

# **Previsão de Vendas com Machine Learning: implementação do Algoritmo Prophet em linguagem R**

## **Machine Learning Sales Forecast: implementation of Prophet algoritmo in language R**

Lucas da Silva Herold

Marcos Leandro Hoffmann Souza

### **RESUMO**

A necessidade de se estabelecer uma gestão de demanda eficaz é uma atividade desafiadora para as organizações e saber lidar com as incertezas do mercado é atividade-chave para assegurar o crescimento e a competitividade de uma empresa. Em uma era, onde é possível armazenar grande volume de dados, utilização de técnicas analíticas avançadas pode trazer informações úteis para os tomadores de decisão. Dessa forma, o presente trabalho foi desenvolvido em uma indústria de médio porte, inserido na cadeia produtiva do mercado de pavimentação de asfalto, como objetivo de utilizar um método de previsão de demanda, utilizando um modelo preditivo com *Machine Learning*. Utilizando o método de Law e Kelton para construção de modelagem, foi realizado um estudo e optou-se em utilizar o software R e aplicar o algoritmo *Prophet*, para analisar a série temporal do produto e construir um modelo para validação. Na sequência o modelo foi construído, ajustado para simular a demanda real dos meses subsequentes. Os resultados foram avaliados e interpretados, obtendo um erro máximo de 2,8% e MEP de -7%. O uso de *Machine Learning* para previsão de demanda foi satisfatório e pode ser considerada como uma ferramenta eficaz para as tomadas de decisão. Uma análise crítica da do método e sugestões para futuras pesquisas conclui este estudo.

**Palavras-chaves:** Previsão de demanda; Machine Learning; Prophet; Tomada de decisão.

### **ABSTRACT**

The need to establish effective demand management is a challenging activity for organizations and dealing with market uncertainties is a key activity to ensure the growth and competitiveness of a company. In an era where it is possible to store large amounts of data, using advanced analytical techniques can bring useful information to decision makers. Thus, the present work was developed in a medium-sized industry, inserted in the asphalt paving market productive chain, aiming to use a demand forecasting method, using a predictive model with Machine Learning. Using the Law and Kelton method for modeling construction, a study was conducted and it was decided to use the R software and apply the Prophet algorithm to analyze the product time series and build a model for validation. Then the model was built, adjusted to simulate the actual demand of the subsequent months. The results were evaluated and interpreted, obtaining a maximum error of 2.8% and SEM of -7%. The use of Machine Learning for demand forecasting was satisfactory and can be considered as an effective tool for decision making. A critical analysis of the method and suggestions for future research concludes this study.

**Keywords:** Demand Forecasting; Machine Learning; Prophet; Decision making.

## 1 INTRODUÇÃO

Em um cenário competitivo acirrado e de constante transformação, é crucial para as empresas se adaptarem as expectativas e exigências do mercado (PEREIRA et al., 2015) e estarem sempre a frente de seus concorrentes, tanto em tecnologia quanto em métodos de gerenciamento de seus recursos (DORNELAS, 2017). Sendo assim, fortalece a necessidade de se estabelecer uma gestão de demanda eficaz, como forma de dar sustentação à tomada de decisão, permitindo assim a minimização dos riscos inerentes de projeções futuros. (ERHARD; BUG, 2016).

Martin *at al.* (2016) reforça que lidar com demanda imprevisível é crucial para o sucesso da companhia. Dias *at al.* (2015) destaca que os fatores externos incontroláveis (economia, mercado e concorrentes) e fatores internos (marketing, decisões de fabricação), são os eventos que influenciam nas variações de demanda. Esses fatores aliados as recentes crises econômicas, tem obrigado gestores a tomarem decisões mais rápidas e assertivas (COSTA *at al.*, 2018).

A gestão de demanda é sempre uma tarefa complicada e saber lidar com as incertezas do mercado é fator chave para a inteligência empresarial moderna, em uma era, onde a internet e os sistemas computacionais possibilitam dados históricos armazenados em longo prazo e em grandes quantidades, a utilização de técnicas analíticas avançadas podem trazer informações úteis para as tomadas de decisões subsequentes (VASCONCELOS, 2018).

Neste contexto imprevisível, o mercado de compactação de asfalto tem um grande potencial de crescimento no Brasil, pois dos quase 1,7 milhão de quilômetros da malha rodoviária apenas 12,4% possui pavimentação (MT, 2019). Estudos da CNT estima que, para solucionar todos os problemas do segmento, seriam necessários investimentos da ordem de R\$ 293 bilhões em 618 projetos de infraestrutura, o que possibilitará oportunidades para as indústrias de equipamentos deste segmento (MT, 2019).

Para Costa (2018) uma resposta rápida as necessidades dos clientes são fundamentais para as organizações e fazer isso de forma eficiente, utilizando as novas tecnologias disponíveis para manter-se competitivo, é base para a quarta revolução industrial. E as técnicas de previsão de vendas utilizando algoritmos de *Machine Learning* podem ser um forte aliado, na busca de práticas aprimoradas de gestão de demanda que possibilite menores perdas para a organização.

Nesta perspectiva, estar preparado para as projeções incertas, no segmento de rolos compactadores de asfalto é particularmente relevante. Diante disso, o presente trabalho tem

como objetivo de aplicar um método de previsão de demanda, utilizando um modelo preditivo com *Machine Learning*. Considerando como estudo de caso uma indústria de médio porte, que está inserido nesta cadeia produtiva, com fornecimento de componentes para máquinas de compactação de asfalto. Os resultados desta análise servirão para reduzir as incertezas com uma melhor assertividade nas previsões de vendas.

O presente trabalho está estruturado em 5 capítulos, sendo o primeiro deles esta introdução, o segundo capítulo é uma revisão bibliográfica dos conceitos básicos de previsão de demanda, séries temporais, técnicas de *Machine Learning* e o algoritmo Prophet utilizado no modelo; o capítulo três apresenta a metodologia utilizada para desenvolvimento e obtenção dos resultados; o capítulo quatro apresenta a construção e os resultados da modelagem da previsão de vendas; e por último, o capítulo 5 apresenta a conclusão do presente estudo e faz considerações para a realização de trabalhos futuros sobre o tema.

## **2 PREVISÃO DE DEMANDA**

A previsão da demanda é um assunto tratado com muita atenção nas companhias e aceito como parte integral dos planos de negócios e tomadas de decisão. Este tipo de análise permite com que sejam dimensionados recursos necessários para produção com maior acurácia. Assim é possível concluir que a previsão de demanda é uma das bases do processo de planejamento (MINE, 2010).

De acordo com Florêncio (2016) existem diversos métodos para realizar a previsão de demanda. Estes métodos podem ser de abordagem quantitativa, utilizando modelos matemáticos para análise dos dados, ou qualitativas, em que a percepção de mercado dos especialistas é o que direciona os parâmetros da previsão de vendas.

### **2.1 Métodos Qualitativos**

Segundo Schrippe *at al.* (2015) os Métodos qualitativos são técnicas apoiadas em dados subjetivos, baseados no julgamento e na experiência das pessoas. Para Meneghini *at al.* (2018), são aplicados quando os dados históricos não são adequados ou escassos, como em ambientes onde existe introdução de novos produtos ou mudança na tecnologia, o que exige uma previsão com base na opinião e intuição humana.

Rossetto *at al.* (2011) salienta sobre a importância de se utilizar mais de uma técnica para incorporar mais variáveis nas tomadas de decisão e esta combinação pode reduzir os

erros de previsão e melhorar as estimativas de vendas. Dentre as técnicas qualitativas mais comuns, Scipioni (2015) destaca de maneira resumida as mais utilizadas:

- Método Delphi: trata-se de um modelo que busca o consenso de um grupo de especialistas, realizando um brainstorming a respeito do comportamento de determinada demanda (DIAS *at al.*, 2015).
- Júri de executivos: executivos a nível gerencial opinam sobre o comportamento do mercado para prever alguma variável não verificada.
- Força de vendas: são previsões compiladas de estimativas feitas periodicamente por membros da equipe de vendas da empresa.
- Pesquisa de mercado: é um modelo de avaliação do comportamento da demanda através do levantamento dos fatores mais relevantes que influenciam a preferência do consumidor final (ROSSETTO, 2011).
- Analogia Histórica: é feita a previsão de demanda para este novo produto com base na trajetória de um produto similar existente.

## 2.2 Métodos Quantitativos

Os métodos quantitativos são baseados em séries de dados históricas e por meio de análises são identificados padrões de comportamento para que estes sejam lançados em projeções futuras (CORÊA, CORÊA, 2012). Os métodos quantitativos podem ser divididos em dois blocos, métodos causais e séries temporais.

Modelos causais preveem a demanda tomando como base uma relação de causa e efeito entre as variáveis de demanda e cofatores que possam afetá-la. Esses métodos têm como característica aumentar o erro de predição por demandar previsões das variáveis independentes em tempos futuros, assumindo que as relações causais históricas se manterão no futuro (JUÁREZ *at al.*, 2016).

Para Scipioni (2015) a metodologia mais utilizada é a regressão linear, que por meio de uma equação linear há uma correlação de uma variável dependente a uma variável independente, logo, o que se quer prever é a variável dependente e esta sofre influência da independente, determinada na função da reta  $Y = a + bX$ , sendo Y a variável dependente, X a independente, a é a interação da linha do eixo Y e b é a inclinação da linha.

Já as séries temporais são caracterizadas por utilizar um conjunto de dados históricos, ordenados no tempo que compartilham um comportamento de dependência entre si. Assim, um modelo de série temporal pressupõe que a demanda histórica pode ser usada para prever a

demanda futura, utilizando métodos estatísticos para identificar padrões do comportamento das séries históricas (WALTER *at al.*, 2013).

Para Machado *at al.* (2016) os métodos de decomposição das séries temporais são indicados para previsões de médio e curto prazo, e possui três padrões: tendência, sazonalidade e ciclo. A tendência ocorre quando a demanda cresce ou diminui ao longo do tempo. Tendência existe quando há um acréscimo ou decréscimo em longo prazo no nível da série. A sazonalidade ocorre quando a série é influenciada por um período de tempo fixado. O ciclo geralmente apresenta períodos maiores que a sazonalidade e ocorre quando os dados exibem variações crescentes ou decrescentes em períodos não fixados.

Segundo Corrar e Theophilo (2004), as series temporais são classificadas de acordo com a estacionariedade. São classificadas como series estacionarias, quando o movimento da tendência na reta não é significativo e podem ser analisados pela média móvel, média móvel ponderada ou ainda suavização exponencial. Quando a tendência se apresenta significativa a oscilação da demanda, as séries são não estacionárias, sendo utilizada a tendência linear e o método de Holt.

### 2.3 Erros de Previsão

Todos os modelos de previsão têm uma incerteza associada e para tal é necessária à mensuração, que pode ser executada por diferentes índices que medem as incertezas de previsão. As incertezas devem ser medidas, explicitadas e avaliadas (PEINADO; GRAEML, 2009), por exemplo, o MPE (Mean Percentual Error – Erro Percentual Médio), de acordo com Silva (2008), é o indicador mais utilizado e mais preciso, pois possibilita verificar se a demanda prevista está acima ou abaixo da demanda real. O MPE é dado pela Equação 1:

$$MPE = \frac{1}{n} \sum_{t=1}^n \frac{Dt - Pt}{Dt} \quad \text{Eq. 1}$$

Quanto ao teste de significância estatística, para Barlas (1996) um modelo é estatisticamente significativo e válido quando a Taxa de Erro for inferior a 5%. A porcentagem de Erro ( $E_1$ ) é definida por meio da Equação 2, 3 e 4 em que  $\bar{S}$  representa a média do resultado da simulação e  $\bar{A}$  representa a média do dado histórico.

$$E_1 = \frac{|\bar{S} - \bar{A}|}{\bar{A}} \quad \text{Eq. 2}$$

Onde

$$\bar{S} = \frac{1}{N} \sum_{i=1}^N S_i \quad \text{Eq. 3}$$

$$\bar{A} = \frac{1}{N} \sum_{i=1}^N A_i \quad \text{Eq. 4}$$

## 2.4 Machine Learning

De acordo com Constantino e Garcia (2018), quatro estatísticos foram os pioneiros nos trabalhos relacionados a Machine Learning (BREIMAN *et al.* 1984) que publicaram um livro sobre *Classification and Regression Trees* em meados de 1980, e ao longo dos anos 1970 e 1980 um pesquisador de Machine Learning, J. Ross estava desenvolvendo um sistema para inferir árvores de classificação através de exemplos.

Machine Learning é um campo da ciência da computação que permite dar aos computadores a habilidade de aprender sem que sejam explicitamente programados para isso. Machine Learning ou Aprendizado de Máquina é um método de análise de dados que automatiza o desenvolvimento de modelos analíticos. Usando algoritmos que aprendem a partir de dados, o aprendizado de máquina permite que os computadores encontrem insights ocultos sem que seja explicitamente programado para procurar algo específico (MEHENDALE; SHERIN, 2018).

A aprendizagem, de acordo com Vasconcelos (2017), pode ser dividida em aprendizagem supervisionada e a aprendizagem não supervisionada. Aprendizado supervisionado utiliza um agente externo, denominado supervisor ou professor, que indica à rede a resposta desejada para o padrão de entrada. No Aprendizado Não Supervisionado não existe um agente externo indicando a resposta desejada para os padrões de entrada.

Machine Learning é definido como um ramo da estatística e da computação que reúne uma série de métodos que possuem dois objetivos principais. O primeiro é o desempenho preditivo de modelos e o segundo é automatizar o processo de modelagem das bases de dados observados ou aprendizado com os dados observados.

No que se refere ao desempenho preditivo dos modelos, a acurácia das estimativas ou previsões das estimativas ou previsões é um aspecto importante. Nesse sentido, uma parte importante da literatura de Machine Learning se dedica a reduzir a variância das estimativas ou a parcela redutível da variância das estimativas. A parcela não redutível da variância não

pode ser trabalhada, por exemplo, devido à omissão de variáveis do modelo (Vasconcelos, 2017).

Segundo Bontempi *at all.* (2013) o aprendizado de máquina e os grandes volumes de dados estão trazendo mudanças de paradigma no desenvolvimento de um melhor modelo de previsão. Pois essa técnica possibilita analisar enormes quantidades de dados e fornecer informações instantâneas que podem melhorar a performance de tomada de decisões nos negócios.

No contexto da previsão de vendas Erhard e Bug (2016) aponta que a análise preditiva com os seus vários tipos de modelos está no centro das atenções. O modelo preditivo por sua vez, é construído por um processo de aprendizagem de máquina de computador automatizado utilizando dados históricos (SIEGEL, 2013). A seguir, os tipos mais comuns de modelos preditivos serão descritos:

- Lógica Fuzzy modelam dados não lineares e incompletos. É baseada em regras linguísticas, o conhecimento humano e, conseqüentemente, as influências complexas de variáveis explicativas sobre as vendas podem ser incluídas. Usando o conhecimento especializado e aprendizagem de máquina o modelo é capaz de reproduzir automaticamente a abordagem especialista ao realizar previsões intuitivas (THOMASSEY, 2010).
- As Máquinas de suporte vetorial elaborado por Vapnik em 1995, fundamentada em aprendizagem estatística, estabelecem princípios que deverão ser seguidos para se atingir uma boa generalização na classificação de dados pertencentes a classes distintas (SILVA, 2014).
- Árvores de decisão estão entre as técnicas de modelagem preditivas mais populares, quando se trata de árvore de decisão. Todas as árvores podem ser lidas como uma série de regras “*If-Then-Else*” que acabará por gerar um valor preditivo em termos da atribuição a uma determinada categoria usando um algoritmo de segmentação (ABBOTT, 2014).
- O agrupamento é uma técnica de extração de dados proeminente em que os itens com atributos semelhantes são agrupados em conjunto, a fim de revelar a estrutura dos dados. Além disso, agrupamento de dados ajuda a identificar, aprender ou prever a natureza de novos itens de dados utilizando algoritmos agrupamento como K-means ou K-nearest (BARI et al., 2014).
- De acordo com Penpece e Elma (2014) rede neural artificial (ANN) pode ser definida como uma matriz altamente ligada de processadores elementares, chamadas neurónios, geralmente definido como uma rede composta por um grande

número de processadores simples (neurónios) que estão interligados massivamente opera em paralelo, e aprender a partir da experiência.

## 2.5 Facebook Prophet

Prophet é um algoritmo de previsões *open source* do Facebook que foi disponibilizada para o público em 2017, tanto em Python como em R. O Prophet foi criado com o intuito de facilitar a tarefa de fazer previsões, gerando valores mais assertivos. Por esse motivo, é prático para treinar um modelo e criar previsões a partir dele com essa ferramenta (TAYLOR; LETHAM, 2017).

De acordo com Taylor e Letham (2017), o Prophet trabalha com séries temporais decompostas em tendências, sazonalidade e datas especiais. O somatório destas previsões decompostas representa a previsão completa realizada pelo algoritmo. O procedimento do *Prophet* possui previsões customizáveis e são feitas de forma intuitiva.

Este algoritmo foi concebido para facilitar a tarefa de forecasting que é extremamente complexa tanto para máquinas quanto para experientes cientistas de dados. O Prophet foi otimizado para realizar previsões na área de negócios, tomando como base as tarefas encontradas no Facebook, que possuem as seguintes características:

- Observações horárias, diárias ou semanais com pelo menos alguns meses ou anos de base histórica.
- Sazonalidades presentes: dia da semana e tempo do ano.
- Feriados importantes que são previamente conhecidos, como campeonatos de futebol.
- Um número razoável de informações faltantes e outliers.
- Mudança de comportamento histórica, como quebra de uma companhia ou lançamento de um produto.
- Tendências que não são lineares, onde a tendência atinge um limite natural ou um ponto de saturação.

O *Prophet* é um procedimento para prever dados de séries temporais com base em um modelo aditivo no qual tendências não lineares se ajustam à sazonalidade anual, semanal e diária, além de efeitos de férias. É mais bem aplicado em séries temporais com efeitos sazonais fortes e várias temporadas de dados históricos. É robusto para a falta de dados e mudanças na tendência e normalmente lida bem com discrepantes. (TAYLOR; LETHAM, 2017).



### 3 METODOLOGIA

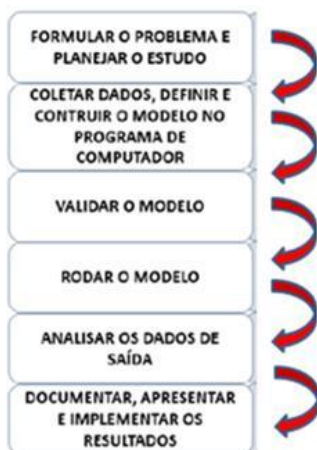
A metodologia de pesquisa serve para geração de conhecimentos válidos na medida em que indicam um caminho a ser seguido (LAKATOS; MARCONI, 1991). De acordo com Silva e Menezes (2005), a pesquisa deve ser apresentada seguindo dois aspectos: a caracterização do tipo de pesquisa e a descrição das etapas, técnicas e ferramentas que o autor irá utilizar para atingir os seus objetivos.

Quanto à natureza de pesquisa e a classificação conforme Silva e Menezes (2005), o presente trabalho se caracteriza como pesquisa aplicada, pois visa aplicar as técnicas de Machine Learning em uma empresa de médio porte, para melhorar a programação da produção, através de uma abordagem quantitativa, pois requer o uso de métodos e técnicas estatísticas. Portanto o processo analisado é o ambiente natural e a fonte direta para a coleta de dados, onde serão analisados indutivamente (SILVA e MENEZES, 2005).

Quanto ao objetivo da pesquisa, o presente trabalho classifica-se como uma pesquisa prescritiva, pois visa propor soluções e respostas para o problema apresentado (GIL, 2008; SILVA; MENEZES, 2005; YIN, 2001). Para caracterização do método de trabalho quanto aos procedimentos o presente trabalho se caracteriza como estudo de caso, pois pretende ter um caráter de profundidade e detalhado da utilização de Machine Learning para previsão de vendas (Gil, 2008).

De acordo com os objetivos, a presente pesquisa foi delineada nas etapas, resumida na Figura 1. Neste trabalho optou-se por utilizar o método proposto por Law e Kelton (1991) para a construção da modelagem. Os autores apresentam uma série de passos, os quais são apresentados a seguir.

Figura 1 - Etapas do Método de Trabalho

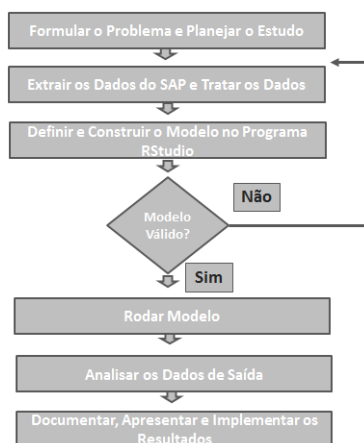


Fonte: Adaptado de Law e Kelton (1991)

### 3.1 Método de Trabalho

Para alcançar os objetivos traçados previamente, deve-se determinar a sequência de passos necessários para a construção do modelo (DRESH, LACERDA, ANTUNES JR, 2015). Com o método escolhido para a condução do modelo, segue o detalhamento de cada etapa do modelo.

Figura 2 - Etapas do Método de Trabalho



Fonte: Elaborado pelo autor (2019)

A primeira etapa deve-se esclarecer o contexto do problema e definir os objetivos do sistema. Neste contexto foi considerada pela organização a necessidade de um método mais aprimorado de previsão de demanda para produtos onde os clientes não estabelecem um horizonte de previsão de demanda, onde o gestor de Planejamento e Controle de Produção (PCP) que normalmente realiza as previsões com base nos históricos de vendas, em sua experiência e observação do mercado.

Nesta etapa foi realizado um breve estudo sobre as técnicas de Machine Learning e o quanto estas novas tecnologias podem auxiliar os gestores nas tomadas de decisões. Identificou-se nesta pesquisa a possibilidade de utilizar o algoritmo Facebook Prophet, que apresenta como um de seus principais benefícios à previsão de demanda de séries temporais. A partir deste ponto, formularam-se os objetivos da pesquisa e o problema a ser resolvido.

Na segunda etapa é realizada a coleta dos dados, onde é extraída do ERP a série histórica de venda do produto escolhido, ocorridas no período de 26 de setembro de 2011 a 26 de maio de 2019. Em seguida, as informações foram tratadas no Excel, retirando os dados sem importância ao modelo (Número da Ordem de Produção, código do produto, descrições, etc), deixando apenas as datas e quantidades de vendas, que são os dados necessários ao modelo, cumprindo com a etapa de carregamento.

Esta etapa também aborda a definição e construção do modelo, a qual iniciou com a definição do algoritmo de Machine Learning a ser utilizada e a busca por seus conceitos e aplicações. Esta busca foi realizada na fundamentação teórica na seção 2.4, em artigos, dissertações, a fim de compreender como utilizar a ferramenta.

Em seguida foi determinado o software a ser utilizado que, de acordo com Law e Kelton (1991), deve-se considerar a facilidade de acesso e o conhecimento para utilização da ferramenta. Para a presente pesquisa optou-se por utilizar o software R, pois o mesmo apresenta versão gratuita e há diversos estudos disponíveis que foram utilizados de apoio para esta pesquisa. Em sequência, o modelo foi construído de acordo com as especificações do software.

Foi realizada no software R a transformação dos dados diários em mensais e de acordo com Taylor e Letham (2017) para utilizar o algoritmo Prophet à base precisa estar dividida em duas colunas, *ds* e *y*. A coluna *ds* é relativa à linha temporal, ou seja, as datas. Estas datas precisam seguir o formato de MM/DD/AAAA, este formato de data significa mês, dia e ano. Já a coluna *y* deve conter os valores da demanda real para ser realizada a previsão.

A próxima etapa é a validação do modelo, que tem a finalidade de encontrar possíveis inconsistências e bugs e corrigi-los, se necessário. De acordo com Zumel Mount (2014), ao construir um modelo, é preciso verificar com dados de teste, se o mesmo funciona. Para validação do modelo será extraído o período de 26 de setembro de 2011 a 28 de maio de 2018 dos dados históricos para realizar o treino do modelo e os dados históricos de junho 2018 a maio de 2019 para dados de teste, com isso validar o modelo de previsão. Considerando como um modelo válido, quando a Taxa de Erro ( $E_1$ ) for inferior a 5%, de acordo com Barlas (1996) e para esta pesquisa foi determinado  $\pm 10\%$  de Erro Percentual Médio (MEP).

Nas etapas de número quatro e cinco, o modelo validado foi utilizado no R com as transações de venda do produto analisado, ao qual o algoritmo Prophet foi aplicado para gerar as previsões sazonais. A etapa de análise dos dados, objetiva dar sentido ao conjunto de informações abordadas. (DRESCH; LACERDA; ANTUNES JR, 2015).

A última etapa proposta por Law e Kelton (1991) consiste em apresentar os resultados obtidos por meio do modelo para que possam auxiliar na tomada de decisão e implementação. Os autores recomendam que a modelagem seja documentada para possíveis utilizações futuras. O presente trabalho foi documentado em forma de artigo e apresentado à banca avaliadora como trabalho de conclusão do curso. Também foi realizada a apresentação do modelo a gerência da empresa, como método alternativo de previsão de demanda.

## 4 CONSTRUÇÃO DO MODELO

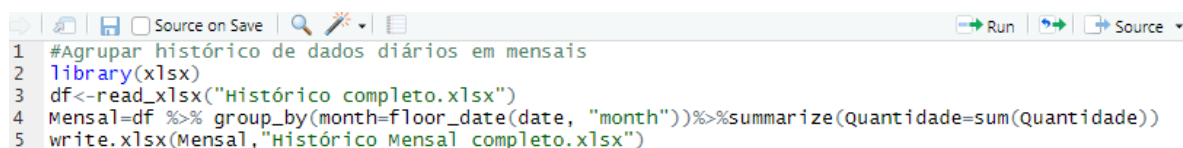
Para construção do modelo foi definida pela direção da empresa o produto em que seria realizado este estudo. A escolha do Shassi do Rolo Compactador de asfalto se dá pelo motivo de ser um produto estratégico para empresa, em nível de faturamento, por passar em processos gargalos e por não receber um horizonte de previsão do cliente.

Para alcançar os objetivos do trabalho, buscaram-se artigos referentes a métodos tradicionais de previsão de demanda e métodos alternativos utilizando técnicas com *Machine Learning*. Nesta busca observou-se que o algoritmo *Prophet* é um procedimento utilizado para prever dados de séries temporais e possui muitas possibilidades para os usuários ajustarem suas previsões, mesmo com pouco conhecimento na área. Por esse motivo, esta técnica surge como alternativa aos métodos de previsão de demanda utilizados na Companhia.

Após realizar os estudos, coletou-se a série de dados históricos do produto, no período de 26 de setembro de 2011 a 26 de maio de 2019. Estas informações foram retiradas do ERP da Empresa (SAP), exportadas no formato *xlsx*. Foi realizado o tratamento do *dataset*, ficando apenas as colunas Data de Lançamento e Quantidade. Na coluna quantidade, os valores vieram com números negativos, portanto foi preciso retirar o caractere “-” com a função do Excel “TEXTO PARA COLUNA”.

Para desenvolver o modelo foi definida a utilização do software R e para realizar a previsão dos dados históricos optou-se pelo algoritmo *Prophet*, por sua facilidade de implementação e acurácia alta em previsões de tendência e sazonal. Porém antes de realizar o modelo utilizou-se o R para transformar a série de dados diários em mensais, conforme mostrado na Figura 3.

Figura 3 – Preparação dos Dados no R



```
1 #Agrupar histórico de dados diários em mensais
2 library(xlsx)
3 df<-read_xlsx("Histórico completo.xlsx")
4 Mensal=df %>% group_by(month=floor_date(date, "month"))%>%summarize(Quantidade=sum(Quantidade))
5 write.xlsx(Mensal,"Histórico Mensal completo.xlsx")
```

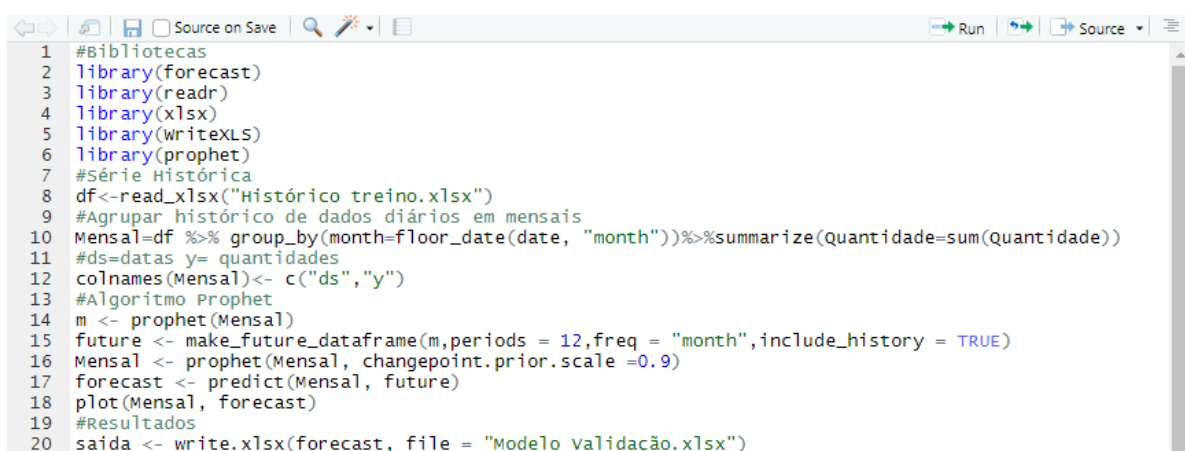
Fonte: Elaborado Pelo Autor (2019)

Para realizar a etapa de validação do modelo foi retirado da planilha o período de junho de 2018 a maio de 2019 (15%) para dados de teste, e o período de setembro de 2011 a maio de 2018 (85%) para dados de treino, criando assim outra planilha, renomeada como “Histórico Treino”. Para completar esta etapa foi aplicado no R o algoritmo de Machine

Learning Facebook Prophet para realizar a previsão das demandas, referente aos meses de teste (junho 2018 – maio 2019), de acordo com as especificações do algoritmo.

Para que o software importe os dados e o R explore as transações para entregar os resultados alguns comandos foram necessários. Portanto, o modelo foi construído na forma destes comandos, que são os passos necessários para obter as previsões de demanda. Dessa forma, o modelo construído no software é apresentado na Figura 4.

Figura 4 – Modelo Validação



```
1 #Bibliotecas
2 library(forecast)
3 library(readr)
4 library(xlsx)
5 library(writexLS)
6 library(prophet)
7 #Série Histórica
8 df<-read_xlsx("Histórico treino.xlsx")
9 #Agrupar histórico de dados diários em mensais
10 Mensal=df %>% group_by(month=floor_date(date, "month"))%>%summarize(Quantidade=sum(Quantidade))
11 #ds=datas y= quantidades
12 colnames(Mensal)<- c("ds","y")
13 #Algoritmo Prophet
14 m <- prophet(Mensal)
15 future <- make_future_dataframe(m,periods = 12,freq = "month",include_history = TRUE)
16 Mensal <- prophet(Mensal, changepoint.prior.scale = 0.9)
17 forecast <- predict(Mensal, future)
18 plot(Mensal, forecast)
19 #Resultados
20 saida <- write.xlsx(forecast, file = "Modelo validação.xlsx")
```

Fonte: Elaborado Pelo Autor (2019)


Após executar o modelo para validação e aplicado os métodos de medição do erro proposto na metodologia, a Taxa de Erro ( $E_1$ ) ficou em 2,91%, considerado válido pelo método de Barlas (1996), modelos com Taxa de erro inferior a 5%. O MEP ficou em -7%, dentro do esperado para ser quantitativamente válido, pois apresentou valor dentro da faixa de  $\pm 10\%$ , conforme proposto na metodologia deste artigo.

Para melhorar a acurácia do modelo, foi aplicado o ajuste da flexibilidade da tendência, realizando durante os testes do modelo o ajuste da função “*changepoint\_prior\_scale*” o modelo foi ajustado com parâmetro 0,9. De acordo com Taylor e Letham (2017) este parâmetro está definido, por padrão, com 0,05 e quanto maior for este valor, maior será a flexibilidade da tendência.

A Figura 5 representa a aplicações do *Prophet* na série temporal recolhida do produto selecionado. A linha azul do gráfico representa a previsão feita pelo algoritmo. Os pontos pretos marcados no gráfico representam o valor real da demanda ao longo do tempo. O eixo chamado de *y* é a escala dos valores, absolutos, da previsão. Já o eixo chamado de *ds* contém

a linha do tempo das previsões e dos valores reais. A área azulada que acompanha a linha representa os valores mínimos e máximos potenciais para a demanda.

Figura 5 – Previsão do Algoritmo Prophet



Fonte: Elaborado Pelo Autor (2019)

A próxima etapa é a utilização do modelo válido para realizar a projeção futura. Para isso, um segundo modelo foi criado, utilizado a mesma série histórica, porém ao contrário do modelo de validação que projetou até o período de maio de 2019, o modelo foi realizado para testar a demanda real, ocorrida de junho 2019 até novembro de 2019. Para realizar esta projeção foi necessário alterar de 12 para 18 meses de previsão na função “*periods*”, conforme Figura 6.

Figura 6 – Previsão Futura do Algoritmo Prophet

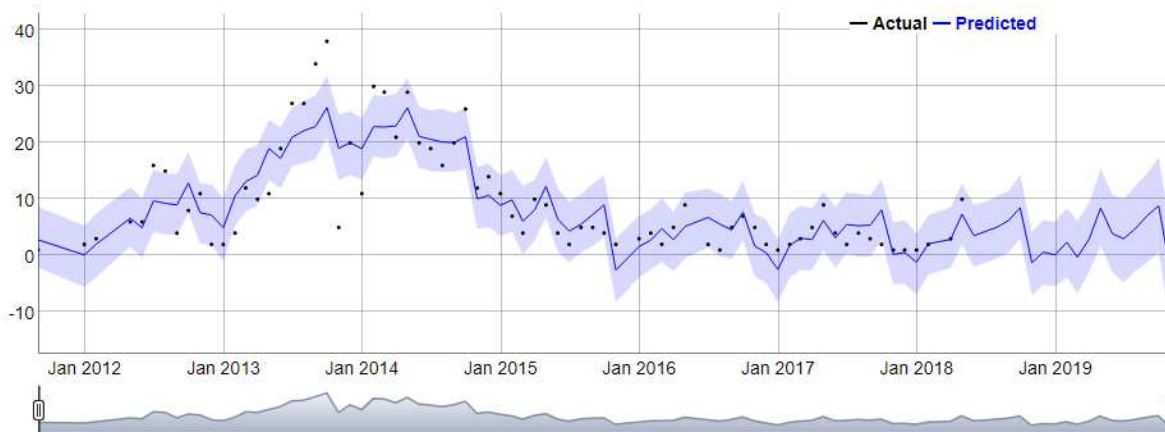
```
15 future <- make_future_dataframe(m, periods = 18, freq = "month", include_history = TRUE)
```

Fonte: Elaborado Pelo Autor (2019)

Após realizar a alteração, o modelo foi executado para gerar a previsão da demanda. Os valores entregues pelo *Prophet* foram exportados para Excel, para serem analisados com os dados reais no decorrer dos meses. Após os pedidos de compra ser firmados, os valores até outubro foram inseridos na planilha para medir a acurácia deste método. O *Prophet* fornece um quadro de dados (Tabela 1) com uma coluna *ds* contendo as datas para as quais as

previsões foram feitas, até o final do período inserido na função “*make\_future\_dataframe*”, para este modelo são considerados 18 meses. Estes dados podem ser visualizados no gráfico interativo utilizando a função “*dyplot.prophet*” conforme mostra a Figura 7.

Figura 7 – Previsão Futura do Algoritmo Prophet



Fonte: Elaborado Pelo Autor (2019)

A Tabela 1 apresenta os resultados previstos pelo modelo. Os valores de *trend* representa a tendência, *yhat* o valor previsto representado pela linha azul do gráfico, *yhat\_lower* e *yhat\_upper* representa os valores mínimos e máximos potenciais para a demanda e é representada na área azulada que acompanha a linha. Para facilitar a visualização dos resultados, foi inserida na tabela uma coluna para adicionar os dados reais.

Tabela 1 – Dados do Algoritmo Prophet e Demanda Real

	ds	yhat_lower	yhat_upper	trend_lower	trend_upper	yhat	trend	Real
74	01/06/2018	-1,817172132	9,189894061	4,120805314	4,157659058	3,534820691	4,144345845	4
75	01/07/2018	-1,397782191	10,05582664	3,96360573	4,308171999	4,27091363	4,14115666	2
76	01/08/2018	-0,328094471	10,70844124	3,759607945	4,503610769	5,045169299	4,13786117	6
77	01/09/2018	0,669272888	11,85652088	3,486578398	4,753556185	6,250658116	4,134565679	4
78	01/10/2018	2,440396315	13,96482883	3,13034489	5,078170526	8,493137854	4,131376494	3
79	01/11/2018	-6,45168496	4,659181857	2,819784978	5,469303006	-1,252469048	4,128081004	3
80	01/12/2018	-5,503150782	6,677628052	2,481639626	5,808519298	0,621080408	4,124891819	5
81	01/01/2019	-5,513505983	6,348239937	2,024481127	6,146793369	0,1476752	4,121596329	5
82	01/02/2019	-3,789497659	8,388454226	1,580942811	6,466779073	2,364125299	4,118300838	4
83	01/03/2019	-6,981873985	5,528788918	1,15768685	6,896211677	-0,260368595	4,115324266	5
84	01/04/2019	-3,632886065	9,390277997	0,628606394	7,314238333	2,9863267	4,112028775	4
85	01/05/2019	1,815940795	15,16241513	0,120800154	7,78772794	8,453151818	4,108839591	6
86	01/06/2019	-3,154051005	10,63225424	-0,4690837	8,312987344	3,891870134	4,1055441	6
87	01/07/2019	-4,674841865	10,43806656	-0,886829247	8,850221772	3,005817701	4,102354915	6
88	01/08/2019	-3,13240948	12,73365369	-1,447758754	9,395837039	4,815502685	4,099059425	3
89	01/09/2019	-0,73865867	15,13013624	-2,107479419	9,962511016	7,108523287	4,095763934	3
90	01/10/2019	0,257959678	17,36279271	-2,588764978	10,48754446	8,842088673	4,09257475	3
91	01/11/2019	-11,63920499	5,838228021	-3,277643256	11,11056538	-2,720007783	4,089279259	

Fonte: Elaborado Pelo Autor (2019)

A Tabela 2 apresenta o resultado dos cálculos de incerteza para os três períodos analisados no trabalho.

Tabela 2 – Cálculo Erro Médio e MEP, Prophet x Real

ds	yhat_lower	yhat_upper	trend_lower	trend_upper	yhat	trend	Real
Média Período 1 06/18 a 05/19	-2,54	9,33	2,44	5,72	3,39	4,13	4,25
Erro Médio	160,3%	119,9%	42,7%	34,8%	20,4%	2,9%	
MEP	162,8%	-141,4%	31,7%	-43,0%	11,0%	-6,6%	
Média Período 2 06/19 a 11/19	-3,85	12,02	-1,80	9,69	4,16	4,10	4,20
Erro Médio	191,6%	186,3%	142,8%	130,6%	1,0%	2,4%	
MEP	125,2%	-226,5%	121,2%	-130,2%	-25,6%	-7,7%	
Média Período 3 06/18 a 11/19	-2,98	10,23	1,03	7,05	3,64	4,12	4,24
Erro Médio	170,3%	141,4%	75,7%	66,3%	14,0%	2,8%	
MEP	150,2%	-169,7%	61,5%	-108,1%	-9,8%	-7,0%	


Fonte: Elaborado Pelo Autor (2019)

Na Tabela 2 observam-se os resultados dos cálculos de Erro Médio e MEP nos três períodos analisados. O valor de 2,9 % do Período 1 corresponde aos meses utilizados para validar o modelo (junho 2018 – maio 2019), o Período 2 corresponde aos meses da aplicação do modelo (julho 2019 – outubro 2019) com valor de 2,4 % de Taxa de Erro ficou dentro da faixa esperada. Também foi medido a acuracidade de todo o período de previsão realizado pelo *Prophet* (Junho 2018 – outubro 2019) e o resultado de 2,8 % de Taxa de erro e MEP de -7% entende-se que o modelo de previsão pode ser aceito.

Estes resultados são benéficos aos gestores de Planejamento e Controle de Produção (PCP), pois além de auxiliar nas tomadas de decisão, os resultados desta técnica amparam com assertividade as projeções de demandas futuras em dois aspectos. O primeiro é que este modelo preditivo teve resultados satisfatórios mesmo com quantidades pequenas de produção. O segundo ponto é a pequena janela de projeção futura, mesmo com um período curto de análise, o resultado de junho a outubro (2,4 %) foi satisfatório para a pesquisa.



Figura 8 – Prophet x Demanda Real (Período 3)



Fonte: Elaborado Pelo Autor (2019)

É possível observar na Figura 8 que o comportamento da demanda ficou dentro do grau de incerteza (limites mínimo e máximo da demanda prevista) representada por *yhat\_lower* e *yhat\_upper*. É possível observar que os valores de *trend* acompanha o comportamento da Demanda Real em toda a sua extensão. Outro dado importante fornecido pelo Prophet são os da *trend\_lower* e *trend\_upper*, em que mostra duas projeções futuras, interpretando como tendência otimista e outra pessimista.

Este método surge como forte aliado aos tomadores de decisão, pois possibilita, além da assertividade das previsões, visualizar cenários de possibilidades, sempre com limites projetados pelo algoritmo de Machine Learning. A Figura 8, o resultado de *trend\_upper* mostra que a demanda tende a crescer nos períodos subsequentes e o Valor médio para esta projeção foi de 7,05 peças até o final do período projetado. Com esses dados o observador pode prepara os recursos e investimentos necessários para atender esta demanda, minimizando os riscos de falta de capacidade para atender o cliente, considerando um mercado aquecido.

Da mesma forma o valor entregue pela técnica de *Machine Learning*, para um cenário pessimista, ajuda a visualizar o quanto a demanda do produto em estudo pode cair no período projetado, aonde *trend\_lower* chegando a um valor médio de 1,03 peças. Com esse cenário o gestor prepara seus recursos entendendo que a linha não para, mas sofre uma baixa

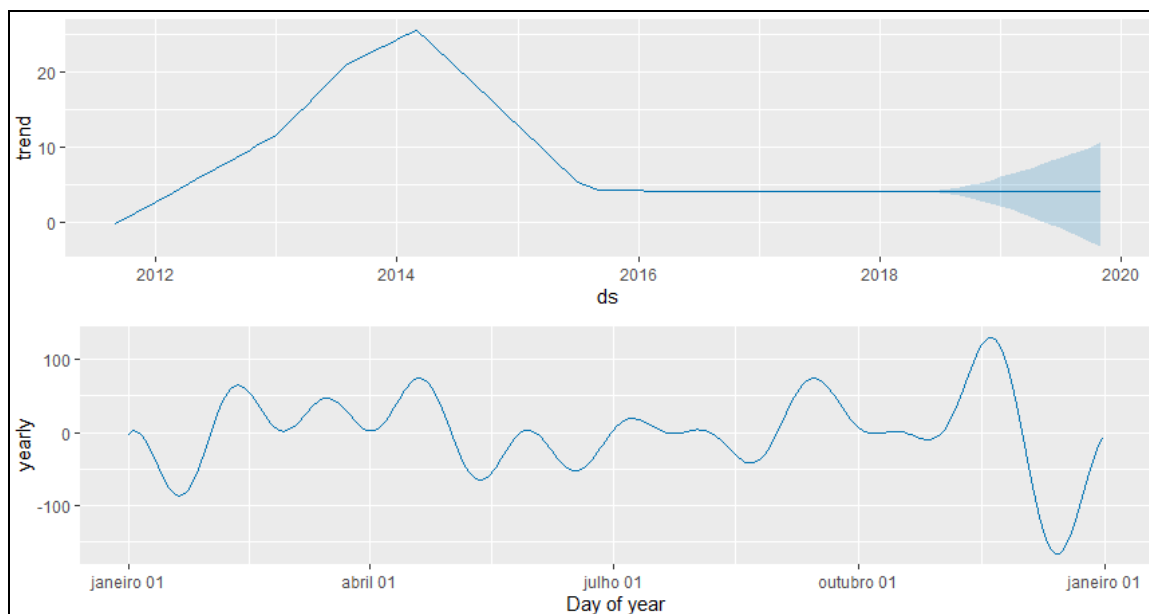
significativa. Cabe ao gestor neste cenário, controlar seus investimentos e tomar decisões cautelosas, garantindo menores perdas para companhia.

Ao utilizar a função “*Prophet.plot\_components*” e plotar para o gráfico os componentes da previsão, a Figura 9 mostra a tendência e a sazonalidade anual da série temporal, ferramenta que fornece insights sobre o problema da previsão realizada, onde evidencia que a série temporal sofre uma mudança brusca em suas trajetórias. Por padrão, o *Prophet* detecta automaticamente esses pontos de mudança e permite que a tendência se adapte adequadamente, mas para ter um ajuste mais refinado foi utilizado o argumento de entrada “*changeoint\_prior\_scale*” com ajuste 0,9 para aumentar assim, a flexibilidade da tendência.

Com esta análise pode ser observado na Figura 9 que a série histórica do produto teve um crescimento a partir do seu início até setembro de 2013. Após isso, o produto teve uma forte queda e se estabilizou, com poucas oscilações até maio de 2019 e no final do gráfico, mostra uma forte tendência em aumentar ou diminuir a demanda. Este mesmo gráfico apresenta, na parte inferior, a sazonalidade anual da previsão realizada, onde a série temporal apresenta um comportamento instável em determinados períodos do ano, e caem drasticamente entre os meses de dezembro a fevereiro.

É importante analisar esse gráfico (Figura 9), pois apresenta ao tomador de decisão a intuição de que após a tendência de um mercado estável há possibilidade de um novo ciclo sazonal na demanda, conceito fundamentado por Taylor e Letham (2017), que afirmam que o *Prophet* analisa séries históricas para realizar as previsões, onde as flutuações da demanda tendem a se repetir no futuro.

Figura 9 – Sazonalidade anual e mensal



Fonte: Elaborado Pelo Autor (2019)

O *Prophet* é um algoritmo que faz as projeções futuras, com base no comportamento da demanda ocorrido no passado, portanto o modelo precisa ser atualizado constantemente com as demandas realizadas. Isso possibilita ao algoritmo constante aprendizado no que tange ao comportamento da demanda. Na próxima seção é sugerido as frequências de atualização do modelo e as considerações finais.

## 5 CONCLUSÃO E CONSIDERAÇÕES FINAIS

Neste artigo foi proposto como objetivo, um método de previsão de demanda utilizando um modelo preditivo com Machine Learning, aplicando o algoritmo *Facebook Prophet*. Para testar sua efetividade, o mesmo foi aplicado com o auxílio do Software R, a análise da Série Temporal de um componente de máquina do ramo de Pavimentação de asfalto, utilizando como estudo de caso, uma empresa de médio porte. A previsão de demanda foi gerada para o período de junho de 2018 a julho 2019.

A utilização do Algoritmo *Prophet* foi possível após entendimento do documento de Taylor e Letham (2017) e as funções nele destacados. Foi realizado o ajuste da flexibilidade da tendência, e com isso foi, possível ter uma previsão futura, com intervalo de incerteza acompanhando o comportamento da demanda dos dados utilizados para treino.

O uso de *Machine Learning* em um componente de máquina de pavimentação de asfalto foi eficiente, pois foi capaz de analisar em poucos minutos um conjunto de dados e realizar as previsões com acuracidade dentro do esperado. Como resultado do ajuste, foi obtido um erro máximo de 2,8 % e MEP de -7% frente à demanda real e essa metodologia podem ser consideradas como uma ferramenta de apoio à decisão bem-sucedida para previsão de demanda. Esta métrica ampara aos gestores tomarem decisões mais assertivas frente às demandas insertas do mercado.

É importante destacar que para aumentar a precisão na previsão há a real necessidade de uma maior amostragem de dados. Deste modo sugere-se a atualização do modelo com as demandas reais no mínimo a cada 3 meses, e projeções futuras de no máximo 12 meses, pois com isso o algoritmo permanece em constante aprendizado e melhorando a acuracidade das previsões.

Como limitador desta metodologia está à ausência de componentes exógenos nos dados de entrada, como fatores que ocorrem no presente que podem influenciar a demanda no futuro, visto que o mercado de pavimentação de asfalto sofre com influências políticos, econômicos, infraestrutura, conservação e planejamento de projetos (FIESP, 2017). Em desdobramentos futuros sugere-se a adoção de métodos que permitam a utilização desses inputs, para análises e resultados mais aprofundados e precisos.

## REFERÊNCIAS

ABBOTT, Dean **Applied Predictive Analytics: Principles and Techniques for the Professional Data Analyst**, Indianapolis: John Wiley & Sons, 2014.

BARI, A., Chaouchi, M., e JUNG, T. **Predictive Analysis for the Laity**. New Jersey, 2014.

BARLAS, Yaman. **Formal aspects of model validity and validatio in system dynamics**. *System dynamics review*. V.12,n.3, p. 183-210, 1996.

BREIMAN, Leo; FRIEDMAN, J.H.; OLSHEN, R.A. e STONE, C.J.: **Classification of regression trees**. Wadsworth & Books /Cole Advanced Books & Software, Monterey, CA, 1984.

BONTEMPI, Gianluca. *At all*. **Machine Learning Strategies for Time Series Forecasting**. M.-A. Aufaure and E. Zimanyi (Eds.): eBISS 2012, LNBIP 138, pp. 62-77, 2013. Springer Verlag Berlin Heidelberg 2013

CORRAR, L.; THEOPHILO, C. **Pesquisa operacional para decisão em contabilidade e administração: contabilometria**. Sao Paulo: Editora Atlas, 2004.

CORRÊA, Henrique L.; CORRÊA, Carlos A. **Administração de Produção e de Operações**. Manufatura e serviços: uma abordagem estratégica. São Paulo: Atlas, 2012.

CONSTANTINO, Rafaela Flores Kuff; GARCIA, Ricardo Alexandre Martins. **Utilização do machine learning para tomada de decisões na gestão de marketing digital para turismo.** Revista Observatorio de la Economía Latinoamericana, 2018. Disponível em: <<https://www.eumed.net/rev/oel/2018/10/machine-learning-turismo.html> > Acesso em: Março de 2019.

COSTA, Daniel Fonseca. **Proposta de Um Modelo de Previsão do Resultado Para o Planejamento Tributário de Pequenas Empresas.** Artigo apresentado originalmente no XVI USP International Conference in Accounting. UEM - Paraná v. 37 n. 3 p. 93-110 setembro / dezembro 2018.

DIAS, Edimar Nunes. *et all.* **Previsão de Demanda: Uma Análise quantitativa baseada em séries temporais de uma empresa fabricante de portas.** Disponível em:< [http://www.fecilcam.br/anais/ix\\_eepa/data/uploads/1-engenharia-de-operacao-e-processos-da-producao/1-01.pdf](http://www.fecilcam.br/anais/ix_eepa/data/uploads/1-engenharia-de-operacao-e-processos-da-producao/1-01.pdf)>. Acesso em: 15 de março de 2015.

DORNELAS, RAISA CAROLINA. **Previsão de Vendas e Gestão da Demanda de Máquinas Agrícolas: proposta de uma abordagem baseada em redes neurais artificiais.** Dissertação de Mestrado – Faculdade de Ciências Aplicadas da Universidade Estadual de Campinas. São Paulo, 2017.

DRESCH, Aline; LACERDA, Daniel Pacheco; ANTUNES JR, José Antônio Valle. Design Science Research: **Método de pesquisa para avanço da ciência e tecnologia.** Porto Alegre: Bookman, 2015. Livro eletrônico.

ERHARD, Julia; BUG, Peter. **Application of Predictive Analytics to Sales Forecasting in Fashion Business -** Reutlingen University. Reutlingen, 2016

FLORÊNCIO, Paulo Henrique Borba. **Aplicação de Redes Neurais Artificiais na Previsão de Demanda de Peças de Reposição de Veículos Automotores.** 2016, 86f. Dissertação (Mestrado em Engenharia de Produção e Sistemas), Pontifícia Universidade Católica de Goiás, Goiás, 2016.

GIL, A. C. **Métodos e Técnicas de Pesquisa Social.** 6. ed. São Paulo: Ed. Atlas, 2008.

JUÁREZ, Arturo Contreras. **Análisis de series de tiempo en el pronóstico de la demanda de almacenamiento de productos perecederos.** V.32, Issue 141, October–December 2016, Pages 387-396

LAKATOS, E. M.; MARCONI, M. A. **Fundamentos da Metodologia Científica.** 3 ed. São Paulo: Atlas, 1991.

LAW, Averill M; KELTON, W. David. **Simulation Modeling and Analysis.** 2. ed. Singapore: McGraw- Hill, Inc., 1991.

MACHADO, Raphael Henrique Soares **Estudo comparativo de modelos clássicos e técnicas de combinação para a previsão do volume de captação de água para uso urbano – um estudo de caso,** ENCICLOPÉDIA BIOSFERA, Centro Científico Conhecer - Goiânia, v.13 n.23; p.1778-1793, 2016.

MARTIN, Amanda Caroline. **Análise de séries temporais para previsão da evolução do número de automóveis no Município de Joinville.** Espacios, v. 37 (Nº 06) Año 2016. P. 29.

MEHENDALE, Abhang; SHERIN, Nadheera. **Application of artificial intelligence (AI) to increase efficacy and adaptive sales forecast**. The Journal Research Gestão Contemporânea, 2018, V. 12, p., 17-35.

Meneghini, Mateus. **Ajuste de Previsão de Demanda Quantitativa Com Base em Fatores Qualitativos: estudo de caso em um restaurante fast food**. Sistemas & Gestão (2018), pp 68-80 V. 13, Número 1, 2018, p. 68-80.

MT, REVISTA MANUTENÇÃO E TECNOLOGIA. **Mercado de equipamentos para compactação de asfalto tem potencial de crescimento no Brasil**. Disponível em:<<http://www.revistamt.com.br/Noticias/Exibir/mercado-de-equipamentos-para-compactacao-de-asfalto-tem-potencial-de-crescimento-no-brasil>>. Acesso em: 6 de março de 2019.

MINE, Otávio Massashi. **Previsão de Demanda de Autopeças com Redes Neurais**. 2010, 225 f. Dissertação (Mestrado em Ciência da Computação), Universidade Federal do Espírito Santo, Vitória, 2010.

PEINADO, Jurandir; GRAEMEL, Alexandre R. **Administração da Produção: Operações Industriais e de Serviços**. Curitiba: UnicenP, 2007.

PENPECE, Dilek; ELMA, Orhan Emre. **Predicting Sales Revenue by Using Artificial Neural Network in Grocery Retailing Industry: A Case Study in Turkey** - International Journal of Trade, Economics and Finance, Vol. 5, No. 5, 2014 -DOI: 10.7763/IJTEF.2014.V5.411

Rossetto, Marta. **Técnicas Qualitativas de Previsão de Demanda: um Estudo Multicasos com Empresas do Ramo de Alimentos**. VIII SEGeT – Simpósio de Excelência em Gestão e Tecnologia – 2011

SCHRIPPE, Patrícia. **Estratégia Empresarial Para a Natura: análise de correlação e previsão dos lucros por meio do modelo holt-winters**. REUNA, Belo Horizonte - MG, Brasil, v.20, n.4, p.05-26, Out. – Dez. 2015.

SCIPIONI, Tâmis. . *et al.* **Previsão de Demanda de Três Produtos Fornecidos Por Um Distribuidor de Bebidas**. Revista Liberato, Novo Hamburgo, v. 16, n. 26, p. 101-220, jul./dez. 2015.

SLACK, Nigel; CHAMBERS, Stuart; JOHNSTON, Robert. **Administração da Produção**. 2. ed. São Paulo: Atlas, 2008.

SILVA, Edina, MENEZES, Eстера Muszakat, **Metodologia da Pesquisa e Elaboração de Dissertação**. 4. ed., Florianópolis: Laboratório de Ensino a Distância da UFSC, 2005.

SIEGEL, Eric, **Análise Preditiva: Predictive Analytics - The Power to Predict Who Will Click, Buy, Lie, or Die** r. New Jersey: John Wiley & Sons, 2013.

TAYLOR, Sean J.; LETHAM, Ben. **Forecasting at Scale**. The American Statistician, v. 72, n. 1, p. 37-45, set, 2017.

THOMASSEY, Sébastien. **Sales forecasts in clothing industry: The key success factor of the supply chain management.** International Journal of Production Economics. V. 128, ed.2, P. 470-483, 2010. 470-483. Disponível em: <<http://doi.org/10.1016/j.ijpe.2010.07.018>>

VASCONCELOS, Bruno Freitas Boynad de. **Poder preditivo de métodos de Machine Learning com processos de seleção de variáveis: uma aplicação às projeções de produto de países.** Tese de doutorado em Economia - Faculdade de Economia, Administração e Contabilidade. Brasília, 2017.

WALTER, Olga Maria Formigoni Carvalho. **Aplicação de um modelo SARIMA na previsão de vendas de motocicletas. Application of a SARIMA model in forecasting motorcycle sales.** Exacta – EP, São Paulo, v. 11, n. 1, p. 77-88, 2013.

YIN, Robert K. **Estudo de caso – Planejamento e Métodos**, 2ª edição, Porto Alegre: Bookman, 2001.

YOKOYAMA, T. T.; TAKEDA, S. L. **Proposta de aplicação de previsão de vendas de séries temporais para uma indústria metal-mecânica.** Revista Eletrônica de Tecnologia e Cultura, v. 14, p. 141-152, 2014.

ZUMEL, Nina; MOUNT, John. **Practical Data Science With R**. 2. ed. Shelter Island: Manning, 2014.