fonte: Autores (2021)

4.3.5 *Naive Sazonal*

Por sua vez, o modelo Sazonal busca suavizar as diferenças que ocorrem no modelo estacionário, uma vez que utiliza um fator multiplicador Y_t ao valor observado. Este fator avalia os valores analisados no tempo atual t e no tempo $t-1$, a fim de gerar uma previsão mais adequada. A equação do modelo sazonal é detalhada na Equação 4.

$$\hat{Y}_{t+1} = Y_t \left(1 + \frac{T_t - Y_{t-1}}{Y_{t-1}} \right) \quad (4)$$

A Figura 9 mostra que o modelo Sazonal representa a sazonalidade da série, apresentando os picos e vales dos dados. No entanto, ainda assim, parece não seguir a linha de tendência da série. O MAPE observado para o modelo foi de 18,20%, de forma que a acuracidade do modelo é ainda inferior ao modelo estacionário, apesar do método acompanhar a sazonalidade. O gráfico da comparação entre o previsto e realizado está apresentado na Figura 9.

Figura 9 - Previsão de Demanda utilizando o método *Naive Sazonal*

Fonte: Autores (2021)


4.3.6 Suavização Exponencial Simples

A previsão de demanda usando um modelo de suavização exponencial simples é mais vantajosa uma vez que possui mais peso nas demandas mais atuais (SLACK et al., 2009). De acordo com Chopra; Meindl (2016), a utilização deste método se tornará mais eficaz quando aplicado à uma série temporal sem tendência ou sazonalidade. Este modelo pode ser expresso matematicamente através da Equação 5, onde F_t é a previsão para o período anterior, F_{t+1} é a previsão para o período $t + 1$, Y_t é a demanda no período t e o α é uma constante de amortecimento, que pode variar entre 0 e 1.

$$F_{t+1} = \alpha Y_t + (1 - \alpha)F_t \quad (5)$$

Na Figura 10, podemos observar o comportamento da previsão de vendas da categoria Doceria quando se utiliza o modelo de suavização exponencial simples. Pode-se perceber que o modelo não contempla sazonalidade e, por esse motivo, apresenta discrepâncias quando comparado com os dados reais. Além disso, o MAPE calculado para esse modelo foi de 13,82%, indicando que ele possui uma baixa acuracidade.

Figura 10 - Previsão de demanda utilizando o método de Suavização Exponencial Simples



4.3.7 Holt

Quando uma determinada sequência tem uma tendência linear crescente ou decrescente, se outros componentes da sequência podem ser ignorados, o modelo de Holt pode ser usado de forma satisfatória para a previsão. Este modelo emprega duas constantes de suavização, α e β . A primeira se refere ao nível da amostra e a segunda se refere à tendência da série, onde ambas podem variar entre 0 e 1 (MAKRIDAKIS et al., 1998). O modelo é representado por três equações, as quais são destacadas abaixo nas Equações 6, 7 e 8.

$$L_t = \alpha z_t + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad (6)$$


$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \quad (7)$$

$$\hat{z}_{t+k} = L_t + kT_t \quad (8)$$

As Equações 6 e 7 fazem uma estimativa do nível e da inclinação da série temporal, respectivamente. Já a Equação 8, calcula a previsão da demanda para os próximos k períodos. T_t é a tendência e L_t é o nível calculado no período t .

Na Figura 11, podemos observar que, assim como outros modelos apresentados nesse estudo, o modelo Holt não contempla uma componente sazonal. Apesar disso, o método acompanha a tendência de crescimento da série temporal estudada. Analisando graficamente, ainda assim, podemos observar que há grandes variações quando se observa a comparação entre o previsto e realizado. Ademais, o MAPE calculado para o modelo é 15,78%, sendo um erro considerado bastante elevado.

Figura 11 - Previsão de demanda utilizando o Método Holt



Fonte: Autores (2021)

4.3.8 Holt-Winters

O método de Holt-Winters se difere do modelo de Holt pela sazonalidade. Como apresentado anteriormente, este método se subdivide em dois: Holt-Winters aditivo e Holt-Winters multiplicativo. Vale ressaltar que ambos os modelos possuem as equações de L_t , que representam o nível, T_t , que representam a tendência e F_t , que representam a sazonalidade.

Conforme Koehler et al. (2001), o modelo de Holt-Winters aditivo é adequado para séries temporais com apenas um padrão sazonal e que não mudam com o nível, ou seja, séries em que a amplitude das mudanças sazonais é constante. Por outro lado, a forma multiplicativa aplica-se a séries em que as muda a amplitude das mudanças sazonais varia ao longo do tempo, de acordo com o nível da série (VERÍSSIMO et al., 2012). As Equações 9, 10, 11, 12 e 13 detalham a forma aditiva.

$$L_t = \alpha(Y_t - F_{t-s}) + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad (9)$$

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

$$F_t = \gamma(Y_t - L_t) + (1 - \gamma)F_{t-s} \quad (11)$$

$$\hat{Y}_t(h) = L_t + hT_t + F_{t+h-s} \quad \text{para } h = 1, 2, \dots, s \quad (12)$$

$$\hat{Y}_t(h) = L_t + hT_t + F_{t+h-2s} \quad \text{para } h = s+1, s+2, \dots, 2s \quad (13)$$

Para o método de Holt-Winters multiplicativo, as Equações 14, 15, 16, 17 e 18 são representadas a seguir.

$$L_t = \alpha \left(\frac{Y_t}{F_{t-s}} \right) + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad (14)$$

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \quad (15)$$

$$F_t = \gamma \left(\frac{Y_t}{L_t} \right) + (1 - \gamma)F_{t-s} \quad (16)$$


$$\hat{Y}_t(h) = (L_t + hT_t)F_{t+h-s} \quad \text{para } h = 1, 2, \dots, s \quad (17)$$

$$\hat{Y}_t(h) = (L_t + hT_t)F_{t+h-2s} \quad \text{ou } \quad \text{para } h = s+1, s+2, \dots, 2s \quad (18)$$

Nesses casos, o valor de s representa o número de períodos sazonais, o valor de h representa o horizonte de projeção. F_t é a estimativa da componente sazonal, T_t é a tendência e L_t é o nível calculado no período t . As constantes de amortecimento α , β e γ variam entre 0 e 1.

Na Figura 12, podemos observar a previsão da série temporal utilizando o método Holt-Winters aditivo. Como pode-se perceber, é um método que, analisando graficamente, aparenta ser bem aderente aos dados reais. Ao analisar o MAPE calculado, verifica-se um erro de 6,20%, possuindo uma acuracidade maior em comparação com os demais métodos.


Figura 12 - Previsão de demanda utilizando o método Holt-Winters aditivo



Fonte: Autores (2021)

Já na Figura 13, é apresentada a previsão de demanda do método Holt-Winters multiplicativo. Este acompanha a sazonalidade da série temporal e apresenta dados previstos bem aderentes em relação aos reais. Analisando graficamente, parece ser um bom método para realização da demanda da categoria Doceria. O MAPE calculado foi de 5,55%, possuindo um erro de previsão menor do que os dos demais métodos analisados nesse estudo até o momento.

Figura 13 - Previsão de demanda utilizando o método Holt-Winters multiplicativo



4.3.9 Amortecimentos de Holt-Winters

No estudo de Taylor (2003), são realizadas simulações incorporando uma variável de amortecimento extra ao modelo de Holt-Winters usual a fim de melhorar a acuracidade das previsões.


A Equação 19 representa a previsão sem a constante de amortecimento. Se for desejável amortecer a tendência, a constante de amortecimento deverá ser incluída, como demonstrado na Equação 20.

$$\hat{Z}_t(\tau) = \hat{a}_1(t) + \hat{a}_2(t)\tau \quad (19)$$

$$\hat{Z}_t(\tau) = \hat{a}_1(t) + \left[\sum_{j=1}^{\tau} \varphi^{j-1} \right] \hat{a}_2(t) \quad (20)$$

Na Figura 14, podemos observar a previsão da série temporal utilizando o método o Amortecimento de Holt-Winters. O erro de previsão calculado pelo método MAPE foi de 4,82%, sendo bem reduzido em comparação com os demais métodos apresentados no estudo. Assim sendo, a previsão feita bem aderente à demanda real. Como podemos analisar pela comparação entre a previsão e o realizado, o método possui poucas variações significativas entre os dados.

Figura 14 - Previsão de demanda utilizando o Amortecimento de Holt-Winters



Fonte: Autores (2021)

4.3.10 Regressão Linear


O modelo de regressão linear estuda a relação linear entre duas variáveis: uma variável dependente (y) e uma variável independente (x), representada a partir de uma equação matemática que relaciona as duas variáveis, conforme a Equação 21.

$$y_i = \beta_0 + \beta_1 x_i + \varepsilon_i, \text{ onde } i = 1, \dots, n \quad (21)$$

Como já citado anteriormente, o y da equação representa o valor da variável dependente (ou a resposta) e o x indica o valor da variável independente. Ainda, β_0 e β_1 representam os parâmetros do modelo e o ε representa o erro, sendo β_0 o coeficiente linear e β_1 a inclinação da reta (HOFFMANN, 2006).

O gráfico da Figura 15 representa a reta de tendência para previsão da demanda futura a partir do modelo de regressão linear. Como é possível observar, os dados previstos mantêm a tendência de aumento da série histórica, no entanto, não considera a sazonalidade. Devido a esse fator a acuracidade do método, medida através do MAPE de 12,25%, não é satisfatória. Analisando o gráfico da direita, os dados previstos acompanham a tendência de crescimento da série, mas não apresentam a componente sazonal.

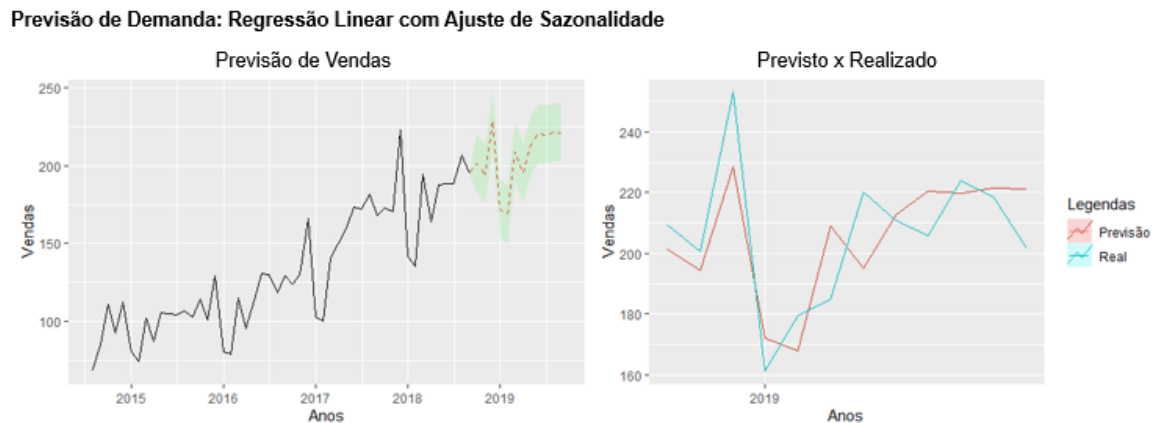
Figura 15 - Previsão de demanda utilizando o método de Regressão Linear



Fonte: Autores (2021)

Com o intuito de tornar o método mais assertivo, foi feito um ajuste de sazonalidade na série prevista, que conforme demonstra o gráfico da Figura 16, agora apresenta também os picos e vales observados na séria histórica, além da tendência, que já era observado no método anterior. Dessa forma, a acuracidade do novo método apresentou uma melhora, chegando a um MAPE de 7,39%, quase metade do MAPE anterior.

Figura 16 - Previsão de demanda utilizando o método de regressão linear com ajuste de sazonalidade

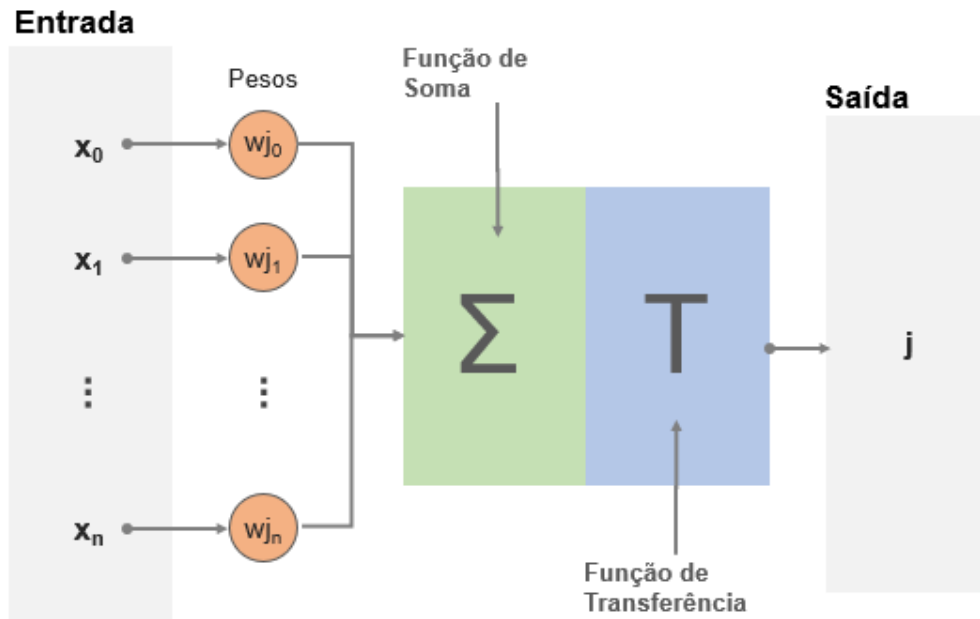


4.3.11 Redes Neurais

Uma rede neural possui poder computacional para adquirir conhecimento por meio de um processo de aprendizagem, armazenar o conhecimento a partir de forças de conexão entre neurônios e disponibilizar o conhecimento adquirido e armazenado, de forma similar ao cérebro humano (HAYKIN, 2001). A partir do reconhecimento de padrões e regularidades em séries temporais, a rede neural se tornou uma alternativa a técnicas estatísticas de previsão de demanda por meio da inteligência artificial. Uma vez que o conhecimento foi adquirido e armazenado, a rede é capaz de entender e replicar o comportamento histórico de forma a prever e estimar o comportamento futuro (TAFNER, 1998).

Na Figura 17, Tafner (1998) demonstra como o neurônio artificial recebe os vetores de entrada (x), processando-os através da função de soma e executando a função de transferência por meio do vetor de saída (j).


Figura 17 - Neurônio artificial de uma rede neural



Fonte: Adaptado de Tafner (1998)

No gráfico da Figura 18, é possível observar o resultado obtido através do método de redes neurais para estimar a demanda futura da série temporal, família Doceria. Fica evidente que o comportamento histórico da série em termos de tendência e sazonalidade foi considerado e replicado na demanda futura, com uma acurácia satisfatória quando comparada com outros métodos utilizados anteriormente, obtendo um MAPE de 6,34%.

Figura 18 - Previsão de demanda com base no método de Redes Neurais




Fonte: Autores (2021)

4.4 Discussão dos Resultados

Ao longo deste estudo, foram testados diferentes métodos preditivos a fim de identificar qual possui melhor confiabilidade para realizar a previsão de demanda da família Doceria da Empresa ABC. Foi realizada a comparação entre métodos clássicos e modernos, que, inclusive, utilizam Inteligência Artificial. A Figura 19 mostra os resultados das previsões para cada um dos métodos.

Figura 19 - Previsão de vendas de todos os métodos analisados



Fonte: Autores (2021)

Na Figura 20, conseguimos perceber mais detalhadamente o comportamento de cada uma das previsões realizadas em comparação com os dados reais. Dessa forma, podemos perceber, a partir de uma análise visual dos gráficos, que métodos como *Naive Sazonal* e Modelo Holt, para essa série temporal, não aparentam ser os modelos ideais, uma vez que apresentam uma discrepância significativa entre os dados previstos e reais. Por outro lado, os modelos de Holt-Winters parecem visualmente ser os mais adequados para realizar a previsão de demanda da categoria Doceria da empresa ABC, pois fica nítido que os modelos apresentam dados projetados mais aderentes aos dados reais.

Figura 20 - Previsão x Realizado de todos os métodos analisados



Fonte: Autores (2021)

Por fim, após a análise visual dos gráficos, a fim de analisar a aderência das previsões e confirmar o melhor modelo para a empresa ABC, foram calculados os erros de previsão utilizando diferentes métodos, os quais são detalhados na Tabela 1. Visto isso na Tabela 2, pode-se observar que o melhor método é o Amortecimento de Holt-Winters, que apresenta o MAPE de 4,82%, ou seja, com uma acuracidade de 95,18%. Por outro lado, métodos como Suavização Exponencial Simples, Naive e Naive Sazonal apresentaram erros muito elevados, acima de 15%, em comparação com os demais métodos. Ainda nesse contexto, vale destacar que o Modelo Holt apresentou um MAPE de 18,20%, o que representa uma acuracidade de 81,80%, sendo quase 4 vezes maior que o MAPE do melhor método, não sendo indicado para essa série de dados estudada. É importante ressaltar também que, apesar de ser um modelo mais moderno, que utiliza Inteligência Artificial, o método de Redes Neurais não apresentou o menor erro de previsão quando comparado com métodos como Amortecimento de Holt-Winters, Holt-Winters aditivo e multiplicativo e Decomposição Aditiva.

Por fim, a indicação para Empresa ABC, no que diz respeito à previsão de demanda da categoria Doceria, é o método de Amortecimento de Holt-Winters. É importante frisar que cada série temporal possui características e comportamentos diferentes, sendo necessário avaliar

individualmente o comportamento dos métodos caso haja necessidade de definir o modelo ideal de outras séries temporais.


Tabela 2 - Erros de previsão dos métodos analisados

MODELO	RMSE	MPE	MAPE
Amortecimento de <i>Holt-Winters</i>	8,21	0,09%	4,82%
<i>Holt-Winters</i> Multiplicativo	8,56	-1,57%	5,55%
Decomposição Aditiva	9,30	-0,74%	6,12%
<i>Holt-Winters</i> Aditivo	9,67	-0,80%	6,20%
Redes Neurais	9,88	-0,75%	6,34%
Decomposição Multiplicativa	10,49	-0,83%	7,03%
Regressão Linear Múltipla	10,63	-0,37%	7,40%
Médias Móveis	28,61	0,37%	10,74%
Regressão Linear Simples	19,38	-2,17%	12,25%
Suavização Exponencial Simples	21,54	2,22%	13,82%
Naive	25,77	0,12%	14,85%
Método Holt	24,39	-5,78%	15,78%
Naive Sazonal	31,85	18,17%	18,20%

Fonte: Autores (2021)

Considerando o contexto do trabalho, além da definição do melhor método para a série temporal estudada, também é importante estudar formas de otimizar o processo considerando as tecnologias disruptivas da Indústria 4.0. Nesse sentido, na Figura 21, é destacado o fluxo do processo de previsão de demanda, a partir do qual são sugeridas algumas oportunidades de melhoria.

Figura 21 - Fluxo do processo de previsão de demanda



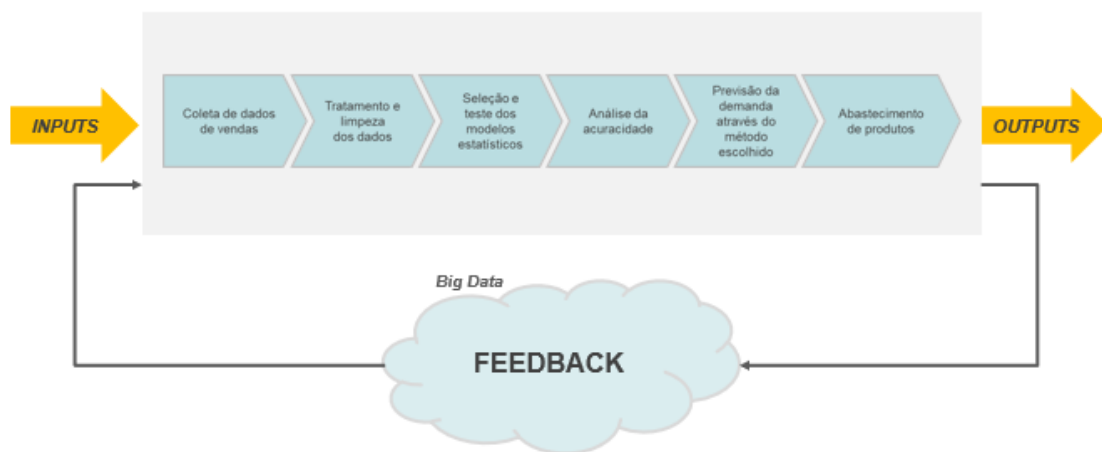
Fonte: Autores (2021)

A primeira etapa do processo é essencial para a utilização de métodos quantitativos, os quais servem como insumos para embasar uma boa previsão de demanda. O diferencial da coleta de dados não é simplesmente a obtenção das informações, mas sim a velocidade e agilidade com que os dados são obtidos. Nesse sentido, considerando a era 4.0, a interconexão entre os elos da cadeia, ou seja, dados reais em tempo real, é um fator relevante para uma organização que deseja se manter competitiva.

Para as três próximas etapas, tratamento e limpeza dos dados, seleção e teste dos modelos estatísticos e análise da acuracidade, é importante utilizar uma ferramenta automatizada que realize esses passos, sem necessidade de intervenção humana. É importante garantir que se tenha capacidade para suportar volumes significativos de dados.

Por fim, para duas últimas etapas, previsão da demanda e abastecimento de materiais, dois fatores devem ser considerados: retroalimentação do processo e fornecedor. Com relação ao primeiro ponto, é importante ficar atento e ter capacidade de utilizar os acontecimentos e variáveis do mercado e flutuações na demanda como inputs para realizar ajustes no modelo e melhorar continuamente o processo. Segundo Corrêa (2019), utilizar e investir em IoT é importante, uma vez que auxilia no alcance desses objetivos e benefícios. Conforme Wang et al. (2016), a Figura 22 ilustra como os outputs coletados por meio da utilização de IoT podem ser utilizados como feedbacks para retroalimentação do processo de previsão de demanda.

Figura 22 - Fluxo de retroalimentação do processo de previsão utilizando *IoT*



Fonte: Adaptado de Wang et al. (2016)

5 CONSIDERAÇÕES FINAIS

O trabalho consistiu na realização de uma revisão bibliográfica dos temas relacionados à Indústria 4.0 e avaliou como as tecnologias da onda 4.0 podem influenciar os processos de planejamento e controle das indústrias, como, por exemplo, o papel dessas tecnologias nas análises de previsão de demanda. À vista disso, o estudo identificou, analisou e classificou diferentes métodos de previsão de demanda a fim de melhorar a assertividade e previsibilidade das vendas da categoria Doceria da empresa ABC do ramo do varejo alimentício.

Os resultados obtidos em cada um dos 13 métodos de previsão utilizados foram analisados e comparados por meio da apuração do cálculo dos 6 métodos de erros de previsão utilizados. Em resumo, nota-se que os métodos estacionários, que não levam em consideração as componentes sazonais ou componentes de tendência da série temporal, como média móvel e NAIVE estacionário, por exemplo, apresentam maiores erros quando os dados reais são comparados com os dados previstos, resultando em uma demanda prevista pouco precisa. Por outro lado, os métodos mais robustos como, por exemplo, os métodos de Holt-Winters apresentaram o melhor desempenho. Um ponto interessante que podemos destacar nesse

contexto é que, apesar do método de Redes Neurais utilizar conceitos modernos ligados à onda 4.0, este não foi o modelo que possui o menor erro de previsão para essa série temporal.

Á vista disso, a partir do estudo de caso realizado, é indicado que a empresa ABC utilize o método Amortecimento de Holt-Winters para prever suas demandas futuras da categoria Doceria. Como avaliado no estudo, a aplicação desse método associada à adoção de tecnologias de machine learning e IoT para garantir um melhor abastecimento dos pontos de venda e gerar alertas em casos de possíveis rupturas, possibilitará maior agilidade na revisão da demanda prevista por possíveis flutuações inesperadas nas vendas reais.

Por fim, o objetivo final do trabalho de realizar uma revisão bibliográfica dos temas da onda 4.0 e estudar e identificar os modelos de previsão mais adequados para a categoria Doceria da Empresa ABC foi cumprido. Como proposta de estudos futuros, existem diversas alternativas que podem ser exploradas: (i) realizar o estudo de previsão de demanda para as outras categorias representativas da empresa ABC a fim de identificar se possuem o mesmo comportamento que a série estudada nesse trabalho, (ii) realizar o estudo de previsão de demanda com outras empresas do ramo de varejo alimentício a fim de comparar os resultados obtidos com o da empresa ABC e (iii) aprofundar a aplicação de outras tecnologias da onda 4.0 a fim de analisar seus impactos tanto em previsão de demanda quanto na gestão da cadeia de suprimentos como um todo.

6 REFERÊNCIAS

- BAHRIN, M.; OTHMAN, F.; AZLI, N.; TALIB, M. **Industry 4.0: A review on industrial automation and robotic**. Journal Teknologi, v. 78, n. 6-13, p. 137–143, 2016.
- BAR, K.; ZAZA, N.; HERBERT-HANSEN, L.; KHALID, W. **Considering Industry 4.0 aspects in the supply chain for an SME**. Production Engineering, v. 12, n. 6, p. 747-758, 2018.
- BOUZADA, M. A. C. **Aprendendo Decomposição Clássica: Tutorial para um Método de Análise de Séries Temporais**. TAC, Rio de Janeiro, v. 2, n. 1, art. 1, p. 1-18, 2012.
- CHOPRA, S.; MEINDL, P. **Gestão da Cadeia de Suprimentos: Estratégia, Planejamento e Operações**. 6. ed. Pearson Universidades, 2016.
- CORRÊA, H. L. **A Indústria 4.0 e suas implicações para as cadeias de suprimentos**. Revista Mundo Logística, 2019.
- EAVES, A. **Forecasting for the ordering and stock-holding of consumable spare parts**. (PhD thesis) - Lancaster University, Department of Management Science. Lancaster, 2002.
- FISCHER, S. **Séries univariantes de tempo: metodologia de Box & Jenkins**. v. 1000, p. 3, 1982.
- FREITAS, M. M. B. C.; FRAGA, M. A. F.; SOUZA, G. P. L. **Logística 4.0: conceitos e aplicabilidade: uma pesquisa-ação em uma empresa de tecnologia para o mercado automobilístico**. Caderno PAIC, v. 17, n. 1, p. 237–261, 2016.
- HASAN, S.; RENNIE, A. E. W.; HASAN, J. **The business model for the functional rapid manufacturing supply chain**. Studia Commercialia Bratislavensia, v. 6, n. 4, p. 536-552, mar. 2013.

- HAYKIN, S. **Redes Neurais: Princípios e Prática**. 2. ed. Porto Alegre: Bookman, 2001.
- HEUSER, C. A. **Projeto de banco de dados**. 4. ed. Porto Alegre: Bookman, 2008.
- HOFFMANN, R. **Análise de Regressão: Uma Introdução a Econometria**. 3. ed. Editora Hucitec, 2006.
- JAZDI, N. **Dynamic calculation of the reliability of factory automation applications**. IEEE International Conference on Automation, Quality and Testing, Robotics (AQTR), ClujNapoca, Romania, 2016.
- KOEHLER, A. B.; SNYDER, R. D.; ORD, J. K. **Forecasting Models and Prediction Intervals for the Multiplicative Holt-Winters Method**. International Journal of Forecasting, v. 17, n. 2, p. 269-286, 2001.
- KUPFER, D. **Indústria 4.0 Brasil**. Valor Econômico, 2016.
- LAMBERT, D. M.; COOPER, M. C.; PAGH, J. D. **Supply Chain Management: Implementation Issues and Research Opportunities**. International Journal of Logistics Management, v. 9, n. 2, p. 1-20, jul. 1998.
- LEMOS, A. **A comunicação das coisas: Internet das Coisas e Teoria Ator-Red**. Cyber Arte Cultura, 2012.
- LUMMUS, R. R.; VOKURKA, R. J. **Defining supply chain management: a historical perspective and practical guidelines**. Industrial Management & Data Systems, v. 9, n. 1, p. 11-17, fev. 1999.
- MAKRIDAKIS, S.; WHEELWRIGHT, S.; HYNDMAN, R. **Forecasting: Methods and Applications**. 3. ed., New York: John Wiley & Sons, 1998.
- MORETTIN, P.; TOLOI, C. **Análise de séries temporais**. São Paulo: Edgard Blücher, 2004.
- PARMEZAN, A. R. S.; BATISTA, G. E. A. P et al. **Descrição de modelos estatísticos e de aprendizado máquina para predição de séries temporais**. São Carlos: ICMC-USP, 2016.
- PELLEGRINI, F. R.; FOGLIATTO, F. S. **Passos para Implantação de Sistemas de Previsão de Demanda Técnicas e Estudo de Caso**. Revista Produção, v. 11, n. 1, p. 43-64, nov. 2001.
- PETRISOR, I.; COZMIUC, D. **Global Supply Chain Management Organization At Siemens In The Advent Of Industry 4.0**. Global Intermediation and Logistics Service Providers, p. 123-142, 2017.
- RITZMAN, L. P.; KRAJEWSKI, L. J. **Administração da produção e operação**. São Paulo: Abdr, 2004.
- TAFNER, M. A. **Redes Neurais Artificiais: Aprendizado e Plasticidade**. Cérebro & Mente, v. 2, n. 5, mar. 1998.
- TAYLOR, J. **Short-term Electricity Demand Forecasting Using Double-seasonal Exponential Smoothing**. Journal of Operational Research Society, v. 54, n. 8, p. 99-805, ago. 2003.
- TEN HOMPEL, M.; KERNER, S. **Logistik 4.0: Die Vision vom Internet der autonomen Dinge**. Informatik-Spektrum, v. 38, n. 3, p. 176-182, 2015.
- TUBINO, D. F. **Planejamento e Controle da Produção: Teoria e Prática**. 2. ed. São Paulo: Atlas, 2009.

VDE ASSOCIATION FOR ELECTRICAL, ELECTRONIC & INFORMATION TECHNOLOGIES. **The German Standardization Roadmap Industrie 4.0**. 1. ed. Frankfurt: DKE, 2013.

VERÍSSIMO, A. J. et al. **Métodos Estatísticos de Suavização Exponencial Holt-winters para Previsão de Demanda em uma Empresa do Setor Metal Mecânico**. Revista Gestão Industrial, v. 8, n. 4, p. 154-171, 2012.

WANG, S.; WAN, J.; LI, D.; ZHANG, C. **Implementing Smart Factory of Industrie 4.0: An Outlook**. International Journal of Distributed Sensor Networks, v. 12, p. 1-10, jan. 2016.