

**UNIVERSIDADE DO VALE DO RIO DOS SINOS - UNISINOS
UNIDADE ACADÊMICA DE PESQUISA E PÓS-GRADUAÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO E
SISTEMAS
NÍVEL MESTRADO**

ANDRES EBERHARD FRIEDL ACKERMANN

**MODELO DE PREVISÃO DE DEMANDA DO SERVIÇO DE URGÊNCIA EM UM
HOSPITAL DE PRONTO ATENDIMENTO**

São Leopoldo

2020

ANDRES EBERHARD FRIEDL ACKERMANN

**MODELO DE PREVISÃO DE DEMANDA DO SERVIÇO DE URGÊNCIA EM UM
HOSPITAL DE PRONTO ATENDIMENTO**

Dissertação apresentada como requisito parcial para obtenção do título de Mestre em Engenharia de Produção e Sistemas, pelo Programa de Pós-Graduação em Engenharia de Produção e Sistemas da Universidade do Vale do Rio dos Sinos - UNISINOS

Orientador: Prof. Dr. Miguel Afonso Sellitto

São Leopoldo

2020

A182m Ackermann, Andres Eberhard Friedl.
Modelo de previsão de demanda do serviço de urgência
em um hospital de pronto atendimento / por Andres
Eberhard Friedl Ackermann. – 2020.
108 f. : il. ; 30 cm.

Dissertação (mestrado) — Universidade do Vale do Rio
dos Sinos, Programa de Pós-Graduação em Engenharia de
Produção e Sistemas, São Leopoldo, RS, 2020.

“Orientador: Dr. Miguel Afonso Sellitto”.

1. Previsão de demanda. 2. Métodos de previsão de
demanda. 3. ARIMA. 4. Mapa logístico. 5. Departamento de
emergência. 6. Serviço de saúde - Qualidade. I. Título.

CDU: 658.5:64.024.8

AGRADECIMENTOS

Agradeço primeiramente a Deus por renovar minha vontade, coragem e dedicação no transcorrer desta pesquisa, mantendo a minha fé e perseverança em todos os momentos desta jornada.

Obrigado a minha esposa Gabriele Neis pelo amor, compreensão e pelos diversos momentos de apoio, incentivo e de motivação ao longo da conquista desse sonho.

Agradeço aos meus pais Elizete e Wolf pela educação, cultura, valores e exemplos transmitidos a mim, e pelo apoio, incentivo e compreensão neste ciclo de formação acadêmica e profissional. Dedico a vocês meu mais sincero muito obrigada, pois sem vocês esta conquista não seria possível!

Agradeço também as minhas irmãs Vanessa e Rodaica que são minhas raízes e minhas fontes de carinho a me fortalecer e olhar por mim. Aos meus cunhados, amigos e companheiros de caminhada dedico minha gratidão de tê-los em minha vida, saibam que a amizade é algo que nos une, fortalece e nos torna pessoas melhores.

Agradeço ao meu mestre, professor e orientador Dr. Miguel Afonso Sellitto por me guiar ao longo do programa de mestrado, depositando em mim sua confiança, experiência e muitos dos seus conhecimentos, que levarei durante minha trajetória acadêmica e profissional.

Agradeço ao corpo docente do PPGEPS/UNISINOS pelos grandiosos e profundos ensinamentos repassados, em especial, ao professor Dr. André Luis Korzenowski, à coordenação do curso, representada pelo professor Dr. Luiz Alberto Oliveira Rocha e à secretária Tana Cassia Malacarne Martins.

Agradeço os meus colegas do PPGEPS/UNISINOS, em especial ao Davenilcio Luiz de Souza e ao João Henrique Sperafico, pela amizade construída e pela troca de conhecimento.

Obrigado a todos!

RESUMO

Neste trabalho foi abordado o tema da previsão de demanda do serviço de urgência em departamento de emergência. O objetivo de pesquisa foi propor um modelo de previsão de demanda para consultas de urgência. Composto por dois artigos acadêmicos, o primeiro artigo é uma revisão sistemática da literatura dos métodos de previsão de demanda com o propósito de reunir os métodos e modelos disponíveis acerca dos conceitos utilizados atualmente na administração de empresas relacionados ao consumo e produção de produtos e serviços. A metodologia utilizada é a revisão sistemática da literatura com abordagem qualitativa com o propósito de dar uma visão geral dos métodos dominantes utilizados em previsão de demanda. Foi realizado o mapeamento da literatura para identificar o estado da ciência por meio da produção científica disponível. Os métodos qualitativos e causais demonstram adaptar-se melhor às previsões de médio e longo prazos, enquanto a análise de séries temporais indica se adequar mais a previsões de curto prazo. O segundo artigo propõe um modelo para prever o número de atendimentos diários em um hospital de pronto atendimento. Foram utilizados os dados de um período de 66 meses de um Pronto Atendimento e Hospital Dia privado localizado no Rio Grande do Sul, Brasil. É uma pesquisa de modelagem quantitativa, caracterizada como empírica normativa quantitativa, com o propósito de fornecer a identificação do estágio atual do conhecimento referente a previsão de demanda de consultas de urgência em departamento de emergência e por meio de um modelo probabilísticos propor uma metodologia para assertividade e ganhos de eficiência no ambiente estudado. A modelagem dos dados foi realizada com o uso do software Microsoft Excel para a coleta e organização dos dados e do software livre R Versão 3.6.2 para construção do modelo de previsão demanda e análises estatísticas. Os resultados sugerem o modelo ARIMA (1,1,4) para clínico geral adulto e ARIMA (4,1,1) para pediatra, considerando o melhor ajuste possível para as predições. Recomenda-se previsões de 1 dia a frente até 14 dias de previsão, com erros próximos a 10%. Além disso, como modelo alternativo de previsão demanda foi proposta a utilização do modelo caótico pelo método do mapa logístico para previsão de curto prazo em consultas de urgência, incorrendo em baixo erro associado as previsões. O estudo demonstra a importância do uso de modelos

matemáticos de previsão em serviços de atendimento em departamento de emergência e como ferramenta de gestão.

Palavras-chave: Previsão de demanda, Métodos de previsão de demanda, ARIMA, Mapa logístico, Departamento de emergência, Serviço de saúde, Qualidade em serviço de saúde

ABSTRACT

In this work, the topic of forecasting demand for emergency services in the emergency department was addressed. The research objective was to propose a demand forecasting model for emergency consultations. Consisting of two academic articles, the first article is a systematic review of the literature on demand forecasting methods with the purpose of bringing together the methods and models available about the concepts currently used in the management of companies related to the consumption and production of products and services. The methodology used is the systematic review of the literature with a qualitative approach in order to give an overview of the dominant methods used in demand forecasting. The literature was mapped to identify the state of science through the available scientific production. Qualitative and causal methods show better adaptation to medium and long-term forecasts, while the analysis of time series indicates that it is more suitable for short-term forecasts. The second article proposes a model to predict the number of daily visits to an emergency hospital. Data from a 66-month period from a private Emergency Care and Day Hospital located in Rio Grande do Sul, Brazil were used. It is a quantitative modeling research, characterized as empirical normative quantitative, with the purpose of providing the identification of the current stage of knowledge regarding the forecast of demand for emergency consultations in the emergency department and through a probabilistic model to propose a methodology for assertiveness and efficiency gains in the studied environment. Data modeling was performed using Microsoft Excel software for data collection and organization and free software R Version 3.6.2 to build the demand forecast model and statistical analysis. The results suggest the ARIMA model (1,1,4) for adult general practitioners and ARIMA (4,1,1) for pediatricians, considering the best possible adjustment for predictions. Forecasts from 1 day ahead to 14 days of forecast are recommended, with errors close to 10%. In addition, as an alternative demand forecast model, it was proposed to use the chaotic model by the logistic map method for short-term forecasting in emergency consultations, incurring a low error associated with the forecasts. The study demonstrates the importance of using mathematical forecasting models in emergency department care services and as a management tool.

Keywords: Demand forecasting, Demand forecasting methods, ARIMA, Logistic map, Emergency department, Health care service, Quality in health care service

LISTA DE FIGURAS

Figura 1 - Protocolo da revisão sistemática da literatura sobre previsão de demanda	32
Figura 2 - Etapas do método de trabalho	79
Figura 3 - Protocolo da revisão sistemática da literatura sobre previsão de demanda em serviço de saúde	80
Figura 4 - Função autocorrelação da série temporal clínico geral.....	84
Figura 5 - Função autocorrelação parcial da série temporal clínico geral	85
Figura 6 - Função autocorrelação da série temporal pediatra	85
Figura 7 - Função autocorrelação parcial da série temporal pediatra	86
Figura 8 - Raízes inversas do modelo ARIMA (1, 1, 4)	89
Figura 9 - Raízes inversas do modelo ARIMA (4, 1, 1)	89
Figura 10 - Relação de ajuste dos dados ao modelo do mapa logístico do clínico geral	92
Figura 11 - Relação de ajuste dos dados ao modelo do mapa logístico do pediatra	93

LISTA DE GRÁFICOS

Gráfico 1 - Nº de consultas clínico geral adulto de julho 2013 a dezembro 2018.....	82
Gráfico 2 - Nº de consultas pediatra de julho 2013 a dezembro 2018	82
Gráfico 3 - Gráfico de resíduos ARIMA (1, 1, 4) do clínico geral.....	87
Gráfico 4 - Gráfico de resíduos ARIMA (4, 1, 1) do pediatra	88

LISTA DE TABELAS

Tabela 1 - Artigos publicados por tema.....	17
Tabela 2 - Síntese dos métodos de previsão de demanda	58
Tabela 3 - Revisão da literatura sobre previsão de demanda em departamento de emergência.....	65
Tabela 4 - Medidas de acurácia das previsões	90
Tabela 5 - Evolução temporal do mapa logístico do clínico geral.....	91
Tabela 6 - Evolução temporal do mapa logístico do pediatra.....	92
Tabela 7 - Resumo dos resultados obtidos por modelo	94

LISTA DE SIGLAS

ACF	Função de Auto Correlação
ANN	Rede Neural Artificial
APE	Erro Percentual Absoluto
AR	Processo Autorregressivo
ARIMA	Método Autorregressivo Integrado a Média Móvel
ARMA	Método Autorregressivo com Média Móvel
DNN	Redes Neurais Profundas
FS	Seleção de Recursos
FSE	Erro Padrão de Previsão
GA	Algoritmo Genético
GLM	Modo Linear Generalizado
MA	Processo de Média Móvel
MAE	Erro Médio Absoluto
MAPE	Erro Percentual Absoluto Médio
MASE	Erro Médio Absoluto em Escala
MGA	Algoritmo Genético Modificado
MMEP1	Média Móvel Exponencialmente Ponderada de 1ª ordem
MMEP2	Média Móvel Exponencialmente Ponderada de 2ª Ordem
MMP	Média Móvel Ponderada
MMS	Média Móvel Simples
MS	Ministério da Saúde
MSARIMA	Método da Média Móvel Integrada Autorregressiva Multivariada
MSE	Erro Quadrático Médio
NB	Naive Bayes
OMS	Organização Mundial da Saúde
PACF	Função de Auto Correlação Parcial
RMAP	Desempenho Médio Relativo Absoluto
RMSE	Erro Quadrático Médio da Raiz
SAMU	Serviço de Atendimento Móvel de Urgência
SANN	Redes Neurais Artificiais Rasas
SARIMA	Método da Média Móvel Integrada Autorregressiva Sazonal

SARIMAX	Método da Média Móvel Integrada Autorregressiva Sazonal
SES	Suavização Exponencial Única
UPA	Unidade de Pronto Atendimento

SUMÁRIO

1 INTRODUÇÃO	14
1.1 TEMA DE PESQUISA	16
1.2 JUSTIFICATIVA ACADÊMICA	17
1.3 JUSTIFICATIVA EMPRESARIAL	20
1.4 IMPORTÂNCIA SOCIOECONÔMICA	23
1.5 PROBLEMA DE PESQUISA E OBJETIVOS	24
1.6 DELIMITAÇÕES	25
1.7 ESTRUTURA DO TRABALHO	25
2 MÉTODO	27
3 MÉTODOS DE PREVISÃO DE DEMANDA: UMA REVISÃO SISTEMÁTICA DA LITERATURA	29
3.1 INTRODUÇÃO	29
3.2 METODOLOGIA	31
3.3 REVISÃO SISTEMÁTICA DA LITERATURA	33
3.3.1 Métodos Qualitativos	35
3.3.1.1 Julgamento por Especialistas	35
3.3.1.2 Delphi	35
3.3.1.3 Método de Analogia Estruturada	36
3.3.1.4 Pesquisa de Intenção e Opinião	36
3.3.2 Métodos Quantitativos	37
3.3.2.1 Modelos Causais	37
3.3.2.2 Séries Temporais	40
3.3.3 Métodos com Base em Inteligência Artificial	53
3.4 CONSIDERAÇÕES FINAIS	57
4 PREVISÃO DE DEMANDA EM UNIDADE DE PRONTO ATENDIMENTO DE COMPLEXIDADE INTERMEDIÁRIA	60
4.1 INTRODUÇÃO	60
4.2 REFERENCIAL TEÓRICO	62
4.2.1 Hospital de Pronto Atendimento	63
4.2.2 Métodos de Previsão de Demanda em Departamento de Emergência	63
4.2.3 Séries Temporais	72
4.2.4 Modelos Caóticos	74

4.2.5 Medidas de Acurácia.....	75
4.3 METODOLOGIA.....	78
4.4 RESULTADOS E DISCUSSÃO.....	81
4.4.1 Previsões com Modelo ARIMA.....	83
4.4.2 Previsões com Modelo Caótico	91
4.4.3 Análise dos Modelos de Previsão.....	93
4.5 CONSIDERAÇÕES FINAIS	95
5 CONCLUSÃO	97
REFERÊNCIAS.....	100

1 INTRODUÇÃO

O presente trabalho está voltado ao atendimento do serviço de urgência em pronto atendimento. O foco está no atendimento prestado por especialistas da equipe médica, com a finalidade de se ter a disposição o recurso médico e obter o menor tempo possível de espera dos pacientes. Evidenciando-se que os departamentos de emergência são serviços complexos, torna-se necessária uma abordagem especial de gestão, planejamento, projeto e gerenciamento das operações analisando todo o sistema para identificar as restrições e realizar uma pesquisa mais aprofundada nas causas das ineficiências.

Conforme o Ministério da Saúde (MS), as unidades de pronto atendimento são caracterizadas como serviços de atendimento de saúde de complexidade intermediária situada entre a Atenção Básica de Saúde, a Atenção Hospitalar e a Rede Hospitalar (MS, 2013). Esses serviços, na maioria dos casos, possuem alto índice de variabilidade, superlotação e uma demanda maior do que a capacidade de recursos instalados, causando tempo de espera excessivo impactando na qualidade do atendimento e na segurança dos pacientes. (ORDU; DEMIR; TOFALLIS, 2019b).

O Colégio Americano de Médicos de Emergência indica que geralmente os recursos disponíveis são insuficientes para prover as necessidades de atendimento dos pacientes de emergência. (VOSE, 2014). Os gerentes do hospital estão cada vez mais prestando atenção ao departamento de emergência, a fim de oferecer um serviço de melhor qualidade aos pacientes. (AFILAL et al., 2016a). Pacientes que saem insatisfeitos do departamento de emergência por não serem avaliados por um médico passam a ser considerados importante indicador de qualidade.

Adicionalmente, a contenção de custos é uma das principais dificuldades enfrentadas pelos hospitais, assim, passa a compor como solução para melhorar a qualidade dos serviços de saúde a maximização da eficiência dos recursos existentes e a redução de perdas com foco em produtividade. (BHAT; GIJO; JNANESH, 2016). Além disso, é um setor onde é inaceitável não atender plenamente as necessidades de assistência ao paciente e a implementação de um sistema robusto e eficiente para apoiar decisões referentes à escala de pessoal tem potencial para melhorias, possibilitando economia de tempo e de custo. (WONG; XU; CHIN, 2014).

Os desafios relacionados à demanda e custos estão cada vez maiores nos sistemas de saúde de países desenvolvidos. Taylor e Nayak (2012) afirmam que a quantidade e a qualificação dos funcionários guardam uma relação direta com a segurança e readmissão dos pacientes, tendo como solução mais comum havendo problemas nos serviços hospitalares, mesmo com um alto custo, a de alocar mais pessoas. Entretanto, melhorar o fluxo e a capacidade dos processos requer um estudo aprofundado das estruturas dos processos das áreas de emergência e internação, sendo que a simplificação de processos complexos como os da saúde é um desafio constante. (VOSE, 2014).

Devido à complexidade dos serviços de saúde e à presença dos clientes no sistema, ao considerar o valor para o paciente neste ambiente é de maior importância a segurança e a eficiência do que o custo e a eficácia. As consequências de uma escala de trabalho inadequada são inúmeras e prontamente percebidas. Afetam a qualidade de atendimento, satisfação do cliente, riscos nos processos, o custo e prejudicam a eficiência operacional do hospital. (DIAS, 2015).

Estes sistemas lutam para lidar adequadamente com a demanda. (ABOAGYE-SARFO et al., 2015). Compreender o histórico de chegada dos pacientes por hora, por dia e por semana, auxilia na previsão e gestão dessa demanda. Para se fazer previsões de demanda, em um dos modos, é preciso identificar os padrões de comportamento com base em séries históricas de dados e, então, por meio de um modelo matemático prever o comportamento futuro. (AFILAL et al., 2016b). As previsões de demanda abrangem o grau de disponibilidade do produto ou serviço e são necessárias como elemento qualificador para uma melhor tomada de decisão. (FORTSCH; KHAPALOVA, 2016).

As empresas necessitam planejar as suas operações em relação à oferta de produtos ou de serviços. A previsão de demanda é uma metodologia para estimar um valor futuro de uma grandeza de interesse. As previsões são elemento necessário no processo de tomada de decisão sobre o futuro. (PETROPOULOS et al., 2018). Realizar previsões de demanda significa reconhecer padrões de comportamento em séries históricas e prever o comportamento futuro, ou ainda, identificar fatores causais que afetam o comportamento e extrapolá-lo.

Existem métodos de previsão de demanda basicamente classificados em quantitativos e qualitativos. (HANKE; WICHERN, 2001; MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998; KRAJEWSKI; RITZMAN; MALHOTRA, 2009).

As técnicas qualitativas não requerem manipulação de dados, e somente julgamentos são utilizados para criar a previsão. (JUN; SUNG; PARK, 2017). Já as técnicas quantitativas geralmente não necessitam de julgamento, pois são procedimentos padronizados que produzem resultados objetivos.

Neste sentido, é necessário encontrar soluções viáveis para melhorar a previsibilidade e a eficiência no uso dos recursos em departamentos de emergência, tais como o ajuste dos recursos humanos e no fluxo dos processos. O estudo técnico e científico nos processos de urgência e emergência fornece o direcionamento para a melhoria dos serviços de saúde. (ZHAO, 2015). Este tipo de análise permite fornecer uma visão sistêmica e integrada das perdas nos processos organizacionais e indicar os passos a serem priorizados para eliminar tais perdas. (BAUER et al., 2019).

No sentido de identificar as atividades que agregam ou não valor ao cliente, são estudos de processo e de fluxo de trabalho que representam análises de emprego de recursos operacionais e de tempo e a agregação de valor. (GAUZE JÚNIOR, 2016). Conforme Shou et al. (2017), as análises de processos e de fluxo de valor tem sido bastante utilizada no setor de cuidados de saúde em departamentos administrativos e no processo de tratamento do paciente. Segundo o estudo, os principais benefícios na área de saúde estão na redução de horas extras, de reclamações de clientes em processos administrativos, do tempo de espera e tempo de tratamento.

O tema da previsão de demanda indica ser atual e relevante para as instituições da área de saúde. Portanto, propor um modelo probabilístico conceitual para prever a demanda de pacientes e otimizar o quadro de lotação de médicos de um hospital de pronto atendimento torna-se relevante para acadêmica e para as instituições hospitalares.

1.1 TEMA DE PESQUISA

Este trabalho aborda a previsão de demanda do serviço de urgência em um hospital de pronto atendimento. Sua orientação recai sobre as consultas de urgência nos aspectos de comportamento de demanda e de previsão do número de atendimentos no curto prazo.

1.2 JUSTIFICATIVA ACADÊMICA

Foi realizada uma pesquisa no portal da CAPES, nas bases de dados Scopus e Web of Science, com a finalidade de demonstrar a relevância do trabalho, bem como estabelecer a sua justificativa acadêmica. Foi aplicado o horizonte temporal do ano de 2010 a 2018 e foram utilizados os termos: "demand forecasting", "service management", "management health service" e "quality in service". A pesquisa indicou que muitas pesquisas acadêmicas sobre previsão de demanda e gestão de serviços são publicadas há muitos anos e em ritmo crescente.

Estudos de temas relacionados a gestão de serviços de saúde mantiveram o número de publicações acima de onze artigos por ano. Os dados demonstram poucos trabalhos sobre o tema e, avaliando especificamente os últimos cinco anos, indicam crescimento significativo conforme apresentado na Tabela 1.

Tabela 1 - Artigos publicados por tema

Temas	2010	2011	2012	2013	2014	2015	2016	2017	2018
"demand forecasting"	380	412	417	470	604	548	610	686	868
"service management"	1.082	1.247	1.398	1.338	1.490	1.352	1.468	1.495	1.749
"management health service"	21	13	11	20	15	23	18	18	19
"quality in service"	4	2	9	3	8	3	2	3	9
Total	1.487	1.674	1.835	1.831	2.117	1.926	2.098	2.202	2.645

Fonte: Elaborada pelo autor.

Temas voltados a qualidade em serviços foram pouco explorados, porém com grande potencial de pesquisa já que se pode observar que nos anos de 2012 e de 2018 ocorreram números maiores de publicações. Pela tabela, observa-se que a produção total tem subido, e desde 2014 se mantém em ritmo acima de mil e novecentas novas publicações de artigos por ano.

Atualmente os hospitais necessitam otimizar a utilização dos seus recursos para melhorar seu desempenho global, e as técnicas de Engenharia de Produção permitem maximizar a utilização desses recursos da melhor maneira possível. (DIAS, 2015). Neste sentido, trabalhos acadêmicos sobre previsão de demanda conduzidos em departamento de saúde apontam resultados satisfatórios. Wang et al. (2015a), com base nos princípios lean e na otimização por simulação em um departamento de emergência hospitalar, reduziram o tempo médio de espera dos pacientes de 78 para 38 minutos, aumentaram o nível de serviço de 54,86% para

88,55% e reduziram o número de enfermeiros de nove para seis. A modelagem de simulação proposta em Zhao (2015) mostra a promessa de economia de tempo na detecção de gargalos nas operações de emergência em hospitais. Souza (2015a) afirma que a aplicação de metodologias utilizando ferramentas matemáticas e estatísticas e técnicas oriundas da indústria para melhoria de qualidade, resolução de problemas e melhoria da produtividade possibilitam sucesso empresarial em ambientes de saúde.

O estudo de Gopakumar et al. (2016) investigou diferentes modelos para prever o número total de altas no dia seguinte de uma enfermaria aberta e desenvolveu uma estimativa inteligente de leitos disponíveis em enfermarias, que desempenha um papel crucial para aliviar o bloqueio de acesso em departamentos de emergência. Afilal et al. (2016a) e Afilal et al. (2016b) abordaram a previsão do fluxo de pacientes visando ajudar os tomadores de decisão a otimizar a alocação de recursos humanos e de materiais com foco na previsão do atendimento diário em departamento de emergência. Os modelos desenvolvidos nos dois estudos mostram desempenho acima de até 90% para a previsão de fluxo total anual e robustez em períodos epidêmicos.

Juang et al. (2017) construíram um modelo para prever visitas mensais a um pronto-socorro. O modelo ARIMA (0, 0, 1) foi considerado o mais adequado para prever a demanda de atendimento e seus resultados de previsão foram disponibilizados para ser usados como um auxílio nos processos de tomada de decisão. Para Villani et al. (2017), os modelos de séries temporais SARIMA indicaram ser uma ferramenta valiosa que permitem a previsão do número de casos futuros com alta precisão e prever casos crescentes de emergências diabéticas pré-hospitalares. O modelo gerado por este estudo pode ser aplicado por prestadores de serviços no planejamento adequado e alocação de recursos em emergências diabéticas.

De acordo com Jiang et al. (2017), a previsão de demanda bem executada fornece aos gerentes do departamento ambulatorial informações essenciais para o agendamento de atendimentos e escala de funcionários, considerando a política de não reserva do ambulatório da China. Os resultados da metodologia proposta para a previsão do número de atendimentos nesta pesquisa tornaram-se pré-requisitos cruciais para o escalonamento de pessoal e alocação de recursos no departamento

ambulatorial, fornecendo informações práticas sobre a associação potencial entre combinações de recursos múltiplos e variação de demanda.

O modelo de previsão do número de chegadas no departamento de emergência obtido em Carvalho-Silva et al., (2018) trouxe previsões para uma semana ou um mês com um nível de qualidade significativo, diminuindo os cancelamentos de admissões planejadas, otimizando a alocação de leitos, alocação de recursos humanos e o número de postos de atendimento ao paciente. Jilani et al. (2019) propuseram um modelo de lógica fuzzy baseado em heurística para prever atendimentos em departamento de emergência e auxiliar na alocação de recursos e reduzir a pressão sobre hospitais ocupados. O modelo de previsão de demanda teve precisão aceitável e mostrou ser útil como ferramenta no melhor gerenciamento de leitos, equipe e agendamento de cirurgia eletiva.

De Brito et al. (2019) apresentam um modelo matemático para realizar as previsões do número de atendimentos de pacientes no departamento de emergência de um município de Minas Gerais, Brasil. O modelo ARIMA (1,1,1) apresentou o melhor ajuste para essa previsão. Além disso, concluíram que a aplicação dos modelos de previsão de demanda deve ser vista pelos gestores como uma ferramenta para auxiliar as decisões, apoiando processos de planejamento, gestão e avaliação no ambiente hospitalar, e caracterizou-os como um instrumento de atendimento e serviços gerenciais.

Ordu, Demir e Tofallis (2019a) desenvolveram uma estrutura de modelagem de previsão para todos os serviços de urgência de um hospital, incluindo todas as especialidades ambulatoriais, internação e departamento de acidentes e emergência, com o objetivo de apoiar a gestão para melhor lidar com a demanda e planejar com eficácia. O estudo aponta que conhecer o comportamento da demanda do hospital em sua totalidade permitirá que a administração planeje com antecedência, garanta que os recursos necessários estejam disponíveis, gerencie melhor os orçamentos e venha a reduzir situações de risco para pacientes, funcionários e instituição.

Em Ordu, Demir e Tofallis (2019b), foi elaborado um sistema de apoio à decisão combinando simulação de eventos e técnicas de previsão comparativa para o melhor gerenciamento do Hospital Princesa Alexandra na Inglaterra. Foi proposto um modelo de simulação de eventos discretos para medir uma série de métricas de desempenho consideradas importantes. Este trabalho apresenta um estudo

relevante que permite aos diretores e gestores de serviços prever suas atividades e formar um plano estratégico com certa antecedência.

Neste contexto, percebendo poucas pesquisas empíricas sobre previsão de demanda em departamento de emergência, evidenciou-se uma oportunidade de pesquisa acadêmica científica no tema. Pretende-se com esta pesquisa contribuir com a construção de um modelo baseado em probabilidade para a previsão de demanda de atendimentos no serviço de consulta em pronto atendimento de saúde. Na literatura encontram-se poucas pesquisas relacionadas a ambos os assuntos e sua combinação traz relevante contribuição à gestão de operações na saúde.

1.3 JUSTIFICATIVA EMPRESARIAL

No Brasil o financiamento à saúde tem oscilado nos últimos anos próximos de 8% do PIB. Países, como o Canadá (10,4% do PIB) e o Reino Unido (9,9% do PIB), que oferecem acesso universal à saúde de boa qualidade alocam recursos pouco superiores aos do Brasil. A solução para o adequado funcionamento do sistema de saúde de um país depende de dois fatores: financiamento suficiente e gestão adequada dos recursos obtidos. (SALDIVA; VERAS, 2018). Com base neste cenário, o setor de serviço de atendimento de saúde foi escolhido devido ao volume e potencial de crescimento do gasto no setor, bem como por perceber a necessidade de adequação da gestão dos recursos.

Conforme o novo relatório da Organização Mundial da Saúde (OMS), os gastos com saúde estão crescendo mais rapidamente que o resto da economia global, representando 10% do produto interno bruto (PIB) mundial. O relatório revela uma rápida trajetória ascendente dos gastos com saúde em todo o mundo, o que é particularmente notável em países de baixa e média renda. Nestes países os gastos com saúde crescem em média 6% ao ano, em comparação com 4% realizados em países de alta renda. (OMS, 2018).

Os gastos com saúde são compostos por gastos públicos, pagamentos diretos das pessoas pelos cuidados e fontes como seguro de saúde voluntário, programas de saúde fornecidos por empregadores e atividades de organizações não governamentais. Os recursos públicos fornecem uma média de 51% dos gastos com saúde de um país e mais de 35% dessas despesas são pagas pelas pessoas com recursos próprios. O relatório da OMS destaca uma tendência de aumento do

financiamento público interno para saúde em países de baixa e média renda e o declínio do financiamento externo em países de média renda. O gasto público em saúde per capita em países de média renda dobrou desde o ano 2000. Em média, os governos gastam US\$ 60 por pessoa em saúde nos países de baixa-média renda e, cerca de, US\$ 270 por pessoa nos países de média-alta renda. (OMS, 2018).

O financiamento de saúde do Brasil, conforme os dados do IBGE, é centrado predominantemente no sistema privado de saúde que atende a algo em torno de 23% da população. (IBGE, 2018). Existe também um incentivo federal, ao longo dos últimos anos, para a criação de planos de saúde mais populares, com menor cobertura para doenças mais graves. Por outro lado, Saldiva e Veras (2018) explicam que nas situações mais graves, como uma neoplasia ou a necessidade de um transplante, a cobertura dos planos mais simples não acontece, onerando o SUS. Tal sistema favorece o capital privado em detrimento do sistema público. Portanto, com as ações praticadas no Brasil parecem indicar que o país está em um processo rumo à privatização, conforme Saldiva e Veras (2018).

Problemas de fluxo demonstram o descompasso entre a realização de consultas médicas, exames e cirurgias. Tais problemas são interpretados pelo usuário como ineficiência e o induzem a não procurar diretamente a assistência básica. Além disso, a desorganização do sistema de saúde impacta o perfil de adoecimento no Brasil e provoca aumento dos gastos no setor. O problema se reproduz também na assistência por planos de saúde, onde a atenção básica é praticamente inexistente e o usuário frequentemente procura diretamente um hospital independente da gravidade de seus sintomas. Existe também casos em que o usuário procura o hospital após dificuldades de agendamento com o especialista e exames relacionados. (SALDIVA; VERAS, 2018).

Conforme Souza (2015b) as instituições da saúde, públicas ou privadas, vivenciam uma realidade hostil que as conduz a buscarem sobrevivência no mercado. Há uma tendência global de alta na demanda por qualidade e de aumento das expectativas e exigências de redução de custos. (BAUER et al., 2019). Desse modo, é importante também aprimorar a gestão e regulação de serviços de saúde. A escassez de profissionais da saúde é um problema a ser discutido de forma profunda e competente. Relações mais produtivas entre o sistema de saúde e instituições de ensino superior precisam ser organizadas e implantadas, buscando

profissionais qualificados e em quantidade suficiente para suprir, com qualidade, a população. (SALDIVA; VERAS, 2018).

A complexidade do atendimento em saúde requer a diversidade de profissionais, onde médicos, enfermeiros e demais profissionais representam o grupo de sustentação à atenção à saúde. (LUO et al., 2017). Assim, o momento é de apoiar e complementar a formação desses profissionais, mediante a expansão do programa de formação continuada em serviço e agregar conhecimentos de outras áreas no sentido de obter maior eficiência operacional.

De acordo com Saldiva e Veras (2018), profissionais com formação sem qualidade fazem mal à saúde dos pacientes, principalmente quando esses estão operando nos níveis da atenção primária e secundária. A perda de capacidade de resolver as principais demandas de saúde nesses níveis de atenção sobrecarrega o nível de atenção terciária, encarece o tratamento pela solicitação de exames desnecessários, e, principalmente, prejudica o paciente pela demora na resolução dos seus problemas, comprometendo por vezes a possibilidade de cura. (SALDIVA; VERAS, 2018).

A adequação da gestão e a redução dos custos requer a introdução de tecnologias e a inteligência em saúde. O Brasil possui uma base de dados de saúde, porém é preciso melhorar a sua análise. O uso de tecnologia de big data e de simulação de sistemas complexos, técnicas frequentemente empregadas em outras áreas do conhecimento, deve ser expandida na área da saúde. Modelos preditivos de epidemias ou surtos de doenças infecciosas, análise de custo efetividade de procedimentos e técnicas de tratamento devem ser objeto de análise contínua, orientando sobre como o sistema deve se organizar para o futuro. (ORDU; DEMIR; TOFALLIS, 2019b).

Caso esse tipo de análise não seja ampliada e aplicada, sempre reagiremos a um problema em detrimento do planejamento de longo prazo. Então faz-se necessário conhecer os problemas e os seus fatores relacionados, definir prioridades de intervenção e propor estratégias conforme os recursos disponíveis com o objetivo maior da melhoria do nível de saúde da população. Assim, percebe-se uma progressiva pressão sobre os serviços de saúde referente ao aumento de eficiência por meio da adoção de metodologias e conceitos de gestão, incluindo conhecimentos, técnicas e ferramentas da Engenharia de Produção. (DIAS, 2015; ORDU; DEMIR; TOFALLIS, 2019a).

Segundo Bauer et al. (2019), os sistemas de saúde devem se concentrar na melhoria contínua de seus processos, para evitar o desperdício de recursos ou de tempo, bem como serem capazes de usar as informações de forma eficaz para atender a comunidade, preservar a eficiência e garantir a qualidade do serviço.

1.4 IMPORTÂNCIA SOCIOECONÔMICA

Os serviços de atendimento de saúde trazem junto de si uma missão importante e um forte senso de propósito que é a manutenção e o restabelecimento da saúde de uma população. (SOUZA, 2015a). O Brasil vivencia uma dura realidade de dificuldade de tratamento das mais diversas doenças e do envelhecimento da população. Tal realidade impulsiona a repensar a gestão dos recursos e procurar alternativas para resolver os problemas cotidianos e neste contexto há espaço para melhorias. (SALDIVA; VERAS, 2018).

O aumento da procura de cuidados de saúde, o investimento limitado do governo e a concorrência elevada entre as organizações fazem com que os hospitais estejam cada vez mais conscientes da necessidade de usar seus recursos da forma mais eficiente possível. (AFILAL et al., 2016a). Este setor vem enfrentando grandes desafios para melhorar a qualidade dos serviços oferecidos à população e as organizações de saúde tem buscado incorporar novas estratégias de gestão capazes de conciliar a redução dos custos, a melhoria dos serviços oferecidos e o atendimento das necessidades e expectativas dos clientes e colaboradores. (DIAS, 2015). Neste sentido, as instituições de saúde estão cada vez mais interessadas na implantação de métodos e tecnologia como apoio à tomada de decisão no processo de planejamento das equipes de trabalho, buscando otimizar seus recursos humanos.

O dimensionamento inadequado de equipes de saúde aumenta custos ou prejudica a qualidade da assistência prestada. A inadequação quantitativa e qualitativa dos recursos humanos prejudica os pacientes dos serviços de saúde no seu direito de assistência à saúde, livre de riscos. (DIAS, 2015). Aspectos importantes como planejar o sistema de atenção para o envelhecimento da população, prevenir a epidemia de obesidade, garantir acesso aos tratamentos hoje disponíveis, necessitam de uma análise mais sofisticada e, portanto, é necessário

induzir a formação dos profissionais a partir do sistema que interaja com as mais diversas áreas de conhecimento.

As instituições de saúde têm procurado cada vez mais melhorar suas operações para se manterem competitivos frente aos desafios da demanda crescente por serviços de atendimento médico, o surgimento de novas tecnologias, o aumento da concorrência e a exigência de padrões de qualidade mais elevados, forçando os hospitais a se adaptarem a uma nova realidade em que a sobrevivência do negócio está diretamente ligada à eficiência de seus processos. (HENRIQUE et al., 2016). A qualidade dos serviços de saúde está voltada a satisfazer as demandas e necessidades dos seus grupos de interesses, representado pelos prestadores de serviço de saúde, administradores destes serviços e usuários. Buscar uma melhoria de processos visando à excelência do desempenho, permite alcançar resultados sustentáveis e alinhados às expectativas dos usuários de um sistema de saúde e aumentando o retorno financeiro é possível. (SOUZA, 2015a). Neste sentido, esta pesquisa se justifica em buscar meios de aumentar a qualidade dos envolvidos no serviço de atendimento de saúde.

1.5 PROBLEMA DE PESQUISA E OBJETIVOS

A presente pesquisa tem por objetivo responder ao problema de pesquisa: Como prever a demanda das consultas de urgência em um hospital de pronto atendimento?

O objetivo geral deste trabalho é propor um modelo de previsão de demanda para consultas de urgência em um hospital de pronto atendimento.

Os objetivos específicos são:

- a) Identificar o comportamento da demanda de consultas de urgência;
- b) Quantificar a demanda do recurso médico de atendimento ser utilizado no curto prazo;
- c) Propor um modelo probabilístico de previsão de demanda de curto prazo, com a finalidade de se ter a disposição o recurso médico e obter o menor tempo possível de espera dos pacientes;
- d) Testar e avaliar o modelo de previsão de demanda de curto prazo proposto.

1.6 DELIMITAÇÕES

O foco está nas consultas de emergência com especialistas da equipe médica, visando se ter a disposição o recurso médico e obter o menor tempo possível de espera dos pacientes e máxima utilização deste recurso. Neste sentido, serão objeto de estudo as duas especialidades de atendimento mais requisitadas no serviço de urgência desta pesquisa, que são, clínico geral adulto que representa 58% dos atendimentos e clínico geral pediátrico que corresponde a 24% dos atendimentos. Demais especialidades, atividades e processos não estão no escopo de trabalho.

1.7 ESTRUTURA DO TRABALHO

O presente trabalho foi estruturado com uma introdução à dissertação, apresentando as considerações iniciais a respeito do tema, as justificativas acadêmica e empresarial, importância socioeconômica, bem como os objetivos gerais e específicos, as delimitações do tema e a estrutura do trabalho.

A segunda parte do trabalho possui o capítulo sobre método, para responder à questão de pesquisa e expor o método de trabalho com as etapas cumpridas para alcançar o objetivo do trabalho.

Após é apresentado um artigo com uma revisão sistemática da literatura dos métodos dominantes utilizados em previsão de demanda, discorrendo sobre o estado da ciência por meio da produção científica disponível nos bancos de dados Scopus e Google Scholar. A revisão sistemática da literatura, organizada em formato de artigo acadêmico, reúne os métodos e modelos disponíveis acerca dos conceitos utilizados atualmente na administração de empresas e gestão de serviços.

O capítulo quatro contém um artigo que fornece a identificação do estágio atual do conhecimento referente a previsão de demanda de consultas de urgência em departamento de emergência e propõe um modelo probabilístico de previsão de demanda para consultas de urgência em um hospital de pronto atendimento. Também é considerada a viabilidade do modelo proposto, a relevância e as implicações gerenciais de sua utilização.

Por fim, este trabalho conta com a conclusão. Na conclusão serão discutidas as limitações do trabalho e serão apresentadas proposições de futuros trabalhos como continuidade de pesquisa e de outras pesquisas relacionadas.

2 MÉTODO

O método de pesquisa demonstra um conjunto de regras, passos e etapas com o propósito de construir conhecimento científico em determinada área e que são aceitos e reconhecidos pela comunidade acadêmica. (LACERDA et al., 2013). Conforme Marconi e Lakatos (2010), método de trabalho é o conjunto de atividades sistemáticas e racionais que possuem a função de orientar e sustentar o desenvolvimento de conhecimentos necessários e que dá a direção do caminho a ser seguido. Neste sentido, o presente trabalho possui a preocupação de assegurar que exista adesão entre observações e ações na realidade pesquisada e o modelo elaborado desta realidade. (MIGUEL; FLEURY, 2018). É composto da revisão sistemática da literatura dos métodos dominantes utilizados em previsão de demanda e da proposta de um modelo de previsão de demanda para consultas de urgência em um serviço de urgência de um hospital de pronto atendimento. Para tanto, a pesquisa é apresentada em dois artigos.

No primeiro artigo foi elaborada a revisão sistemática da literatura, com o propósito de dar uma visão geral, dos métodos dominantes utilizados em previsão de demanda. (WEE; BANISTER, 2016). Foi identificado o estado da ciência por meio da produção científica disponível nos bancos de dados Scopus e Google Scholar. As buscas foram somente em documentos do tipo “artigo”, em língua inglesa e a partir do ano de 2015. Sua contribuição é de reunir os métodos e modelos disponíveis acerca dos conceitos utilizados atualmente na administração de empresas relacionados ao consumo e produção de produtos e serviços, contemplando os métodos qualitativos, quantitativos e com base em inteligência artificial. Também evidenciou as diferentes técnicas e métodos empregados recentemente e que proporcionam resultados bem-sucedidos em previsão de demanda e previsão de vendas em aplicações diversas.

O segundo artigo é uma pesquisa de modelagem quantitativa, caracterizada como empírica normativa quantitativa, com o objetivo de desenvolver estratégias e ações que melhorem a situação corrente em um serviço de urgência de um hospital de pronto atendimento. De acordo com Miguel e Fleury (2018), pesquisa quantitativa está direcionada a descrições matemáticas e simbólicas das relações causais entre as variáveis de controle e de desempenho em que são desenvolvidas, analisadas e

testadas. Sua contribuição é de fornecer a identificação do estágio atual do conhecimento referente a previsão de demanda de consultas de urgência em um departamento de emergência e por meio de modelos probabilísticos propor uma metodologia que proporcione assertividade e ganhos de eficiência no ambiente estudado. O resultado deste artigo é um modelo de previsão de demanda para consultas de urgência em um hospital de pronto atendimento.

Ambos os artigos contêm o detalhamento dos procedimentos metodológicos aplicados. Os capítulos 3 e 4 apresentam seções que aprofundam e detalham o método de pesquisa e o método de trabalho empregados em cada um dos artigos.

3 MÉTODOS DE PREVISÃO DE DEMANDA: UMA REVISÃO SISTEMÁTICA DA LITERATURA

Este capítulo apresenta o artigo referente a revisão sistemática da literatura em previsão de demanda. Artigo submetido à Revista INNOVAR, ISSN:0121-5051, SJR 2019: 0.163 e CiteScore 2019: 0.6.

Resumo: A previsão de demanda é uma metodologia da administração de empresas para estimar um valor futuro de uma grandeza de interesse. Realizar previsões de demanda significa reconhecer padrões de comportamento em séries históricas e prever o comportamento futuro, ou ainda, identificar fatores causais que afetam o comportamento e extrapolá-lo. Este artigo tem por objetivo realizar uma revisão sistemática da literatura dos métodos de previsão de demanda com o propósito de reunir os métodos e modelos disponíveis acerca dos conceitos utilizados atualmente na administração de empresas relacionados ao consumo e produção de produtos e serviços. A metodologia utilizada é a revisão sistemática da literatura com abordagem qualitativa com o propósito de dar uma visão geral dos métodos dominantes utilizados em previsão de demanda. Foi realizado o mapeamento da literatura para identificar o estado da ciência por meio da produção científica disponível nos bancos de dados Scopus e Google Scholar. Sendo assim, é possível afirmar que o melhor método é aquele que fornece os valores mais próximos entre a previsão e a demanda real, independente do segmento de atuação empresarial. Os métodos qualitativos e causais demonstram adaptar-se melhor às previsões de médio e longo prazos, enquanto a análise de séries temporais, especificamente pelos métodos das médias e suavização exponencial, indicam se adequar mais a previsões de curto prazo. Métodos que utilizam inteligência artificial modelam situações simples e complexas, e possuem a capacidade de identificar relacionamentos não lineares e interativos, sendo usados em sistemas de previsão de demanda ou como pré-processadores de dados para suavizar e classificar dados ruidosos para combinar as relações entre funções complicadas. Mostrou-se um recurso utilizado em diversas realidades a construção de um modelo próprio de previsão de demanda utilizando aspectos, conceitos e características de diferentes modelos conceituais, entretanto, é fundamental validar o modelo adotado e sempre mantê-lo sob controle, de maneira a poder efetuar correções dentro do menor prazo possível.

Palavras-chave: Previsão de demanda, Métodos de previsão de demanda, Previsão, Revisão

3.1 INTRODUÇÃO

As empresas necessitam planejar as suas operações em relação à oferta de produtos ou de serviços. A previsão de demanda é uma metodologia da administração de empresas para estimar um valor futuro de uma grandeza de interesse. As previsões são elemento necessário no processo de tomada de decisão sobre o futuro. (PETROPOULOS et al., 2018). Realizar previsões de demanda

significa reconhecer padrões de comportamento em séries históricas e prever o comportamento futuro, ou ainda, identificar fatores causais que afetam o comportamento e extrapolá-lo.

Existem métodos de previsão de demanda basicamente classificados em quantitativos e qualitativos. (ARVAN et al., 2019), aplicados ao consumo e à produção de bens ou de serviços. As técnicas quantitativas geralmente não necessitam de julgamento, pois são procedimentos padronizados que produzem resultados objetivos por meio de métodos matemáticos. Já as técnicas qualitativas não requerem manipulação de dados, e somente julgamentos são utilizados para criar a previsão. (JUN et al., 2017).

Nos anos 70 George Box e Gwilym Jenkins propuseram os Métodos Autorregressivos Integrados a Média Móvel (ARIMA), partindo-se da ideia de que os valores de uma série temporal são altamente dependentes. (BRENTAN et al., 2017). Com o advento da computação passou-se a utilizar métodos baseados em computação e fundamentados em modelos com inteligência artificial que modelam situações simples e complexas, e possuem a capacidade de identificar relacionamentos não lineares e interativos. (WANG; LI; LI, 2018). Já na última década, as redes neurais artificiais e abordagens compostas, como neuro-fuzzy e associados aos modelos caóticos, foram consideradas uma poderosa ferramenta computacional para resolver problemas complexos em previsão de demanda (FIOT; DINUZZO, 2016 e CORTEZ et al., 2018a).

Sob o aspecto acadêmico, pesquisas como a de Raza e Khosravi, (2015) trazem uma revisão sobre técnicas de previsão de demanda baseada em inteligência artificial para redes e edifícios inteligentes. Deb et al., (2017) apresentam uma revisão sobre as técnicas de previsão com uso de séries temporais voltados ao consumo de energia. Katsikopoulos et al., 2018 revisaram e sintetizaram pesquisas que usaram análises matemáticas e simulações em computador em modelos simples e complexos. Armstrong e Green, 2019 discorrem sobre os diferentes métodos de previsão de demanda em aplicações empíricas.

O uso do julgamento humano, único ou em conjunto com modelos quantitativos, foi amplamente pesquisado na literatura acadêmica e é uma abordagem popular de previsão na prática da administração de empresas. Arvan et al., 2019 apresentam uma revisão sistemática da literatura sobre previsão de demanda com uso de julgamento, com foco na integração de métodos. Entretanto,

percebeu-se a lacuna de uma pesquisa acadêmica que faça a revisão sistemática da literatura contemplando os métodos qualitativos, quantitativos e com base em inteligência artificial tendo o foco voltado à administração de empresas no que diz respeito ao consumo e produção de produtos e serviços.

Sob o aspecto empresarial e social o tema da previsão de demanda indica ser atual e relevante para as instituições de diversos segmentos de atuação. As consequências de um plano de trabalho inadequado são inúmeras e prontamente percebidas. (ARVAN et al., 2019). Afetam a qualidade, a satisfação do cliente, o custo e prejudicam a eficiência operacional do negócio (TRATAR, 2015), consequentemente gerando impactos negativos à sociedade.

Assim, conhecer os conceitos, métodos e modelos para prever a demanda de produtos, serviços, materiais e otimizar a utilização dos recursos organizacionais torna-se relevante para acadêmica no campo teórico da administração de empresas, para as empresas no que se refere a gestão de recursos e a sociedade como geração de progresso econômico e financeiro. Neste sentido, questionou-se, quais são os métodos de previsão de demanda sobre o consumo e produção de produtos e serviços utilizados atualmente na administração de empresas?

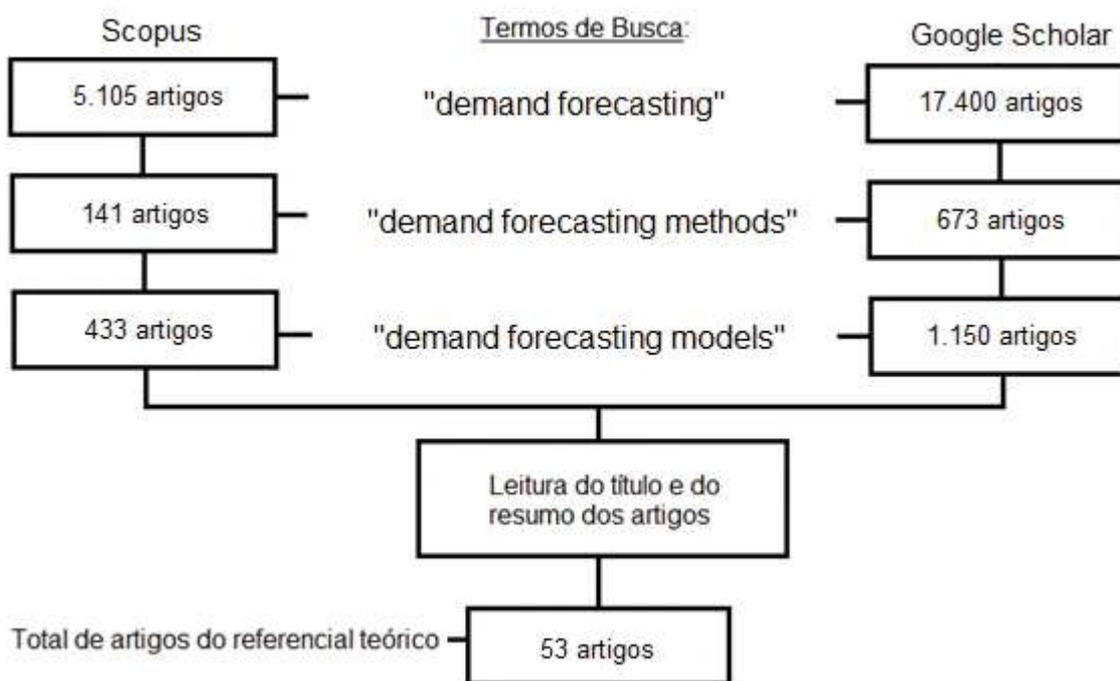
O objetivo deste estudo é, portanto, realizar uma revisão sistemática da literatura dos métodos de previsão de demanda com o propósito de reunir os métodos e modelos disponíveis acerca dos conceitos utilizados atualmente na administração de empresas relacionados ao consumo e produção de produtos e serviços. O artigo está separado em quatro seções. Após a introdução ao tema de pesquisa, na seção de metodologia são descritas a abordagem e a metodologia de estudo. Na seção 3.3 está a revisão sistemática da literatura que descreve os métodos de previsão de demanda, tratados em termos de métodos qualitativos, métodos quantitativos e métodos com base em inteligência artificial. As conclusões, considerações finais e sugestões de novos estudos são apresentadas na seção de considerações finais.

3.2 METODOLOGIA

A metodologia utilizada neste artigo é a revisão sistemática da literatura com abordagem qualitativa em que tem o propósito de dar uma visão geral dos métodos dominantes utilizados em previsão de demanda. (WEE; BANISTER, 2016). Foi

realizado o mapeamento da literatura para identificar o estado da ciência por meio da produção científica disponível nos bancos de dados mais relevantes. (ZUPIC; ČATER, 2015). A pesquisa foi conduzida em quatro etapas: i) definição dos termos de busca, ii) pesquisa nas bases de dados, iii) coleta e avaliação dos artigos e iv) interpretação dos resultados. O protocolo da revisão sistemática da literatura sobre previsão de demanda está exposto na Figura 1.

Figura 1 - Protocolo da revisão sistemática da literatura sobre previsão de demanda



Fonte: Elaborado pelo autor.

Na primeira etapa foram definidos os termos de busca "demand forecasting", "demand forecasting methods" e "demand forecasting models". Os termos de busca foram utilizados na língua inglesa presentes no título, resumo ou palavras-chave. As pesquisas dos termos de busca, ou seja, a etapa dois, foi realizada nos bancos de dados Scopus e Google Scholar, em função de oferecerem o maior número de artigos em cada um dos termos de busca. As buscas foram refinadas, restringindo-as somente a documentos do tipo "artigo", em língua inglesa e dos último cinco anos para se ter uma base atual de pesquisa. (ZUPIC; ČATER, 2015).

Na terceira etapa, os arquivos foram inicialmente analisados por título e resumo, para que fossem incluídos somente os documentos que se referem ao tema de pesquisa e selecionados por ordem de documentos mais citados. A etapa quatro

foi a análise sobre os diferentes métodos de previsão de demanda e os seus conceitos. Por fim tem-se as considerações finais.

3.3 REVISÃO SISTEMÁTICA DA LITERATURA

As previsões de demanda desempenham um importante papel em diversas áreas na gestão de organizações e, independentemente do tamanho ou área de atuação, todas as empresas necessitam planejar. Os planejamentos de negócios em geral estão baseados de alguma forma em previsões. Previsões são usadas extensivamente nos negócios para planejamento e gerenciamento tático, estratégico ou operacional em horizontes diferentes que variam de dias, semanas ou meses, embora o nível de detalhamento seja diferente. (ABOAGYE-SARFOET al., 2015).

As quantidades de vendas de produtos, os padrões de consumo de produtos ou serviços e as necessidades de matéria-prima são exemplos de informações essenciais a uma empresa. (PETROPOULOS et al., 2018). Neste sentido, existe uma base comum e importante a todos os planejamentos que é a previsão de demanda. As previsões de demanda abrangem o grau de disponibilidade do produto na cadeia de suprimentos e caracterizam-se necessárias como elemento qualificador para uma melhor tomada de decisão em relação ao futuro. (FORTSCH; KHAPALOVA, 2016).

A necessidade de planejar surge do requisito de se trabalhar no presente em atividades que serão requisitadas como demanda futura. Porém, a realidade das organizações não é estática. A dinâmica de mudanças dos negócios em alguns casos pode ser gradual ou, em outros, podem ser súbitas. (FERREIRA; LEE; SIMCHI-LEVI, 2016). Os mercados também estão expostos a condições semelhantes. Um produto pode ter demanda constante por anos, enquanto outro produto pode desaparecer antes mesmo da fase de desenvolvimento de projeto ser finalizada. Serviços podem apresentar alta demanda em um período, ter baixa procura em outro período e serem substituídos por outros serviços inéditos na sequência.

As técnicas de previsões permitem transformações das informações empresariais estratégicas para prever a demanda por novos produtos, novas tecnologias, novas participações de mercado ou a melhor estratégia competitiva. Afinal, as empresas necessitam planejar as suas operações e vendas de seus

produtos ou serviços no futuro. (SELLITTO et al., 2017). Essa expectativa é o ponto de partida para muitas outras decisões.

Entender a demanda por um produto ou serviço é um processo complexo e que envolve a relação de diversos fatores. Compreender o efeito de cada um dos principais fatores e como eles interagem, seria construir um modelo matemático que apresente uma estimativa exata da demanda futura. Entretanto, entender os efeitos da competição, dos fenômenos econômicos, das propagandas e das alternativas de fornecimento para o produto não é algo simples. Por outro lado, é possível desenvolver algum mecanismo ou algum sistema de interação de fatores geradores de demanda e pode-se usar as teorias estatísticas e matemáticas para construir um modelo com um efeito satisfatório (GREEN; ARMSTRONG, 2015).

A previsão de demanda é um processo racional de busca de informações sobre as quantidades das vendas futuras de um item ou de um conjunto de itens. Algumas características são comuns entre os métodos de previsão e dentre elas está o fato de que as mesmas causas presentes no passado, configurando a demanda, estarão presentes no futuro. Também é possível reconhecer padrões de comportamento em séries históricas e prever o comportamento futuro. Outro modo é identificar fatores causais que afetam o comportamento e extrapolá-lo, segundo um modelo matemático. (ARVAN et al., 2019).

Outra característica comum a todos os métodos de previsão são os erros, e que por isso, os métodos não levam a resultados perfeitos. Isso devido a fatores aleatórios e que exercem influência no resultado das previsões. (SYNTETOS; BABAI; GARDNER, 2015). Desse modo, quanto maior o horizonte de previsão maior será a chance de erro no futuro. Conhecer se a demanda por produtos ou serviços está aumentando ou diminuindo não é suficiente. O fluxo de informações, conhecimento, produto ou recursos entre essas entidades deve ser gerenciado adequadamente para maximizar a lucratividade geral e conhecer a taxa de mudança é fundamental no planejamento do negócio. (CORTEZ et al., 2018a).

Os métodos de previsão de demanda basicamente são classificados em métodos qualitativos e métodos quantitativos. (ARVAN et al., 2019). Métodos qualitativos não requerem manipulação de dados e somente julgamentos são utilizados para criar a previsão, já os métodos quantitativos não requerem julgamento, sendo procedimentos padronizados que produzem resultados objetivos.

3.3.1 Métodos Qualitativos

Os métodos de previsão de demanda qualitativos, também chamados de métodos baseados no julgamento, são fundamentados no julgamento e experiência de pessoas que tenham condições de opinar sobre a demanda futura. (PETROPOULOS et al., 2018). São apropriados para criar cenários futuros, quando há disponibilidade de poucos dados relevantes para elaboração da previsão, como padrões e relações causais. (SEIFERT et al., 2015). São bastante úteis na ausência de dados, quando os dados não são confiáveis ou no lançamento de novos produtos. (ARVAN et al., 2019).

3.3.1.1 Julgamento por Especialistas

Um dos métodos qualitativos de previsão de demanda é o julgamento por especialistas, também chamado de abordagem de painel, que tem como base utilizar a opinião e a experiência de especialistas para criar a predição de demanda. (ARMSTRONG; GREEN, 2019; ARVAN et al., 2019). Os especialistas realizam individualmente a previsão e depois as partes são combinadas para se chegar à previsão agregada. As previsões são de longo prazo, envolvendo aspectos do planejamento estratégico da empresa.

A auto alavancagem por julgamento permite que dados preditos por especialistas sejam utilizados em modelos matemáticos, fazendo com que julgamentos subjetivos sirvam como base de informação em procedimentos estruturados. Para tanto, são inicialmente identificadas as informações utilizadas pelos especialistas na predição de demandas, e então, os especialistas elaboram previsões para diversos casos, reais ou hipotéticos. (ARVAN et al., 2019). Os dados resultantes são convertidos para um modelo estimando uma regressão em função do conjunto de previsões coletadas. (SEIFERT et al., 2015).

3.3.1.2 Delphi

O método Delphi emprega um questionário que é enviado a especialistas, cujas respostas são analisadas, resumidas e retornadas anonimamente aos respondentes. (NIKOLOPOULOS et al., 2015). Segundo de Løe et al. (2016) a

técnica Delphi foi desenvolvida na década de 1950 para estruturar a comunicação em grupo e a interação entre painéis de especialistas, com o objetivo de prever a ocorrência de eventos ou tendências através de processos iterativos.

Normalmente é composto de uma equipe de cinco a vinte especialistas. Anonimamente, os especialistas respondem formulários emitindo, e justificando, as suas previsões. O processo é repetido até que haja pouca alteração nas previsões entre as rodadas. (VON BRIEL, 2018). Duas ou três rodadas geralmente são suficientes, e o resultado da previsão será a mediana ou a moda das previsões finais dos especialistas. (ARVAN et al., 2019). De acordo com Kudlak et al. (2018), o método Delphi é frequentemente aplicado a fenômenos complexos e sub-explorados na previsão de ciência e tecnologia, previsão de negócios e elaboração de políticas participativas.

3.3.1.3 Método de Analogia Estruturada

O método de analogia estruturada utiliza como referência os comportamentos passados com a finalidade de ajudar a prever o resultado de uma nova situação, por meio de analogias. Conforme Jun et al. (2017), é uma tentativa consciente e deliberada de aproveitar a experiência histórica, envolvendo uma comparação sistemática de algo a ser previsto com elementos anteriores que se acredita ter sido semelhante em todos ou em alguns aspectos mais importantes.

No método de analogia estruturada um administrador prepara uma descrição da situação objetivo e seleciona especialistas que conheçam situações análogas, preferencialmente que possuam experiência direta. (JUN et al., 2017). Então os especialistas identificam e descrevem situações similares, classificam sua semelhança com a situação-alvo e combinam os resultados de suas analogias com resultados potenciais dessa situação-alvo. Dessa forma, o administrador deriva uma analogia de cada especialista com a mais semelhante aos demais especialistas, obtendo uma previsão análoga por especialista. (ARMSTRONG; GREEN, 2019).

3.3.1.4 Pesquisa de Intenção e Opinião

As pesquisas de intenção e opinião são utilizadas para verificar as intenções de compra ou padrões de comportamento referentes a determinadas condições.

Neste método devem ser consideradas surveys que possuam significância estatística para generalizações. (ARMSTRONG; GREEN, 2019). Porém, por vezes são usados grupos focados para esse fim, entretanto, neste caso não se trata de uma amostra significativa da população. As análises conjuntas também fazem parte deste grupo quando a pesquisa é realizada com a intenção de perceber os atributos que levariam a uma opção de compra ou a um padrão de comportamento. (JUN et al., 2017).

3.3.2 Métodos Quantitativos

Os métodos de previsão de demanda quantitativos, também conhecidos como métodos matemáticos, utilizam modelos matemáticos para se chegar aos valores previstos. (REN et al., 2016). Os métodos matemáticos permitem controlar o erro e são divididos em métodos causais e séries temporais.

3.3.2.1 Modelos Causais

Nos modelos causais a demanda de um item ou conjunto de itens possui relação de causa e efeito com uma ou mais variáveis internas ou externas à empresa, chamadas de variáveis causais. A demanda por um produto poderia ser prevista por meio de uma função de variáveis como preço, país de origem e assim por diante. (KATSIKOPOULOS et al., 2018). No método causal a previsão de demanda é altamente correlacionada com certos fatores no ambiente, como por exemplo, fatores da economia e a taxa de juros de um país. Nos modelos causais os dados seguem um comportamento identificável ao longo do tempo e existem relações identificáveis entre as informações que se deseja prever e outros fatores (ARVAN et al., 2019).

Um modelo de regressão é um relacionamento entre o que se pretende prever, denominado variável dependente (Y), e os fatores que determinam o valor de Y , denominadas variáveis independentes (X_i). (KATSIKOPOULOS et al., 2018). O modelo de regressão simples analisa a relação entre duas variáveis, onde os dados apropriados para este método consistem em observações, cada uma delas com duas medidas diferentes. (GREEN; ARMSTRONG, 2015). A regressão é significativa quando a variável dependente se relacionar de modo significativo com as variáveis

independentes. (FANG; LAHDELMA, 2016). A regressão simples pode ser representada pela equação (1), ou seja, Y é uma função de X:

$$Y = f(X) \quad (1)$$

onde

Y = variável dependente (demanda)

X = variável independente ou variável causal

Quando a variável dependente está ligada exclusivamente a uma variável independente, existem diferentes possibilidades para sua função, dentre os formatos mais utilizados estão:

$$Y = a + bX \quad (2)$$

$$Y = ab^x \quad (3)$$

$$Y = a + bX + cX^2 \quad (4)$$

onde

a, b, c = representam valores numéricos constantes (parâmetros)

A equação (2) é uma regressão linear simples que assume o formato de uma reta. A equação (3) contém uma regressão exponencial que possui o formato exponencial. Já a equação (4) é uma regressão parabólica em formato de parábola.

O modelo de regressão múltipla pode ser expresso pela função exposta na equação (5).

$$Y = f(X_1, X_2, \dots, X_n) \quad (5)$$

onde

X_1, X_2, \dots, X_n = conjunto de n variáveis independentes

Na regressão múltipla, existem muitas possibilidades de formato da função e do número de variáveis independentes a se considerar. Porém, é amplamente utilizada a regressão linear múltipla, representada na equação (6). (WANG; LI; LI, 2018). Esta regressão chama-se linear, porque todas as variáveis independentes possuem expoente igual a um.

$$Y = b_0 + b_1X_1 + b_2X_2 + \dots + b_nX_n \quad (6)$$

onde

$b_0, b_1, b_2 \dots b_n$ = são os parâmetros

São apresentados diferentes métodos na literatura para resolver problemas não lineares. Para regressão simples não linear utilizando a função exponencial é possível aplicar a equação (7):

$$Y' = A + BX \quad (7)$$

Por meio da função parabólica, o cálculo da regressão ocorre pelas equações (8), (9) e (10).

$$\sum Y = na + b \sum X + c \sum X^2 \quad (8)$$

$$\sum XY = a \sum X + b \sum X^2 + c \sum X^3 \quad (9)$$

$$\sum X^2 Y = a \sum X^2 + b \sum X^3 + c \sum X^4 \quad (10)$$

O método de Gauss-Newton, ou da linearização, expande o modelo não-linear em uma série de Taylor aproximando-o por um modelo linear. No método de Gauss-Newton a soma dos quadrados dos erros é reduzida pressupondo que a função de mínimos quadrados é localmente quadrática e buscando encontrar o mínimo da potência quadrática. (LV et al.,2017). Outro método é e o método de Levenberg-Marquardt que, conforme Chae et al. (2016), é uma combinação de dois métodos de minimização: o método do gradiente descendente e o método de Gauss-Newton. Para o método do gradiente descendente, a soma dos quadrados dos erros é reduzida atualizando os parâmetros no sentido da maior redução dos mínimos quadrados. O método de Levenberg-Marquardt está mais para o método de gradiente descendente quando os parâmetros estão longe de seu valor ideal. Por outro lado, quando está mais próximo da convergência, o método Levenberg-Marquardt comporta-se como o método de Gauss-Newton. (SHAIKH; JI, 2016).

Conforme Wang, Li e Li, (2018) e Deb et al., (2017), os resultados da regressão não linear são representativos se: (i) o modelo possui justificativa, pois a regressão apenas ajusta parâmetros da equação escolhida; (ii) os erros são normais, possuem variância constante, são independentes em relação a Y e não-correlacionados entre si; (iii) a imprecisão na medição de Y é pequena perante sua variabilidade; (iv) o resultado apresentado faz sentido científico, e (v) as estatísticas obtidas são aceitáveis.

3.3.2.2 Séries Temporais

A modelagem de séries temporais, também chamada de modelagem univariada, geralmente usa o tempo como uma variável de entrada sem outras variáveis explicativas externas. É definida como um conjunto de observações geradas sequencialmente no tempo. (BOROOJENI et al., 2017). A análise de séries temporais examina o padrão de comportamento passado de um fenômeno ao longo do tempo para prever o comportamento futuro. (VILLANI et al., 2017). Assim, este método exige o conhecimento de valores passados da demanda, ou da variável que se quer prever, indicando uma coleção de valores da demanda tomados em instantes específicos de tempos. Quando evolui com o tempo é classificada como um processo estocástico, mas se o desvio padrão varia ao longo do tempo, os dados da série temporal são definidos como não estacionários. (FORTSCH; KHAPALOVA, 2016). São utilizados para fazer previsões de curto prazo quando os valores das observações ocorrem conforme um padrão de comportamento identificável ao longo do tempo. (ZHU et al., 2015).

Nos métodos quantitativos por séries temporais a expectativa é que o padrão observado nos valores do passado forneça subsídios para a previsão da demanda futura. É possível decompor séries temporais em quatro componentes (DEB et al., 2017; TRATAR; MOJŠKERC; TOMAN, 2016), também chamados de padrões de demanda, comportamentos ou efeitos associados a série temporal, conforme descrito abaixo:

- a) Horizontal ou variações irregulares: são variáveis decorrentes de causas não identificadas e que ocorreram no curto e no curtíssimo prazo, diferentemente dos ciclos de negócios. Por ocorrerem ao acaso, estas variações não podem ser previstas por nenhum modelo de previsão;
- b) Efeito de tendência: confere à demanda uma tendência crescente ou decrescente com o tempo. Existe a possibilidade, também, da demanda permanecer estacionária, variando sempre próximo de um valor médio;
- c) Efeito sazonal: representa o fato de que a demanda de determinados produtos assume comportamentos semelhantes em épocas bem definidas do ano;
- d) Ciclo de negócios: são flutuações econômicas de ordem geral, de periodicidade variável, resultantes de uma multiplicidade de causas ainda

em debate. São movimentos típicos das economias capitalistas modernas e de difícil previsão.

As variações de uma série temporal que não possuam interpretação e explicações por meio dos quatro componentes citado anteriormente são decorrentes de ruído aleatório no processo gerador dos dados. (TRATAR; MOJŠKERC; TOMAN, 2016). Esse ruído não é matematicamente modelável, porém pode ser tratado ou seu efeito atenuado por filtros, entre eles, pode-se citar o filtro de Kalman.

Nos modelos de decomposição, as séries são compostas por quatro componentes, detalhados anteriormente: tendência, sazonalidade, ciclos de negócios e variações irregulares. Esta decomposição é a tentativa de se isolarem os diferentes componentes, com exceção às flutuações irregulares, de tal modo que os efeitos possam ser tratados individualmente.

A combinação dos componentes em uma série é separada fundamentalmente em modelo aditivo e modelo multiplicativo. (AFILAL et al., 2016a; FORTSCH; KHAPALOVA, 2016). O modelo aditivo trata a série como sendo composta pela soma dos componentes, expresso pela equação (11).

$$Y = (T) + (S) + (C) + (i) \quad (11)$$

onde

Y = valor da série (demanda prevista)

T = componente de tendência

S = componente de sazonalidade

C = componente cíclica

i = resíduo devido a flutuações irregulares

Para as quantidades de T , S , C e i os valores são expressos em unidades de demanda que se somam.

O modelo multiplicativo bastante utilizado, é representado pela equação (12). (FORTSCH; KHAPALOVA, 2016).

$$Y = (T).(S).(C).(i) \quad (12)$$

onde os componentes têm os significados já expostos.

No modelo multiplicativo apenas a tendência é expressa em unidades de demanda e as demais quantidades são expressas em porcentagens dessa tendência. O modelo multiplicativo pode ser simplificado caso admita-se que o horizonte de previsão é curto o suficiente para estar sempre na mesma fase do ciclo de negócios, fazendo com que C seja igual a 1. Além disso, admitindo-se ainda que os efeitos sazonais e as variações ao acaso possam ser reunidos em um só efeito, o modelo simplificado passa a ser. (AFILAL et al., 2016a):

$$Y = (T).(S) \quad (13)$$

onde

S incorpora o efeito sazonal e as variações ao acaso.

Os valores de T são determinados por meio da linha de tendência, ajustada conforme os valores reais da demanda segundo uma regressão simples em que a outra variável é o tempo. Os valores de S são intitulados índices sazonais e a sua determinação é feita pela observação do afastamento dos valores reais da demanda e dos valores previstos pela linha de tendência no passado. Neste sentido, a previsão Y também pode receber o nome de previsão corrigida pelo efeito sazonal.

Existe um conjunto de modelos utilizados como métodos das médias. Entretanto, vale ressaltar que a previsão é sempre obtida por intermédio de algum tipo de média que se tem como base valores reais anteriores da demanda. Ao contrário do que acontece com as regressões, é possível apenas prever um período à frente, apesar da possibilidade de se conceber adaptações para a obtenção de um maior número de previsões futuras. Além disso, a cada nova previsão são excluídos, ou mais fracamente ponderados, os valores mais antigos da demanda real e incorporados os mais novos, isso devido as médias serem móveis. (VAN DER LAAN et al., 2016).

No modelo de Média Móvel Simples (MMS), a previsão para o período t , ou seja, imediatamente futuro, é obtida pela média aritmética dos n valores reais da demanda imediatamente passados. A demanda é variável e pode ser suavizada usando diversos períodos anteriores. (FORTSCH; KHAPALOVA, 2016). A média móvel simples pode ser um método eficiente nos casos em que a demanda é estacionária, quando ela varia em torno de um valor médio. (LI et al., 2017). Embora

identifique uma variação na média, este método faz com que a reação seja lenta. Porém, em situações de demandas crescentes ou decrescentes no decorrer do tempo a tendência é de que a previsão fornecida por MMS esteja sempre atrasada em relação aos valores reais. Portanto, este método não se caracteriza como muito eficiente para captar as variações sazonais, podendo até inclusive escondê-las, de acordo com o valor escolhido para n .

O modelo da Média Móvel Ponderada (MMP) tem semelhança com o modelo MMS ao considerar n valores reais anteriores da demanda para a composição da média. Por outro lado, os valores recebem pesos distintos, visando uma maior importância atribuída aos valores mais recentes da demanda. Assim, os valores mais recentes da demanda recebem maior importância, possibilitando revelar alguma tendência. (VAN DER LAAN et al., 2016). Entretanto, quanto maior for o valor n , mais a previsão suavizará os efeitos sazonais e mais lentamente responderá a variações na demanda.

Também é bastante utilizado o modelo da média móvel exponencialmente ponderada quando a demanda é variável e pode ser suavizada usando períodos anteriores. (TRATAR, 2015). Neste modelo as demandas recentes são mais relevantes para o período atual e o peso da relevância diminui exponencialmente à medida que há afastamento do período presente. (FORTSCH; KHAPALOVA, 2016).

No modelo da Média Móvel Exponencialmente Ponderada de 1ª ordem (MMEP1) a previsão atinge apenas um período imediatamente à frente. Mas com adaptações possíveis, pode-se estender a previsão para vários períodos à frente. O modelo MMEP1 possui as vantagens de suavizar os picos de dados, dados anteriores são considerados, o peso atribuído aos dados passados é progressivamente menor e o seu cálculo é simples, necessitando apenas dos dados mais recentes. (LUCAS; ZHANG, 2016). A previsão para o período t , neste modelo, é dada pela equação (14).

$$D_t = D_{t-1} + \alpha(Y_{t-1} - D_{t-1}) \quad (14)$$

onde

D_t = previsão para o período t

D_{t-1} = previsão para o período $(t - 1)$

α = constante de suavização

Y_{t-1} = demanda real no período $(t - 1)$

Para qualquer período de previsão desejado, haverá sempre a necessidade da previsão do período imediatamente anterior. Sendo assim, ao se iniciar uma sequência de previsões deve-se obter o primeiro valor de alguma outra maneira que não por meio da equação. Além disso, é preciso definir o valor da constante de suavização em um intervalo entre zero e um.

Outro modelo bastante parecido com o MMEP1 é a Média Móvel Exponencialmente Ponderada de 2ª Ordem (MMEP2), que corresponde ao que se chama de "dupla suavização" ou "duplo alisamento", demonstrado pela equação (15). É o mesmo modelo utilizado na MMEP1, porém o MMEP2 é aplicado sobre a previsão obtida pelo MMEP1.

$$D'_t = D'_{t-1} + \beta(D_{t-1} - D'_{t-1}) \quad (15)$$

onde

D'_t = previsão de 2ª ordem para o período t

D'_{t-1} = previsão de 2ª ordem para o período $(t - 1)$

β = constante de suavização de 2ª ordem

D_{t-1} = previsão de 1ª ordem no período $(t - 1)$

Para β , assim como em α , os valores variam entre zero e um. Então a previsão com a MMEP1 assume o papel que cabia aos dados reais e a nova previsão com a MMEP2 apresenta-se mais suavizada, ou seja, menos sujeita a variações bruscas. Além disso, em um dado instante de tempo, observa-se ser aproximadamente válida a relação:

$$Y - D = D - D' \quad (16)$$

A diferença entre a demanda real e a previsão gerada pela MMEP1 é aproximadamente igual à diferença entre esta última e a previsão pela MMEP2. Tal relação permite corrigir a lacuna gerada entre a previsão de 1ª ordem e a demanda real, denominado como correção do efeito de tendência. Por meio dessa correção é

desenvolvida uma terceira previsão com valores reais mais próximos dos reais e escrita da seguinte maneira:

$$D_c = D + (D - D') = 2D - D' \quad (17)$$

onde

D_c = demanda corrigida pelo efeito de tendência

Existe ainda os modelos de suavização exponencial que usa uma ponderação para cada valor observado na série temporal, de modo que valores mais recentes recebam pesos maiores. Desse modo, os pesos formam um conjunto que decai exponencialmente a partir de valores mais recentes. A suavização exponencial aplica a suavização dos picos, porém, o peso atribuído aos dados passados é progressivamente menor. Utiliza o princípio de que os dados mais recentes devem receber pesos maiores, além de suavizar as flutuações cíclicas para prever a tendência. (FORTSCH; KHAPALOVA, 2016).

A previsão de demanda pela suavização exponencial é realizada por meio dos cálculos da média e da tendência, utilizando-se como base dados históricos. (SYNTETOS; BABAI; GARDNER, 2015). Entretanto, deve-se primeiro limpar e dessazonalizar os dados, por meio da seleção de fatores de suavização razoáveis.

Os métodos de suavização exponencial trazem como diferencial a possibilidade de identificar informações geradas pela série e explorar as influências apresentadas nas observações. Neste sentido, quando um fato externo provoca mudanças de valores da variável em estudo, a consequência deste fato já está contemplada nos valores observados passados que resultarão em respostas futuras. (DEB et al., 2017).

Dentre os métodos bastante utilizados, está a suavização exponencial simples, chamado método linear de Holt. O método de Holt pode ser utilizado em séries temporais com tendência linear. (TRATAR; MOJŠKERC; TOMAN, 2016). Este método emprega duas constantes de suavização, α e β , com valores entre 0 e 1. O método de Holt é representado pelo conjunto de equações abaixo:

$$L_t = \alpha z_t + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad (18)$$

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \quad (19)$$

$$z_{t+k} = L_t + KT_t \quad (20)$$

As equações (18) e (19) fazem uma estimativa do nível e da inclinação da série temporal, respectivamente. Já a equação (20) calcula a previsão da demanda para os próximos k períodos.

Assim como na suavização exponencial simples, o método de Holt requer valores iniciais para L_0 e T_0 . Uma alternativa para estes cálculos iniciais é utilizar em L_0 o último valor observado na série temporal e calcular uma média da declividade nas últimas observações para L_0 . Uma outra forma de cálculo é a regressão linear simples aplicada aos dados da série temporal, onde se obtém o valor da declividade da série temporal e de L_0 em sua origem.

Os valores das constantes de suavização no método de Holt podem ser determinados de forma semelhante à usada na suavização exponencial simples; ou seja, uma combinação de valores para α e β que minimize a média do quadrado dos erros. (TRATAR, 2015).

Já os métodos de Winters descrevem dados de demanda onde existe a ocorrência de tendência linear e de um componente de sazonalidade. De acordo com Aboagye-Sarfo et al. (2015), os modelos de Winters são divididos em aditivo e multiplicativo. O método aditivo possui a amplitude da variação sazonal constante ao longo do tempo. No método multiplicativo, a amplitude da variação sazonal aumenta ou diminui em função do tempo.

O método multiplicativo de Winters, utilizado em situações em que os dados de amplitude do ciclo sazonal variam com o passar do tempo, é representado abaixo:

$$L_t = \alpha \frac{z_t}{S_{t-s}} + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad (21)$$

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \quad (22)$$

$$S_t = \gamma \frac{z_t}{L_t} + (1 - \gamma)S_{t-s} \quad (23)$$

$$z_{t+k} = (L_t + KT_t)S_{t-s+k} \quad (24)$$

onde

S = período completo de sazonalidade (exemplo: igual a 12 quando os dados são mensais e a sazonalidade é anual)

L_t = nível da série

T_t = tendência

S_t = sazonalidade

z_{t+k} = previsão para k períodos

γ = constante de suavização que controla o peso relativo à sazonalidade e varia entre 0 e 1

Para dar início aos cálculos, os métodos de Winters necessitam valores iniciais para nível, tendência e sazonalidade. Para a estimativa da sazonalidade é preciso ao menos um período sazonal completo de observações. Estimativas iniciais do nível e da tendência são realizadas no período S definido para o componente sazonal.

Para o método aditivo de Winters, conforme segue o conjunto de equações abaixo, são utilizados dados sazonais em que a amplitude do ciclo sazonal permanece constante com o passar do tempo. (PETROPOULOS et al., 2018). O cálculo da tendência é o mesmo do método multiplicativo, entretanto, o componente sazonal possui operações de soma e subtração, em oposição a multiplicar e dividir.

$$L_t = \alpha(z_t - S_{t-s}) + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad (25)$$

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \quad (26)$$

$$S_t = \gamma(z_t - L_t) + (1 - \gamma)S_{t-s} \quad (27)$$

$$z_{t+k} = L_t + kT_t + S_{t-s+k} \quad (28)$$

Valores iniciais de L_s e de T_s são obtidos de modo idêntico ao método multiplicativo. Os componentes sazonais são calculados pela equação (29).

$$S_1 = z_1 - L_s, S_2 = z_2 - L_s, \dots, S_s = z_s - L_s \quad (29)$$

Os Métodos Autorregressivos Integrados a Média Móvel ou Autoregressive Integrated Moving Average (ARIMA), também chamados de modelos de Box-Jenkins, foram propostos por George Box e Gwilym Jenkins nos anos 70. Os métodos ARIMA originam-se da ideia de que os valores de uma série temporal são altamente dependentes, portanto, cada valor pode ser explicado por valores prévios da série. (BRENTAN et al., 2017). A abordagem Box-Jenkins assume que o padrão de variabilidade nos dados é constante e o método usa um procedimento iterativo para ajustar um modelo de previsão baseado em padrões aleatórios e cíclicos de demanda para minimizar erros de previsão. (FORTSCH; KHAPALOVA, 2016).

Os modelos de Box-Jenkins preveem que muitos fenômenos não são de natureza determinística, devido à incidência aleatória de fatores desconhecidos e os padrões históricos não se repetem consistentemente. (FORTSCH; KHAPALOVA, 2016). Nestes casos, a previsão do valor futuro está sujeita a um cálculo de probabilidade e são aplicados métodos matemáticos para analisar tais sistemas, ditos estocásticos. Processos estocásticos são caracterizados por um conjunto de variáveis aleatórias que descrevem a evolução de determinado fenômeno de interesse. Além disso, existe uma importante classe de modelos estocásticos utilizados na representação de séries temporais que são denominadas de modelos estacionários. (JOO; KIM, 2015). Esses modelos pressupõem um processo sob equilíbrio, onde o conjunto de variáveis permanece em um nível constante médio. Por outro lado, algumas séries temporais são melhor representadas por modelos não estacionários. (WANG et al., 2015).

Os modelos estocásticos partem da premissa de que uma série temporal, admitindo valores sucessivos e altamente dependentes, pode ser estimada a partir de uma série de ruído aleatório e transformada por meio de uma função matemática. (FORTSCH; KHAPALOVA, 2016). O ruído aleatório a_t é transformado na série temporal z_t , exposta na equação (30), por uma função de filtro linear que faz uma soma ponderada de ruídos aleatórios prévios.

$$z_t = \mu + \psi(B)a_t \quad (30)$$

$$B^m a_t = a_{tm} \quad (31)$$

$$\psi(B) = 1 + \psi_1 B + \psi_2 B^2 + \dots \quad (32)$$

onde

μ = nível do processo

B = operador de defasagem

$\psi(B)$ = função de transferência do filtro, ou operador de linha, que transforma

a_t em tendência de z_t

Estes modelos podem representar tanto séries estacionárias quanto séries não-estacionárias. Em uma sequência de ψ finita ou infinita e convergente, o processo z_t se caracteriza como estacionário e com média μ . Em situação oposta, z_t é não estacionário e μ torna-se um ponto de referência para o nível do processo em algum momento no tempo.

Na análise de séries temporais o coeficiente de auto correlação ρ descreve a correlação entre dois valores da mesma série temporal em diferentes períodos. (CARVALHO-SILVA et al., 2018). O coeficiente de auto correlação ρ mede a correlação entre dois valores adjacentes na série e a auto correlação é dita auto correlação de lag, ou defasagem. (VILLANI et al., 2017). Sendo assim, o coeficiente de auto correlação ρ_k mede a correlação entre observações distantes k períodos, dita auto correlação de lag k. (BOROOJENI et al., 2017).

$$\rho_k = \frac{E[(Z_t - \mu)(Z_{t-k} - \mu)]}{\sigma_x^2} \quad (33)$$

onde

σ_x^2 = variância da série temporal

Para uma estimativa do coeficiente de auto correlação populacional ρ_k é utilizado o coeficiente de autocorrelação amostral demonstrado na equação (34). (ZHU et al., 2015). O número de autocorrelações de lags diferentes é calculado para análise da série temporal pela relação $N/4$, onde N é o número total de observações na série.

$$\Gamma_k = \frac{\sum_{t=k+1}^n (z_t - \bar{z})(z_{t-k} - \bar{z})}{\sum_{t=1}^n (z_t - \bar{z})^2} \quad (34)$$

$$\bar{Z} = \frac{\sum_{t=1}^n Z_t}{n} \quad (35)$$

onde

$$k = 0, 1, 2, 3, \dots, N$$

Nos modelos estocásticos em que existe muitas observações das séries temporais, o modelo auto regressivo passa a ser aplicado como uma combinação linear finita de valores prévios do processo e um ruído aleatório a_t . (BOROOJENI et al., 2017). Neste modelo, os valores observados de um processo em espaços de tempo são igualmente divididos t , $t-1$, $t-2$, e assim por diante, por Z_t , Z_{t-1} , Z_{t-2} , etc. Além disso, são denominados, \tilde{Z}_{t-1} , \tilde{Z}_{t-2} , etc. como os desvios da média μ , representado na equação (36).

$$\tilde{Z}_t = Z_t - \mu, \tilde{Z}_{t-1} = Z_{t-1} - \mu, \tilde{Z}_{t-2} = Z_{t-2} - \mu, \dots \quad (36)$$

Um processo autorregressivo de ordem p , também chamado de $AR(p)$, é expresso na equação (37). É autorregressivo, porque o modelo linear ilustrado na equação (38) possui uma variável Z dependente a um grupo de variáveis independentes X_1 , X_2 , até X_p , com um termo de erro a e geralmente referido como um modelo de regressão, sendo Z regredido em X_1 , X_2 , ..., X_p .

$$\tilde{Z}_t = \phi_1 \tilde{Z}_{t-1} + \phi_2 \tilde{Z}_{t-2} + \dots + \phi_p \tilde{Z}_{t-p} + a_t \quad (37)$$

$$\tilde{Z}_t = \phi_1 \tilde{X}_1 + \phi_2 \tilde{X}_2 + \dots + \phi_p \tilde{X}_p + a_t \quad (38)$$

Os coeficientes autorregressivos ϕ_1 , ϕ_2 , até ϕ_p são parâmetros que descrevem como um valor corrente Z_t está relacionado com valores passados de Z_{t-1} , Z_{t-2} , até Z_{t-p} . Já o coeficiente autorregressivo de ordem p , usando a definição do operador B , pode ser representado matematicamente pelo modelo autorregressivo simplificado na equação (39).

$$\phi(B)\tilde{Z}_t = a_t \quad (39)$$

Para \tilde{Z} em modelos de média móvel, significa a observação Z_t subtraída da média μ , dependendo linearmente de um número finito q de valores prévios do ruído

aleatório a_t . Assim, obtém-se um processo de média móvel (MA) de ordem q , na equação (40), que expressa o valor atual de uma série temporal como valores atuais e q anteriores com ruídos aleatórios. (WANG et al., 2015). O coeficiente de média móvel θ , de ordem q , pode usar a definição do operador B e ser representado matematicamente, de modo simplificado, pela equação (41).

$$\tilde{Z}_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (40)$$

$$\tilde{Z}_t = \theta(B) a_t \quad (41)$$

Neste caso a série finita ilustrada na equação (42), não possui restrição sobre os parâmetros do processo de média móvel para assegurar estacionariedade.

$$\psi(B) = \theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q \quad (42)$$

A função de autocorrelação de um processo MA(q) é descrita pela equação (43).

$$\rho_k = \frac{-\theta_k + \theta_1 \theta_{k+1} + \dots + \theta_{q-k} \theta_q}{1 + \theta_1^2 + \dots + \theta_q^2} \quad (43)$$

onde

$$k = 1, 2, \dots, q$$

$$\rho_k = 0, \text{ quando } k > q$$

Porém, ocorrem casos em que algumas séries temporais são mais bem modeladas com a utilização de termos autorregressivos e de média móvel, resultando em um modelo misto de autorregressivo com média móvel de ordem (p , q), conforme equação (44). (JOO; KIM, 2015). Para tanto, utiliza-se a notação do operador de defasagem B , conforme a equação (45), sendo abreviado para ARMA (p , q). Os valores de p e q , na prática, são menores que 2 para séries temporais estacionárias. O valor da média móvel é obtido usando uma combinação linear dos movimentos dos erros passados e não simplesmente as médias ponderadas dos valores passados, advertem Fortsch e Khapalova, (2016).

$$\tilde{Z}_t = \phi_1 \tilde{Z}_{t-1} + \dots + \phi_p \tilde{Z}_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (44)$$

$$\theta(B) \tilde{Z}_t = \theta(B) a_t \quad (45)$$

Os modelos ARMA partem do pressuposto de que pode existir um algum tipo de comportamento uniforme no padrão histórico dos dados, que pode ser usado para prever a demanda, embora o comportamento geral das séries temporais possa mudar de um período para o seguinte. (WU; SONG; SHEN, 2017). Os comportamentos históricos podem incluir aleatoriedade, ciclicidade ou mesmo sazonalidade da demanda, que pode se repetir de maneira sequencial e previsível. (FORTSCH; KHAPALOVA, 2016). Para as condições de estacionariedade e de invertibilidade, um modelo ARMA (p, q) é estacionário se as raízes do polinômio $\Phi(B)=0$ estiverem fora do círculo unitário, bem como inversível caso as raízes de $\Phi(B)=0$ resultarem fora do círculo unitário.

Muitas séries temporais apresentam variações sazonais. São séries que possuem uma característica periódica que se repete a cada S intervalos de tempo, como o que acontece em séries compostas por observações mensais e de sazonalidade anual em que S é igual a 12. Nestes modelos chamados sazonais, tem-se um operador de diferença sazonal, (ZHU et al., 2015), descrito na equação (46), intitulados como a primeira diferenciação sazonal.

$$\Delta_x Z_t = (1 - B^S)Z_t = Z_t - Z_{t-S} \quad (46)$$

Muitas diferenciações sazonais, D, podem ser requeridas para tornar uma série estacionária. Portanto, a forma geral do modelo sazonal autorregressivo integrado a média móvel de ordem (P, D, Q) pode ser apresentado na equação (47). (ZHU et al., 2015).

$$\Phi(B^S)\nabla_S^D Z_t = \theta(B^S)a_t \quad (47)$$

onde

$\Phi(B^S)$ = polinômio em B^S de grau P

$\theta(B^S)$ = polinômio em B^S de grau Q

P, D e Q = letras maiúsculas para diferenciar da representação nos modelos não sazonais

Os componentes de erro a geralmente estão correlacionados, então, é utilizado um segundo modelo descrito na equação (48). (LUO et al., 2017).

$$\Phi(B)\nabla^d a_t = \theta(B)a_t \quad (48)$$

onde

a_t = processo de ruído aleatório

$\Phi(B)$ = polinômio em B de grau p

$\theta(B)$ = polinômio em B de grau q

Com base nas equações anteriores, é possível obter um modelo multiplicativo geral, exposta na equação (49), e chamado de processo multiplicativo de ordem (p, d, q) por (P, D, Q) . (LUO et al., 2017).

$$\Phi_p(B)\Phi_p(B^s)\nabla^d\nabla_s^D Z_t = \theta_q(B)\theta_q(B^s)a_t \quad (49)$$

3.3.3 Métodos com Base em Inteligência Artificial

Os métodos de previsão de demanda baseados em computação imitam algumas das capacidades de processamento do cérebro humano para modelar situações simples e complexas. Esses modelos que utilizam a inteligência artificial possuem a capacidade de identificar relacionamentos não lineares e interativos. Os métodos com base em inteligência artificial foram usados em sistemas de previsão de demanda ou como pré-processadores de dados para suavizar e classificar dados ruidosos para combinar as relações entre funções complicadas. (WANG; LI; LI, 2018).

Na última década, as redes neurais artificiais receberam bastante atenção de pesquisadores e são consideradas uma poderosa ferramenta computacional para resolver problemas complexos. As redes neurais são projetadas para captar padrões não lineares de séries temporais longas. (FIOT; DINUZZO, 2016). Técnicas neurais artificiais têm sido empregadas recentemente e com resultados bem-sucedidos em previsão de demanda e previsão de vendas em aplicações biomédicas, aeroespacial, indústria automotiva, segmento de eletrônica, setor financeiro etc. (RAZA; KHOSRAVI, 2015).

Redes neurais artificiais são técnicas de modelagem semelhantes ao funcionamento do cérebro humano. A rede de neurônios artificialmente

interconectados explora múltiplas hipóteses concorrentes por meio de processamento simultâneo. (QIU et al., 2017). No cérebro humano existe uma grande coleção de unidades de processamento chamadas neurônios que atuam em paralelo para o processamento e a coleta de dados. Os neurônios são conectados com pesos sinápticos e descobriu-se que essas conexões ou "pesos" são capazes de armazenar algum tipo de informação que pode ser recuperada posteriormente. (DEB et al., 2017).

A rede neural é composta de um conjunto de neurônios ligados entre si e apresentando diferentes coeficientes de conectividade. Os coeficientes de conectividade representam os pontos fortes das conexões. (REN et al., 2016). A aprendizagem acontece pelo ajuste da força de conexão para que os neurônios possam ser agrupados em camadas. A rede neural pode ser de camada única ou multicamadas. (CHAE et al., 2016). A rede neural multicamadas detém uma ou mais camadas ocultas entre a camada de entrada e a de saída da rede. Apresenta melhor capacidade de aprendizado e produz uma melhor saída do que a rede neural de camada única. (RAZA; KHOSRAVI,2015).

No modelo matemático da rede neural, o objetivo principal é identificar os pesos treinando o modelo com dados registrados no passado, que geralmente são organizados em conjuntos de entradas e saídas. (DEB et al., 2017). A rede neural extrai a relação não linear entre variáveis usando o processo de treinamento da rede. (KE et al., 2017). Esta rede pode aprender o comportamento da demanda usando a função de reorganização de padrão. No entanto, os padrões de saída são aprendidos aplicando os padrões de dados de treinamento de entrada para treinar a rede. (AIZENBERG et al., 2016).

Outro método que utiliza inteligência artificial, bastante comum, é a lógica difusa (Fuzzy Logic ou Lógica Fuzzy). Foi apresentada por Takagi e Sugeno (1985) como uma abordagem de análise numérica para sistemas difusos. São observações de séries temporais com valores linguísticos em vez dos valores numéricos convencionais de observações. Diferentemente dos métodos estatísticos, em séries difusas, não há hipóteses restritivas, como pressupostos estacionários ou lineares a serem cumpridas. Além disso, podem lidar com problemas ou situações não-lineares quando os conjuntos de dados são disponibilizados em termos linguísticos. (EFENDI et al., 2015).

Segundo Guo et al. (2018), geralmente a etapa inicial do projeto é particionar o universo de valores das séries temporais em intervalos iguais ou desiguais, e então conjuntos difusos são definidos com base nesses intervalos. É um sistema de regras “se então” que pode modelar os aspectos qualitativos do conhecimento humano e o processo de raciocínio sem o emprego de análises quantitativas. Os conjuntos difusos são normalmente constituídos de maneira subjetiva e não refletem totalmente os dados existentes. Apesar da especialização humana desempenhar um papel fundamental na formação de conjuntos difusos, as características dos dados não são totalmente capturadas dessa maneira. (GUO et al., 2018).

As relações lógicas difusas são formadas com base nos grupos de amostras. Então são determinados os grupos de relações lógicas difusas dividindo os relacionamentos lógicos difusos derivados em grupos, com base nos estados atuais. Assim, é possível usar esses relacionamentos lógicos para realizar a previsão. (EFENDI et al., 2015).

Existem muitas abordagens nas quais a lógica difusa pode ser determinada, inclusive, por meio de redes neurais artificiais devido à eficácia significativa da etapa de determinação da relação difusa no desempenho da previsão. Portanto, o desempenho da previsão pode ser significativamente aumentado pela utilização de redes neurais na determinação de relações difusas. (KOCAK, 2017). Os sistemas neuro-fuzzy combinam a lógica difusa baseados em regras com a capacidade de aprendizagem de redes neurais. Segundo Raza e Khosravi, (2015), a modelagem neuro-fuzzy tem sido reconhecida como uma ferramenta poderosa e que pode facilitar o desenvolvimento de novos modelos pela combinação de informações de diversas fontes, tais como modelos empíricos, heurística e dados.

Por outro lado, séries temporais aparentemente complexas têm sido melhor compreendidas usando modelos caóticos não-lineares em comparação com técnicas estocásticas. O método (k-nn) mais próximo é um dos métodos de previsão de fluxo caótico mais empregados. (TONGAL; BERNDTSSON, 2017). Um sistema caótico denota as flutuações da saída limitada a uma estrutura não-linear expressando um comportamento caótico que reage bem às condições iniciais e possui propriedade determinista onde existe uma correlação restrita nas leituras do sistema. (JAMIL; ZEESHAN, 2018).

Modelos caóticos descrevem fenômenos com leis de formação determinística, mas que, à primeira vista, parecem ser aleatórios. (SELLITTO et al., 2018). A teoria

do caos permite a avaliação da interação entre as variáveis e revela padrões complexos que governam o comportamento dos sistemas sem a necessidade de avaliar cada variável potencialmente relevante. Portanto, pode detectar com precisão padrões de processos dinâmicos determinísticos que podem parecer estocásticos e lidar com a escassez de dados, já que é capaz de discriminar padrões determinísticos e sistemas aleatórios genuínos sem a necessidade de conjuntos extensos de dados. (CORTEZ et al., 2018b).

Os modelos caóticos podem ser aplicados em pesquisas, e situações, similares a de Sellitto et al., (2017) sobre empresas que operam em cluster, no sentido de antever e prever aspectos estratégicos de produto e do negócio. Conforme exposto em Sellitto e Luchese, (2018), foram pesquisadas as práticas de cooperação entre concorrentes de um cluster e percebeu-se a necessidade de detectar a presença e, caso ocorra, medir a intensidade das dimensões de benefício mútuo, confiança e comprometimento subjacentes à cooperação em relação ao concorrente, podendo-se também fazer uso dos modelos caóticos.

Apesar de ser originado de regras determinísticas, pela recorrência de aplicação da regra e sob certas circunstâncias, os fenômenos caóticos passam a ser imprevisíveis a longo prazo. A extrema dependência das condições iniciais dos parâmetros determina que a produção de um fenômeno caótico se torne instável ao longo do tempo e por consequência os resultados de sistemas determinísticos, mesmo com leis de evolução definidas, são extremamente sensíveis a perturbações e ruído, tornando-os imprevisíveis. Mesmo na ausência de ruído, as não linearidades e interações entre os componentes amplificam erros mínimos nos parâmetros, gerando o caos determinístico. (SELLITTO et al., 2018).

As propriedades importantes para reconstruir a dinâmica dos sistemas caóticos são chamadas de dimensão de incorporação e atraso de tempo. A dimensão de incorporação corresponde ao número de variáveis que governam o sistema. O atraso temporal corresponde à influência temporal das variáveis, ou seja, por quanto tempo as mudanças das variáveis podem afetar o sistema. O Teorema de Taken, que é um dos teoremas mais conhecidos e usados para reconhecer o comportamento caótico em séries temporais indica que a dinâmica do sistema pode ser reconstruída pela reorganização da sequência de observações de séries temporais e que mudanças em suas formas fornecem informações significativas escondidas dentro da dinâmica do sistema. (CORTEZ et al., 2018a).

3.4 CONSIDERAÇÕES FINAIS

No presente artigo foi apresentada uma revisão sistemática da literatura dos métodos de previsão de demanda, reunindo os métodos e modelos disponíveis acerca dos conceitos utilizados atualmente na administração de empresas relacionados ao consumo e produção de produtos e serviços. Pôde-se contemplar os métodos qualitativos, quantitativos e com base em inteligência artificial em pesquisa acadêmica única, exposta em forma de síntese na Tabela 2. Também se evidenciou as diferentes técnicas e métodos empregados recentemente e que proporcionam resultados bem-sucedidos em previsão de demanda e previsão de vendas em aplicações diversas como biomédicas, aeroespacial, indústria automotiva, segmento de eletrônica, setor financeiro etc. (RAZA; KHOSRAVI, 2015).

Conhecer os conceitos para prever a demanda de produtos, serviços, materiais e otimizar a utilização dos recursos organizacionais possui significativa relevância tanto para acadêmica, quanto para as empresas e conseqüentemente para sociedade. Dentre as contribuições relacionadas à previsão demanda, estão os efeitos na qualidade, satisfação do cliente, custos e na eficiência operacional do negócio. (TRATAR, 2015). Assim, é possível afirmar que para previsões de longo, médio ou curto prazo o melhor método é aquele que fornece os valores mais próximos entre a previsão e a demanda real, independente do segmento de atuação empresarial.

Os métodos qualitativos são recomendados quando não há dados quantitativos históricos disponíveis ou quando estes dados não forem confiáveis. São métodos que utilizam a expertise da equipe de especialistas, o que permite alta flexibilidade e análises mais amplas sobre aspectos estratégicos. Os métodos qualitativos e os métodos causais demonstram ser simples na implantação e adaptarem-se melhor às previsões de médio e longo prazos. Os métodos causais são os que melhor representam a relação entre os fatores a serem previstos, bem como outros fatores internos e externos podem ser identificados e considerados. São úteis para prever pontos de inflexão na demanda e fornecem os subsídios para previsões mais sofisticadas.

Tabela 2 - Síntese dos métodos de previsão de demanda

	Método	Abordagem
Qualitativos	Julgamento por Especialistas	Utiliza a opinião e a experiência de especialistas para criar a predição de demanda. Os dados resultantes são convertidos para um modelo estimando uma regressão em função do conjunto de previsões coletadas. As previsões são de longo prazo, envolvendo aspectos do planejamento estratégico da empresa.
	Delphi	Emprega um questionário que é enviado a especialistas, cujas respostas são analisadas, resumidas e retornadas anonimamente diversas vezes aos respondentes. Aplicado a fenômenos complexos e sub-explorados na previsão de ciência e tecnologia, previsão de negócios e elaboração de políticas participativas.
	Método de Analogia Estruturada	Prepara-se uma descrição da situação objetivo e seleciona-se especialistas que conheçam situações análogas. Os especialistas identificam e descrevem situações similares, classificam sua semelhança com a situação-alvo e combinam os resultados de suas analogias com resultados potenciais dessa situação-alvo.
	Pesquisa de Intenção e Opinião	Utilizadas para verificar as intenções de compra ou padrões de comportamento referentes a determinadas condições. É realizada com a intenção de perceber os atributos que levariam a uma opção de compra ou um padrão de comportamento
Quantitativo	Regressão Linear: simples e múltipla	Avalia o relacionamento entre o que se pretende prever, denominado variável dependente (Y), e os fatores que determinam o valor de Y, denominadas variáveis independentes (Xi). Os dados consistem em observações, cada uma delas com medidas em períodos diferentes. São úteis para prever pontos de inflexão no comportamento da demanda e para previsões de longo prazo.
	Séries Temporais: Média Móvel Simples, Média Móvel Ponderada, Média Móvel Exponencialmente Ponderada, Suavização Exponencial, ARMA e ARIMA	Conjunto de observações geradas sequencialmente no tempo, que examina o padrão de comportamento passado de um fenômeno ao longo do tempo para prever o comportamento futuro. São utilizados para fazer previsões de curto prazo quando os valores das observações ocorrem conforme um padrão de comportamento identificável ao longo do tempo.
Inteligência Artificial	Redes Neurais	São projetadas para captar padrões não lineares de séries temporais longas. O modelo com dados registrados no passado, são organizados em conjuntos de entradas e saídas. A rede pode aprender o comportamento de saída da demanda usando a função de reorganização de padrão. Os padrões de saída são aprendidos aplicando os padrões de dados de treinamento de entrada para treinar a rede.
	Lógica Difusa	São observações de séries temporais com valores linguísticos em vez dos valores numéricos convencionais de observações. É um sistema de regras "se então" que pode modelar os aspectos qualitativos do conhecimento humano e o processo de raciocínio sem o emprego de análises quantitativas. São determinados os grupos de relações lógicas difusas dividindo os relacionamentos lógicos difusos derivados em grupos com base nos estados atuais, assim, possibilitam usar esses relacionamentos lógicos para realizar a previsão
	Sistemas Neuro-fuzzy	Combinam a lógica difusa baseados em regras com a capacidade de aprendizagem de redes neurais. Reconhecida como uma ferramenta poderosa e que pode facilitar o desenvolvimento de novos modelos pela combinação de informações diversas e a resolução de problemas complexos em previsão de demanda
	Modelos Caóticos	Avalia a interação entre variáveis e revela padrões complexos que governam o comportamento dos sistemas. Pode detectar com precisão padrões de processos dinâmicos determinísticos que podem parecer estocásticos e lida com a escassez de dados. Reconhece o comportamento caótico em séries temporais e indica a dinâmica do sistema que pode ser reconstruída pela reorganização da sequência de observações de séries temporais e as mudanças em suas formas fornecem informações significativas escondidas dentro da dinâmica do sistema.

Fonte: Elaborado pelo autor.

A análise de séries temporais, especificamente pelos métodos das médias e de suavização exponencial, indica melhores resultados nas previsões de curto prazo. São os métodos mais simples, oferecem bons resultados e são os mais utilizados em previsão de demanda de um modo geral. Além disso, requerem recursos computacionais pouco complexos.

Métodos que utilizam inteligência artificial modelam situações simples e complexas, e possuem a capacidade de identificar relacionamentos não lineares e interativos, sendo usados em sistemas de previsão de demanda ou como pré-processadores de dados para suavizar e classificar dados ruidosos para combinar as relações entre funções complicadas. São recomendados para aplicações que requerem análises de realidades complexas e por isso demandam de recursos operacionais e computacionais mais qualificados.

Porém, é necessário testar diversos modelos até encontrar o mais adequado ao caso específico que se está analisando. Mostrou-se um recurso utilizado em diversas realidades a construção de um modelo próprio de previsão de demanda utilizando aspectos, conceitos e características de diferentes modelos conceituais. Entretanto, é fundamental validar o modelo adotado e sempre mantê-lo sob controle, de maneira a poder efetuar correções dentro do menor prazo possível.

Estudos relacionados à previsão de demanda apresentam oportunidades de maiores pesquisas, sendo oportuna a incorporação de conceitos adicionais, como inteligência artificial, finanças e contabilidades de custos. Estudos envolvendo planejamento de capacidade operacionais, acuracidade das previsões, controle de recursos, bem como métodos de controle de custos integrados à previsão de demanda trariam significativa contribuição.

4 PREVISÃO DE DEMANDA EM UNIDADE DE PRONTO ATENDIMENTO DE COMPLEXIDADE INTERMEDIÁRIA

Este capítulo apresenta o artigo de proposta de um modelo de previsão de demanda para consultas de urgência em um serviço de urgência de um hospital de pronto atendimento. Este artigo será submetido ao Journal of Open Innovation: Technology, Market, and Complexity, ISSN: 2199-8531, SJR 2019: 0.780 e CiteScore 2019: 4.7.

Resumo: Os gerentes de hospitais estão cada vez mais prestando atenção ao departamento de emergência para fornecer serviços médicos de maior qualidade aos pacientes. É necessário encontrar soluções viáveis para melhorar a previsibilidade e a eficiência no uso dos recursos em departamentos de emergência. Este artigo propõe um modelo para prever o número de atendimentos diários em um hospital de pronto atendimento. Fornece a identificação do estágio atual do conhecimento em previsão de demanda de consultas de urgência em departamento de emergência e propõe uma metodologia para assertividade e ganhos de eficiência. Os resultados sugerem o modelo ARIMA (1,1,4) para clínico geral adulto e ARIMA (4,1,1) para pediatra. Recomenda-se previsões de 1 dia a frente até 14 dias de previsão, com erros próximos a 10%. Como modelo alternativo de previsão de demanda foi utilizado o modelo caótico pelo método do mapa logístico para previsão de curto prazo, incorrendo em baixo erro associado as previsões. O estudo demonstra a importância do uso de modelos matemáticos de previsão em serviços de departamento de emergência e como ferramenta de gestão.

Palavras-chave: Previsão de demanda, ARIMA, Modelos caóticos, Mapa logístico, Departamento de emergência, Serviço de saúde, Qualidade em serviço de saúde

4.1 INTRODUÇÃO

As unidades de pronto atendimento brasileiras são caracterizadas como serviços de atendimento de saúde de complexidade intermediária situada entre a Atenção Básica de Saúde, a Atenção Hospitalar e a Rede Hospitalar (MS, 2013). Bastante similar, em termos de complexidade, ao Serviço Nacional de Saúde (NHS) do Reino Unido. (ORDU; DEMIR; TOFALLIS, 2019a; ORDU; DEMIR; TOFALLIS, 2019b). São serviços que, na maioria dos casos, possuem alto índice de variabilidade, superlotação e uma demanda maior do que a capacidade de recursos instalados, causando tempo de espera excessivo impactando na qualidade do atendimento e na segurança dos pacientes.

Os gerentes do hospital estão cada vez mais atentos ao departamento de emergência, a fim de oferecer um serviço de melhor qualidade aos pacientes. (AFILAL et al., 2016b). Pacientes que saem insatisfeitos do departamento de emergência por não serem avaliados por um médico passam a ser considerados

importante indicador de qualidade. A realidade atual provocada pela pandemia do COVID-19 aumentou ainda mais a busca por um maior planejamento de operações e alocação de recursos. (VACCARO et al., 2020). Adicionalmente, a contenção de custos é uma das principais dificuldades enfrentadas pelos hospitais, assim, passa a compor como solução para melhorar a qualidade dos serviços de saúde a maximização da eficiência dos recursos existentes e a redução de perdas com foco em produtividade. (BHAT; GIJO; JNANESH, 2016).

Os desafios relacionados à demanda e custos estão cada vez maiores nos sistemas de saúde de países desenvolvidos. Estes sistemas lutam para lidar adequadamente com a demanda. (ABOAGYE-SARFO et al., 2015). Compreender o histórico de chegada dos pacientes por hora, por dia e por semana, auxilia na previsão e gestão dessa demanda e de recursos. (ORDU; DEMIR; TOFALLIS, 2019a). Para se fazer previsões de demanda, em um dos modos, é preciso identificar os padrões de comportamento com base em séries históricas de dados e, então, por meio de um modelo matemático prever o comportamento futuro. (AFILAL et al., 2016b). As previsões de demanda abrangem o grau de disponibilidade do produto ou serviço e são necessárias como elemento qualificador para uma melhor tomada de decisão. (FORTSCH; KHAPALOVA, 2016).

As empresas necessitam planejar as suas operações em relação à oferta de produtos ou de serviços. A previsão de demanda é uma metodologia para estimar um valor futuro de uma grandeza de interesse. As previsões são elemento necessário no processo de tomada de decisão sobre o futuro. (PETROPOULOS et al., 2018). Realizar previsões de demanda significa reconhecer padrões de comportamento em séries históricas e prever o comportamento futuro, ou ainda, identificar fatores causais que afetam o comportamento e extrapolá-lo. (CALEGARI et al., 2016).

Neste sentido, é necessário encontrar soluções viáveis para melhorar a previsibilidade e a eficiência no uso dos recursos em departamentos de emergência, tais como o ajuste dos recursos humanos e no fluxo dos processos. Este tipo de análise permite fornecer uma visão sistêmica e integrada das perdas nos processos organizacionais e indicar os passos a serem priorizados para eliminar tais perdas. (BAUER et al., 2019).

O tema da previsão de demanda indica ser atual e relevante para as instituições da área de saúde. As consequências de uma escala de trabalho

inadequada são inúmeras e prontamente percebidas. Afetam a qualidade de atendimento, satisfação do cliente, riscos nos processos, o custo e prejudicam a eficiência operacional do hospital. (ORDU; DEMIR; TOFALLIS, 2019a) Portanto, questionou-se como prever a demanda de consultas de urgência em um hospital de pronto atendimento?

Assim, o objetivo deste estudo é de propor um modelo de previsão de demanda para consultas de urgência em um hospital de pronto atendimento. O artigo está separado em quatro seções. A seção 3.2, conta com o referencial teórico sobre previsão de demanda relacionada aos hospitais de pronto atendimento, onde os conceitos são tratados tomando como base o ponto de vista dos principais autores. A abordagem e a metodologia de estudo são descritos na seção 3.3. Na seção 3.4 estão descritos os modelos probabilísticos escolhidos e a utilização dos dados disponibilizados, bem como é considerada a viabilidade dos modelos propostos, a relevância, os principais resultados do trabalho e as implicações gerenciais de sua utilização. As considerações finais e sugestões de novos estudos são apresentadas na seção 3.5.

4.2 REFERENCIAL TEÓRICO

Existe uma base comum e importante a todos os planejamentos que é a previsão de demanda. As previsões de demanda, portanto, possuem importante papel na gestão de organizações e todas as empresas necessitam planejar. A dinâmica de mudanças dos negócios em alguns casos pode ser gradual ou, em outros, podem ser súbitas. (FERREIRA; LEE; SIMCHI-LEVI, 2016). As empresas necessitam planejar as suas operações e vendas de seus produtos ou serviços no futuro. (SELLITTO et al., 2017). Entender a demanda por um produto ou serviço é um processo complexo e que envolve a relação de diversos fatores.

É possível desenvolver algum mecanismo ou algum sistema de interação de fatores geradores de demanda e pode-se usar as teorias estatísticas e matemáticas para construir um modelo com um efeito satisfatório (GREEN; ARMSTRONG, 2015). A previsão de demanda é um processo racional de busca de informações sobre as quantidades das vendas futuras de um item ou de um conjunto de itens. Assim, é possível reconhecer padrões de comportamento em séries históricas e predizer o comportamento futuro, bem como identificar fatores causais que afetam o

comportamento e extrapolá-lo, segundo um modelo matemático. (ARVAN et al., 2019).

4.2.1 Hospital de Pronto Atendimento

As unidades de pronto atendimento devem acolher os usuários e seus familiares sempre que buscarem atendimento médico. Devido à presença dos clientes no sistema, ao considerar o valor para o paciente neste ambiente é de maior importância a segurança e a eficiência do que o custo e a eficácia. O objetivo principal é fornecer cuidados de saúde imediatos e precisos. (CARVALHO-SILVA et al., 2018). Segundo o Ministério da Saúde, o atendimento deve ser resolutivo e qualificado aos pacientes acometidos por quadros agudos ou agudizados de natureza clínica. Deve operar também na prestação do primeiro atendimento aos casos de natureza cirúrgica e de trauma, estabilizando os pacientes, realizando a investigação diagnóstica inicial com a finalidade de definir, em todos os casos, a necessidade ou não de encaminhamento a serviços hospitalares de maior complexidade. É realizada retaguarda às urgências atendidas pela rede de atenção básica à saúde e funciona como local de estabilização de pacientes atendidos pelo serviço de atendimento móvel de urgência (SAMU).

O serviço de pronto atendimento também oferece consulta médica em regime de pronto atendimento aos casos de menor gravidade e presta apoio diagnóstico e terapêutico. Além disso, deve manter pacientes em observação por um período de até 24 horas para fins de elucidação diagnóstica e/ou estabilização clínica. (MS, 2013). Suas atribuições contemplam o encaminhamento para internação em serviços hospitalares nos casos em que os pacientes não tiverem suas queixas resolvidas nas vinte e quatro horas de observação. O atendimento prestado é caracterizado como um serviço de complexidade clínica, cirúrgica e traumática ao usuário. (MS, 2013; ORDU; DEMIR; TOFALLIS, 2019a; ORDU; DEMIR; TOFALLIS, 2019b).

4.2.2 Métodos de Previsão de Demanda em Departamento de Emergência

Os hospitais vivem atualmente uma intensa pressão em relação à disponibilidade e uso de recursos operacionais. Para poder lidar efetivamente com

essa realidade, a gerência precisa descobrir com precisão quantos pacientes devem usar seus serviços no futuro. (KLUTE et al., 2019). Isso se aplica não apenas a um serviço específico, mas a todos os serviços hospitalares. Apoiar os gestores a lidar melhor com a demanda e planejar com eficiência os recursos de que dispõe, tem sido o objetivo de pesquisas acadêmicas e de aplicações empíricas. (JILANI et al., 2019; ORDU; DEMIR; TOFALLIS, 2019b).

Com base na revisão sistemática da literatura sobre previsão de demanda em serviço de saúde foram identificados os métodos de previsão de demanda atualmente utilizados, expostos na Tabela 3. A tabela permite uma visão geral sobre todos os métodos de previsão de demanda utilizados em departamento de emergência e contribui com a identificação das variáveis independentes e medidas de precisão aplicadas nas previsões, separados por autores.

Tabela 3 - Revisão da literatura sobre previsão de demanda em departamento de emergência

Autores	Método	Variáveis Independentes	Medida de Precisão da Previsão
Baia Medeiros, D. T. et al. (2019)	Regressão Linear	Ano	MAD
Benbelkacem, S. et al. (2019)	Aprendizado de Máquina: NB, C4.5 e SVM	Mês, dia da semana e hora do dia.	MAE, RMSE e ERA
de Brito, F. G. et al. (2019)	ARIMA	Dias da semana e mês	MAPE
Jilani, T. et al. (2019)	Lógica Difusa	Dias da semana e mês	MAPE e RMSE
Klute, B. et al. (2019)	Aprendizado de Máquina: XGBoost	Dia do mês, Dia da semana e hora do dia	FSE
Ordu, M., Demir, E. e Tofallis, C. (2019a)	ARIMA, Suavização Exponencial, Regressão Linear e STLF	Dias da semana, mês do ano e feriados. Número de pacientes, recursos físicos, recursos humanos, tarifas financeiras, pagamentos aos recursos humanos e outras informações exames laboratoriais, turnos e características demográficas.	MASE
Ordu, M., Demir, E. e Tofallis, C. (2019b)	ARIMA, Suavização Exponencial, Regressão Linear e STLF	Dia da semana, semana e mês. Feriados e separação por especialidades de atuação médica.	MASE
Whitt, W. e Zhang, X. (2019)	SARIMAX	efeitos de temperatura e feriados	MSE
Carvalho-Silva, M. et al. (2018)	ARIMA	Mês, dia da semana e hora do dia.	MAPE
Jiang, S., Chin, K. e Tsui, K. L. (2018)	Algoritmo Genético e Rede Neural	Dias da semana e hora do dia. Fatores Meteorológicos	MAPE e RMSE
Jiang, S. et al. (2017)	Algoritmo Genético e Rede Neural	Mês do ano, dia da semana e feriados. Fatores Meteorológicos	FS e RMSE
Juang, W. et al. (2017)	ARIMA	Mês do ano.	MAPE
Luo, L. et al. (2017)	SARIMA e Suavização Exponencial	Dia da semana	MAPE
Villani, M. et al. (2017)	SARIMA	Mês do ano. Gênero, tipo de diabetes e tipo de emergência.	MAE, MSE e MAPE
Afilal, M. et al. (2016a)	Séries Temporais	Dia da semana, semana e mês. Total de 8 categorias de necessidade de tratamento, basicamente separadas em pacientes internados e ambulatoriais	RMAP
Afilal, M. et al. (2016b)	Séries Temporais por Modelo Aditivo	Dia da semana, semana e mês. Total de 8 categorias de necessidade de tratamento, basicamente separadas em pacientes internados e ambulatoriais	MAE, RMAE e RMAP
Calegari, R. et al. (2016)	Suavização Exponencial Sazonal, Holt-Winters multiplicativo sazonal, SARIMA e MSARIMA	Dia da semana e mês do ano. Temperaturas mínima, média e máxima, amplitude da temperatura, volume de chuva, velocidade do ar, umidade relativa e horas insolação.	MAPE
Gopakumar, S. et al. (2016)	ARIMA, ARMAX, Regressão K-n, Regressão Aleatória e Regressão Vetorial	Dia da semana, número de pacientes no recurso enfermaria, 20 recursos para pacientes e 88 recursos no nível da enfermaria.	MAE, RMSE e MAPE
Gul, M. e Guneri, A. F. (2016)	Rede Neural	Dia da semana, mês e ano. Feriados e temperaturas máximas.	R^2 e Erro Absoluto

Fonte: Elaborado pelo autor.

Baia Medeiros et al. (2019) quantificaram o número de visitas, especificamente no atendimento de saúde mental e dependência, que o Toronto

Western Hospital recebeu entre os anos de 2012 a 2016 e utilizaram técnicas de regressão linear para prever a demanda futura do departamento de emergência. Além disso, empregaram um modelo de simulação de eventos discretos por cenários para avaliar os efeitos do ajuste da demanda e da capacidade no desempenho. Os resultados obtidos nesta análise mostraram que os tempos de espera provavelmente se deteriorarão se nenhum ajuste na capacidade do recurso for feito.

Benbelkacem et al. (2019), por meio de variadas técnicas de aprendizado de máquina estabeleceram uma metodologia para o gerenciamento de departamentos de emergência para prever o tempo de permanência dos pacientes no pronto-socorro, a fim de evitar situações de tensão. Para tanto, os dados foram coletados no departamento de emergência pediátrica do centro hospitalar regional de Lille, na França. Diferentes técnicas de aprendizado de máquina foram usadas para criar os melhores modelos de previsão, tendo os melhores resultados com os métodos Naive Bayes (NB), C4.5 e SVM.

De Brito et al. (2019) apresentam um modelo matemático para realizar as previsões de demanda em relação aos pacientes classificados como verdes, segundo o Sistema de Triagem de Manchester, no departamento de emergência de um município de Minas Gerais, Brasil. O modelo ARIMA (1,1,1) apresentou o melhor ajuste para essa previsão, comparando-os com base no erro percentual absoluto médio (MAPE).

Jilani et al. (2019) desenvolveram um modelo lógico difuso baseado em heurística para prever atendimentos de emergência e compararam com os modelos de média móvel integrada autorregressiva e de rede neural. Estes modelos foram testados para previsão de curto prazo, dias da semana, e de longo prazo, quatro meses à frente, por meio de séries temporais mensais em quatro departamentos de emergência do Reino Unido. Para avaliar a precisão da previsão utilizaram o (MAPE) e o erro quadrático médio da raiz (RMSE). O modelo lógico difuso de curto prazo proposto teve a melhor precisão, mostrando-se simples de implementar e não requerendo ajustes de periodicidade e sazonalidade.

Klute et al. (2019), com o objetivo de determinar o melhor método para prever a demanda por consultas ambulatoriais, compararam o aprendizado de máquina e diferentes métodos tradicionais. Ao todo foram avaliados 20 métodos de previsão de demanda, distribuídos em métodos tradicionais, híbridos e de aprendizado de máquina em dois locais diferentes de um ambulatório que integra um centro médico.

O melhor resultado de previsão de demanda foi determinado com base no menor erro padrão de previsão (FSE). O estudo apontou que as abordagens avançadas de aprendizado de máquina nem sempre proporcionaram os mais altos níveis de precisão. Métodos tradicionais podem superar o aprendizado de máquina com estruturas de dados lineares, enquanto a aprendizagem de máquina pode melhorar significativamente a capacidade de localizar os preditores certos para gerar resultados aprimorados.

Ordu, Demir e Tofallis (2019a) por meio de um conjunto de dados estatísticos do Serviço Nacional de Saúde da Inglaterra buscaram determinar a demanda das diferentes especialidades médicas. Foram utilizados os métodos ARIMA, suavização exponencial, regressão linear múltipla e decomposição sazonal e de tendências usando a função loess (STLF). Conforme o estudo, as melhores estimativas de demanda surgem de diferentes métodos de previsão e períodos de previsão. Apesar do método STLF ter sido aplicado pela primeira vez no contexto da previsão de cuidados de saúde, ele superou os outros métodos de previsão de séries temporais para as diversas especialidades, com base no método do erro médio absoluto em escala (MASE).

Ordu, Demir e Tofallis (2019b) desenvolveram um sistema de apoio à decisão combinando simulação de eventos discretos e técnicas de previsão comparativa para o gerenciamento do Hospital Princess Alexandra na Inglaterra. Foram considerados o período de abril de 2009 a janeiro de 2013 em duas condições de demanda, sendo uma baseada nas demandas de emergência e outra como demanda inesperada pelo fechamento de um departamento emergência nas proximidades. Para tanto, foram utilizados os métodos de previsão de demanda ARIMA, suavização exponencial, regressão linear e STFL, avaliados por meio do MASE. A pesquisa analisou como as demandas inesperadas são atendidas testando cenários cumulativos, fornecendo um suporte decisório para os gerentes de serviços e da gestão hospitalar, sugerindo que os hospitais devem adotar uma abordagem integrada para capturar demanda e capacidade usando previsão e simulação.

Whitt e Zhang (2019) realizaram as previsões de chegadas diárias e de ocupação horária em tempo real, por meio do histórico recente de chegada e partida dos pacientes e de variáveis exógenas como temperatura e feriados no hospital Rambam em Haifa, Israel. Com base em diferentes métodos de previsão de demanda, incluindo modelos de redes neurais artificiais, o modelo de média móvel

integrada autorregressiva sazonal com modelo de série temporal de regressores exógenos (férias e temperatura) (SARIMAX) mostrou-se o mais eficaz, utilizando o erro quadrático médio (MSE) como critério de avaliação.

Carvalho-Silva et al. (2018) estudaram os dados de chegadas de emergência do hospital de Braga por meio de modelos de previsão baseados em séries temporais. Foram utilizados modelos ARIMA. O melhor modelo para o período de teste foi o ARIMA (1,1,1) (1,0,1)⁷, conforme a avaliação da precisão da previsão baseada na métrica MAPE.

Jiang, Chin e Tsui (2018) exploraram uma estrutura integrada com alta precisão para prever o fluxo de pacientes em departamento de emergência sob diferentes níveis de triagem com base em redes neurais. Um algoritmo de seleção de recursos baseado em algoritmo genético (GA) foi aprimorado e implementado como uma etapa de pré-processamento a fim de explorar os principais recursos que afetam o fluxo do paciente e redes neurais profundas (DNN) foram empregadas como modelo de previsão de demanda com características de adaptabilidade e alta flexibilidade. A estrutura integrada proposta alcançou maior precisão da previsão nas métricas MAPE e RMSE em comparação com outros modelos estatísticos como modo linear generalizado (GLM), ARIMAX, rede neural artificial (ANN) e modelos de máquinas modernas (SVM-RBF, SVM linear, RF e R-LASSO).

Jiang et al. (2017) desenvolveram uma nova metodologia híbrida para prever a demanda dos pacientes por diferentes recursos-chave ambulatorial, combinando um novo método de seleção de recursos e uma abordagem de aprendizado profundo aplicada a um ambulatório localizado no nordeste da China. Uma versão modificada do algoritmo genético (MGA) foi proposta para a seleção de recursos e uma rede neural profunda de feedforward é introduzida como modelo de previsão de demanda. A combinação de algoritmo genético modificado e rede neural profunda pré-treinada apresentou o maior poder preditivo em comparação com os métodos regressão linear múltipla, ARIMAX e redes neurais artificiais rasas (SANN) pelos critérios RMSE e algoritmo de seleção de recursos (FS).

Juang et al. (2017) construíram um modelo ARIMA para prever o número de visitas mensais em departamento de emergência. O modelo ARIMA (0, 0, 1) foi considerado o mais adequado para prever futuras visitas de emergência, com base

na avaliação da precisão prevista do modelo identificado com o erro percentual absoluto médio (MAPE).

Luo et al. (2017) formularam um modelo sazonal ARIMA (SARIMA) em uma série temporal diária, um modelo de suavização exponencial único (SES) no dia da semana e, também, estabeleceram um modelo combinatório entre ambos, aplicando em dois departamentos de medicina interna de um grande hospital de Chengdu. Os modelos foram utilizados para prever os dados transversais por 7 dias consecutivos de consultas ambulatoriais diárias durante um período de 8 semanas, com base em 43 semanas de dados com duração de 1 ano. Foram comparadas a precisão da previsão com base no critério MAPE, e o modelo combinatório indicou extrair com mais eficiência as informações em profundidade de um tamanho finito de amostra de treinamento e obter melhor desempenho para prever visitas diárias ambulatoriais uma semana antes, com menor variação de resíduos e menor média relativa de erros residuais.

Villani et al. (2017) desenvolveram um modelo de previsões de atendimento pré-hospitalar para emergências diabéticas. Para tanto, realizaram uma análise de séries temporais em casos mensais de hipoglicemia e hiperglicemia nos dados do banco de dados eletrônico da Ambulance Victoria (AV) entre os anos de 2009 e de 2015. O modelo SARIMA (0,1,0,12) forneceu o melhor ajuste, com um MAPE de 4,2%, demonstrando ser uma ferramenta valiosa para permitir a previsão de casos futuros com alta precisão e prever casos crescentes de emergências diabéticas pré-hospitalares no futuro.

Afilal et al. (2016a) conduziram um estudo no departamento de emergência do Hospital de Troyes, na França, com o objetivo de prever o atendimento diário de pronto-socorro. Os modelos de previsão desenvolvidos por meio de séries temporais demonstraram ser adaptáveis a todas as categorias de fluxos do paciente. O desempenho dos modelos foi avaliado pelo critério do desempenho médio relativo absoluto (RMAP).

Afilal et al. (2016b) desenvolveram um trabalho de pesquisa com vistas à previsão de atendimento diário em um pronto-socorro, no departamento de emergência no centro hospitalar da cidade de Troyes, na França. Foi proposta uma nova classificação de pacientes no departamento de emergência e modelos ARMA para longo e curto de atendimento diário, sendo a avaliação das previsões realizadas pelo critério RMAP.

Calegari et al. (2016) testaram diferentes modelos matemáticos para prever visitas diárias de emergência no Hospital de Clínicas de Porto Alegre (HCPA) localizado no sul do Brasil. Os modelos testados foram suavização exponencial sazonal simples, Holt-Winters multiplicativo sazonal, média móvel integrada autorregressiva sazonal (SARIMA) e média móvel integrada autorregressiva multivariada (MSARIMA), e a precisão do modelo foi avaliada usando o MAPE. O desempenho dos modelos variou de acordo com a classificação dos pacientes, sendo a suavização exponencial sazonal simples a melhor escolha quando todos os tipos de pacientes foram considerados em conjunto e o SARIMA foi o mais preciso para modelar demandas de pacientes de maior urgência. Os modelos MSARIMA, considerando fatores climáticos, não melhoraram o desempenho dos modelos SARIMA, independentemente da classificação dos pacientes. Além disso, alguns fatores climáticos apresentaram correlação significativa com as séries de demanda de diferentes classes de pacientes, porém não aumentam a precisão da previsão quando incorporadas ao modelo.

Gopakumar et al. (2016) compararam os modelos de previsão de demanda ARIMA, ARMAX, regressão de vizinho mais próximo, regressão aleatória da floresta e suporte à regressão vetorial para prever o número total de descargas no dia seguinte de uma enfermaria aberta sem dados clínicos em tempo real. A qualidade da previsão foi medida usando erro médio de previsão, erro absoluto médio, erro percentual absoluto médio simétrico e erro quadrático médio da raiz. Os modelos aleatórios de regressão de floresta e vetor de suporte foram capazes de usar todos os recursos disponíveis dos dados, resultando em desempenho superior aos métodos autorregressivos tradicionais. O modelo ARMAX superou as previsões do ARIMA, pois incorporou informações sazonais como regressores externos.

Gul e Guneri (2016) analisaram as variações nas chegadas anuais, mensais e diárias no departamento de emergência de um hospital público em Istambul. Com base em modelos de regressão e redes neurais realizaram a previsão de chegadas de pacientes no departamento de emergência. Também foram adicionadas duas variáveis independentes aos modelos, feriados e valores máximos de temperatura da cidade de Istambul. Os resultados mostram que os modelos baseados em rede neural artificial têm valores mais altos de precisão e valores mais baixos de erro absoluto em termos de previsão das chegadas de pacientes no departamento de emergência a longo e médio prazo.

Portanto, sendo a literatura o critério para selecionar o modelo de previsão de demanda a ser aplicado neste estudo, e diante dos trabalhos contidos na Tabela 3, esta pesquisa é única ao evidenciar que o modelo ARIMA e suas variações foram os mais utilizados. O ARIMA, segundo Afilal et al. (2016a), Gopakumar et al. (2016) e Ordu, Demir e Tofallis (2019a), é amplamente utilizado em aplicações hospitalares e está entre os mais recomendados por apresentar os melhores desempenhos, conforme os achados contidos na literatura. Além disso, Klute et al. (2019) afirmam que os métodos de previsão de demanda tradicionais, em muitos casos, apresentam melhor performance em relação aos demais métodos, como o aprendizado de máquina.

Em Carvalho-Silva et al., (2018) diversos tipos de modelos de previsão foram testados e a escolha final foi para os modelos com base no método ARIMA. Este estudo também indica que os modelos ARIMA são uma das metodologias mais usadas para previsão de séries temporais, fornecendo abordagens complementares para o tema previsão de demanda. Para Whitt e Zhang (2019), para as previsões diárias, os modelos autorregressivos mostraram-se mais eficazes do que as redes neurais. Em Luo et al. (2017) a simplicidade de implementação e baixa intensidade computacional são diferenciais destes modelos e recomendam a aplicação para horizontes de previsão de curto prazo.

Conforme de Brito et al. (2019), Gul e Guneri (2016), Juang et al. (2017) e Villani et al. (2017) o método ARIMA tem sido aplicado amplamente e com resultados relevantes em departamento de emergência. Ordu, Demir e Tofallis (2019a) produziram em sua pesquisa os resultados mais acurados com ARIMA em previsões de taxas para internações não eletivas. Juang et al. (2017), concluíram que o modelo ARIMA pode ser considerado adequado para prever demanda em departamento de emergência, e seus resultados podem ser usados para auxiliar nos processos de tomada de decisão. Os modelos de séries temporais ARIMA, segundo Villani et al. (2017), preveem o número de casos pré-hospitalares de emergências diabéticas com alta precisão.

Em relação aos aspectos de construção do modelo de previsão de demanda em departamento de emergência, Calegari et al. (2016) constataram que alguns fatores climáticos apresentam correlação significativa com as séries de demanda de diferentes classes de pacientes, mas não aumentam a precisão da previsão quando incorporados ao modelo. Carvalho-Silva et al., (2018) avaliaram diversas variáveis

ambientais a fim de identificar sua relação com as chegadas no departamento de emergência e concluíram que a precipitação e a temperatura máxima apresentaram maior correlação com as chegadas, entretanto, com valores não significativos.

Whitt e Zhang (2019), exploraram as descobertas de diversos pesquisadores que tiveram o calendário e a variação do clima como elementos úteis para prever os totais diários de chegada em departamento de emergência e concluíram, por meio de diferentes arranjos de correlação, que o fator dia da semana é o mais importante. Percebe-se também que Gopakumar et al. (2016), Juang et al. (2017) e de Brito et al. (2019) apresentam um modelo adequado para a previsão de visitas mensais de emergência utilizando a metodologia ARIMA, construído sem considerar variáveis exógenas, alcançando desempenho bastante acurado.

4.2.3 Séries Temporais

Conforme de Brito et al. (2019) é necessário organizar permanentemente o departamento de emergência, por meio de um planejamento adequado e a utilização de séries temporais pode ser útil no gerenciamento da demanda, analisando o número de serviços executados ao longo do tempo. A análise dos dados do departamento de emergência é de fundamental importância para monitorar; planejar e intervir. Para fins de ajustes de capacidade e organização de recursos em departamento de emergência, Juang et al. (2017) indicam a necessidade de se prever as demandas destes serviços.

Uma série temporal é qualquer conjunto de observações ordenado no tempo. A observação do comportamento das necessidades em uma determinada população e a aquisição de conhecimento sobre a provável evolução da série nos períodos a frente é uma ferramenta importante no planejamento. (DE BRITO et al., 2019). Dentre os modelos de séries temporais amplamente utilizados, inclusive em aplicações em departamento de emergência, está o Método Autorregressivo Integrado a Média Móvel ou Autoregressive Integrated Moving Average (ARIMA). (DE BRITO et al., 2019; JUANG et al., 2017; GOPAKUMAR et al., 2016).

O método ARIMA, que faz parte dos modelos de Box-Jenkins, foi proposto por George Box e Gwilym Jenkins na década de 70. Os modelos de Box-Jenkins possuem como premissa que cada valor pode ser explicado por valores prévios da série, devido aos valores de uma série temporal apresentarem alta dependência.

(BRENTAN et al., 2017). A previsão de valores futuros está sujeita a um cálculo de probabilidade e são aplicados métodos matemáticos para analisar tais sistemas.

Os modelos de Box-Jenkins assumem que a variabilidade dos dados é constante e utiliza um procedimento iterativo para ajustar um modelo de previsão baseado em padrões aleatórios e cíclicos de demanda para minimizar erros de previsão. Classificado como processo estocástico, o método ARIMA é caracterizado por um conjunto de variáveis aleatórias que descrevem a evolução e o comportamento de determinado objeto de estudo. Neste caso, uma série temporal, admitindo valores sucessivos e altamente dependentes, pode ser estimada a partir de uma série de ruído aleatório e transformada por meio de uma função matemática. (FORTSCH; KHAPALOVA, 2016).

O princípio básico dos modelos ARIMA considera correlações de dados estudadas em diferentes momentos. Isso é feito combinando os modelos autorregressivo (AR) e média móvel (MA). (GOPAKUMAR et al., 2016). Os modelos ARIMA utilizam a notação ARIMA (p, d, q), em que p é a ordem do processo autorregressivo (AR), d é o grau de diferenciação envolvido (I) e q é a ordem do processo de média móvel (MA). Com o objetivo de tornar a série temporal estacionária, ou seja, remover eventual tendência, são feitas previamente diferenças d entre os dados. (CARVALHO-SILVA et al., 2018). A expressão matemática deste modelo é apresentada na equação (50).

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q} \quad (50)$$

onde

Y_t = valor variável no tempo t

ϕ = parâmetro autorregressivo

θ = parâmetro da média móvel

e_t = termo residual de distúrbios aleatórios que não podem ser previstos

Os modelos de Box-Jenkins preveem que diversos fenômenos estão expostos à incidência aleatória de fatores desconhecidos e os padrões históricos não se repetem consistentemente. (FORTSCH; KHAPALOVA, 2016). Esses modelos pressupõem um processo sob equilíbrio, onde o conjunto de variáveis permanece em um nível constante médio. (WANG et al., 2015).

4.2.4 Modelos Caóticos

Séries temporais complexas têm sido mais bem compreendidas por meio de modelos caóticos não-lineares. (TONGAL; BERNDTSSON, 2017). Os modelos caóticos descrevem fenômenos com leis de formação determinística, que em um primeiro momento parecem ser aleatórios. (SELLITTO et al., 2018). Os sistemas caóticos exprimem as flutuações de suas saídas associadas a uma estrutura não-linear, indicando um comportamento caótico que reage bem às condições iniciais e possui propriedade determinista onde haja correlação nas leituras do sistema. (JAMIL; ZEESHAN, 2018).

A teoria do caos permite a avaliação da interação entre as variáveis e revela padrões complexos que governam o comportamento dos sistemas. Modelos caóticos permitem detectar com precisão padrões de processos dinâmicos determinísticos que se assemelham ao comportamento estocástico e que possuem um conjunto escasso de dados. Assim, é capaz de discriminar padrões determinísticos e sistemas aleatórios genuínos sem a necessidade de conjuntos extensos de dados. (CORTEZ et al., 2018b).

A extrema dependência das condições iniciais dos parâmetros determina que a produção de um fenômeno caótico se torne instável ao longo do tempo e por consequência os resultados de sistemas determinísticos, mesmo com leis de evolução definidas, são extremamente sensíveis a perturbações e ruído, tornando-os imprevisíveis. (SELLITTO et al., 2018). Apesar da ausência de ruído, as não linearidades e interações entre os componentes amplificam erros mínimos nos parâmetros e proporcionam o caos determinístico. (CAPEÁNS et al., 2017).

As propriedades importantes para reconstruir a dinâmica dos sistemas caóticos são chamadas de dimensão de incorporação e atraso de tempo. (CORTEZ et al., 2018b). A dimensão de incorporação corresponde ao número de variáveis que governam o sistema e o atraso temporal está associado à influência temporal das variáveis, ou seja, por quanto tempo as mudanças das variáveis podem afetar o sistema. O comportamento caótico em séries temporais indica que a dinâmica do sistema pode ser reconstruída pela reorganização da sequência de observações de séries temporais e que mudanças em suas formas fornecem informações significativas escondidas dentro da dinâmica do sistema. (CORTEZ et al., 2018a).

Dentre os modelos caóticos, o mapa logístico apresenta-se como um processo simples e de feedback positivo que é oriundo de uma função quadrática própria. O mapa logístico fundamenta-se em uma relação de recorrência de comportamentos complexos e caóticos e que resultam da aplicação de uma regra determinística. (TARASOVA; TARASOV, 2017). A equação (51) apresenta o modelo do mapa logístico:

$$x_{(t+1)} = ax_t(1 - x_t) \quad (51)$$

onde

a = varia de 0 a 4

Caso a seja menor que 1 há convergência do resultado para 0. Quando a for inferior a 3, o processo tende para um valor fixo. Para a entre 1 e 3, o processo converge para s , conforme a equação (52).

$$s = \frac{(a-1)}{a} \quad (52)$$

onde

s = atrator fixo

O processo passa a adotar comportamento cíclico quando $3 < a < 3,57$, obtendo-se valores múltiplos e sendo caracterizado como um atrator cíclico. Valor de a entre 3,57 e 4 denotam em um comportamento oscilante, com resultado quase imprevisível atingindo a região de limite do caos, assemelhando-se a uma série temporal aleatória, com um padrão regular tendendo ao caos fora da ordem ou caos determinístico. Sendo a acima de 4 tem-se comportamento caótico. (CAPEÁNS et al., 2016).

4.2.5 Medidas de Acurácia

Medidas de acurácia e funções de perda são formas de transmitir informações sobre a capacidade de um determinado método de previsão prever dados reais. (ARMSTRONG; GREEN, 2019). Existem vários modelos que podem ser aplicados na previsão de valores futuros. O modelo mais apropriado é realizado com base no somatório dos erros gerados por cada modelo.

Erro é o componente aleatório presente nos modelos de demanda. Em seu conceito mais elementar, o erro de previsão (e_t), é definido como simplesmente a

diferença encontrada pela subtração da previsão de demanda e da demanda real para um período determinado. O cálculo dos erros pode resultar em valores positivos e negativos e as formas de cálculo constituem-se em critérios para escolha de modelos mais apropriados a séries temporais. (HYNDMAN; ATHANASOPOULOS, 2018).

Na regressão linear simples cada valor da variável causal corresponde a dois valores de demanda: um valor real (que realmente aconteceu) e um valor previsto obtido pela equação da função de previsão de demanda. Neste trabalho definimos Y como os valores reais e Y' como valores previstos. A diferença $(Y - Y')$, é chamada de erro de previsão. (AFILAL et al., 2016b). O erro da previsão para um dado X_i pode ser positivo ou negativo. O método dos mínimos quadrados (MMQ) é utilizado para determinação do erro de previsão de demanda, e busca ajustar uma função parametrizada para um conjunto de dados, minimizando o somatório do quadrado dos erros entre os dados e a função. (WHITT; ZHANG, 2019).

$$MMQ = \sum (Y_i - Y'_i)^2 \quad (53)$$

onde

$$i = 1, 2, 3, \dots, n, \text{ em que, } n \text{ é o número de pares } (X_i, Y_i)$$

Após realizar a previsão para um período futuro, é possível determinar um intervalo de confiança para essa previsão. Em outras palavras, significa um intervalo de valores tais que o valor real da demanda tenha uma probabilidade pré-fixada de estar dentro do intervalo. Portanto, a previsão Y' pode ser considerada como sendo uma média de uma distribuição normal de desvio padrão S_y , o qual é denominado de Erro Padrão da Estimativa e representado na equação (54). (ZHU et al., 2015).

$$S_y = \sqrt{\frac{\sum (Y - Y')^2}{n - 2}} \quad (54)$$

Um determinado intervalo de confiança é dado, aproximadamente, por $Y' \pm zS_y$, onde z é o número de desvios padrão que corresponde a uma dada área sob a curva normal. Esta área representa uma probabilidade de que o valor real da demanda caia dentro do intervalo especificado. Por meio da área (probabilidade) o valor de z pode ser obtido com base na tabela de áreas da curva normal reduzida.

Os critérios mais apropriados de medida de acurácia em séries temporais são: erro médio absoluto ou mean absolute error (MAE); erro quadrático médio ou root mean square error (RMSE) e a média absoluta percentual dos erros ou mean absolute percentage error (MAPE). (GOPAKUMAR et al., 2016). O erro percentual absoluto, ou APE's (absolute percentage errors) são os valores absolutos percentuais em que o MAPE faz a média.

Na equação (55) é apresentado a MAE e a RMSE na equação (56), que são dadas em unidades iguais à variável original. Valores mais próximos de zero, significam melhores resultados da previsão. Quando MAE ou RMSE são pequenos, a previsão está próxima da demanda real, e para um valor grande indica a possibilidade de grandes erros de previsão. (HYNDMAN; ATHANASOPOULOS, 2018). A MAE é a média dos erros de previsão ao longo de uma série de períodos, sem levar em conta se o erro foi superestimado ou subestimado.

$$MAE = \text{média}|Y_t - Y'_t| \quad (55)$$

$$RMSE = \sqrt{\text{média}(Y_t - Y'_t)^2} \quad (56)$$

onde

Y_t = valor real da demanda

Y'_t = previsão

Por outro lado, o MAPE apresentado na equação (57), é a relação percentual entre os erros e a demanda observada. (JOO; KIM, 2015). Seu uso é aconselhado para tomadores de decisão não acostumados às medianas e médias geométricas. Resultados mais próximo de zero, também terá a melhor adequação da previsão do modelo aos dados reais. (CALEGARI et al., 2016). O APE exposto na equação (58) indica o erro percentual absoluto da previsão.

$$MAPE = \frac{\left(\sum_{t=1}^n \left| \frac{Y_t - Y'_t}{Y_t} \right| \right)}{n} (100) \quad (57)$$

$$APE = \left| \frac{Y_t - Y'_t}{Y_t} \right| \quad (58)$$

Segundo Armstrong e Green (2019), o desempenho da previsão depende da medida a ser adotada e o MAPE torna-se uma opção eficiente quando se quer comparar previsões diferentes. Contudo, indica-se a MAE quando pequenos erros

são tolerados, porém não é desejável que se verifiquem grandes erros devido ao seu componente quadrático.

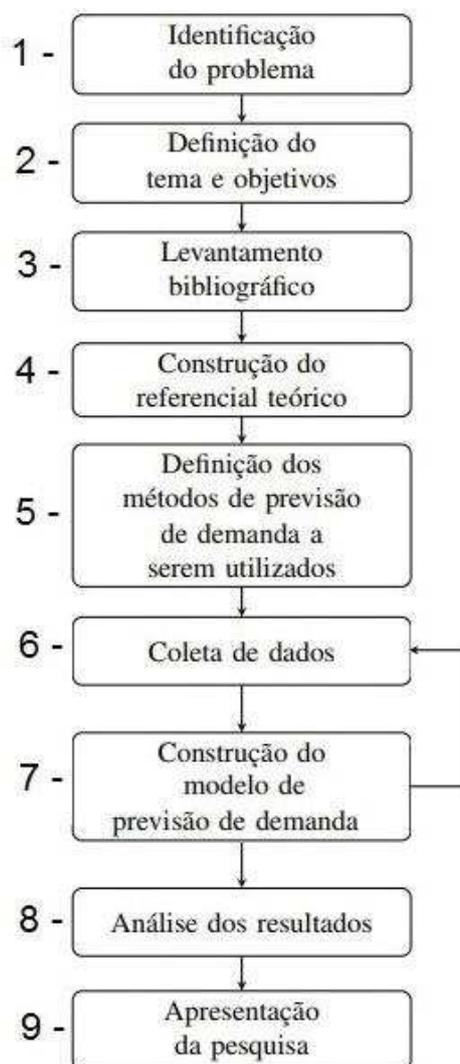
4.3 METODOLOGIA

A modelagem com o uso da simulação computacional é uma ferramenta de planejamento que se utiliza de relações lógicas e matemáticas com a finalidade de imitar o funcionamento de sistemas reais para observar seu comportamento sob situações diferentes. (GOPAKUMAR et al., 2016; BAIA MEDEIROS et al., 2019). Esta pesquisa utiliza da metodologia de pesquisa de modelagem quantitativa, sendo caracterizada como uma pesquisa empírica normativa quantitativa, pois tem como finalidade o desenvolvimento de estratégias e ações que melhorem a situação corrente em um serviço de urgência de um hospital de pronto atendimento (MIGUEL; FLEURY, 2018). Sua elaboração tem o propósito de fornecer a identificação do estágio atual do conhecimento referente a previsão de demanda de consultas de urgência em um departamento de emergência e por meio de um modelo probabilístico propor uma metodologia que proporcione assertividade e ganhos de eficiência no ambiente estudado.

A utilização de modelos, conforme Miguel e Fleury (2018), permite identificar problemas, formular estratégias e apoiar e sistematizar o processo de decisões. Por meio da utilização de um modelo é possível representar uma situação ou realidade de forma a auxiliar o tratamento da situação de maneira sistemática (RAZA; KHOSRAVI, 2015). Qiu et al., 2017 esclarecem que modelos quantitativos são modelos abstratos descritos em linguagem matemática e computacional que fazem uso de técnicas matemáticas, estatísticas e simulação, tendo como aplicação analisar os resultados de diferentes ações possíveis nos sistemas.

As etapas que compõem o método de trabalho desta pesquisa são apresentadas na Figura 2.

Figura 2 - Etapas do método de trabalho



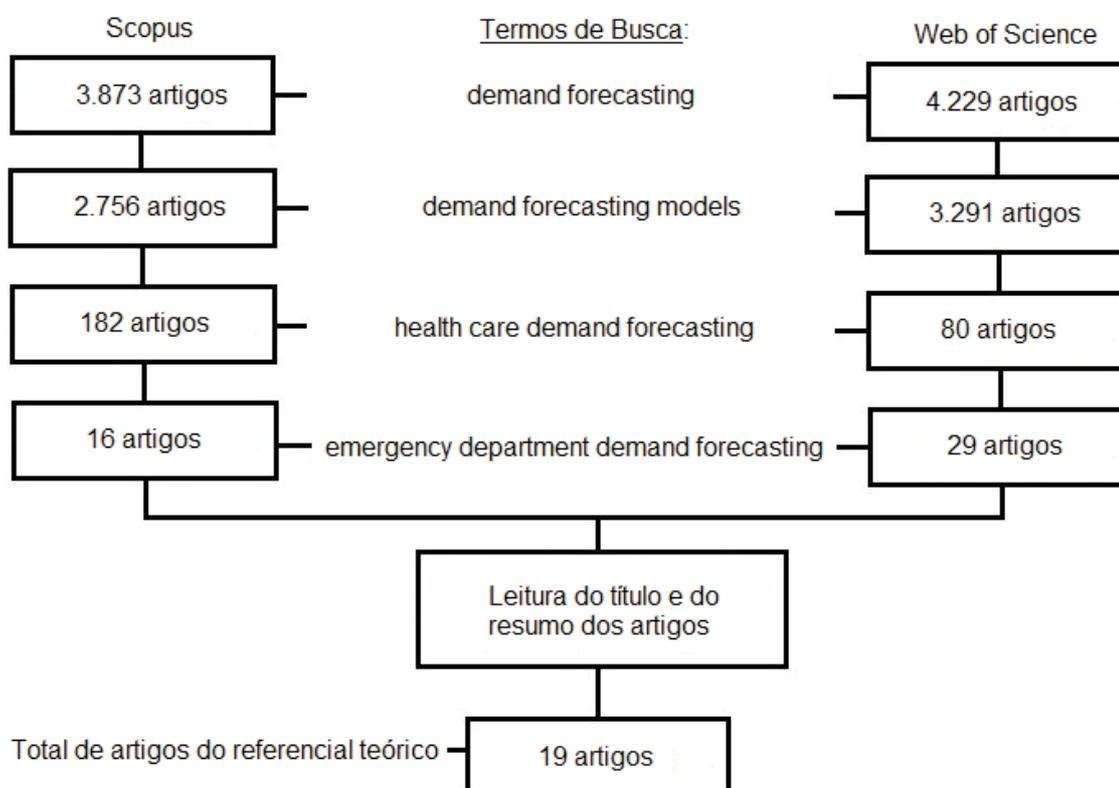
Fonte: Elaborado pelo autor.

O trabalho foi iniciado com a identificação do problema de pesquisa, seguido, na etapa dois, pela definição do tema de pesquisa e dos objetivos, com a delimitação do tema e justificativa de pesquisa. Na terceira etapa foi elaborado uma revisão sistemática da literatura com a finalidade de servir de base para a construção do referencial teórico sobre previsão de demanda em serviço de saúde nas bases de dados Scopus e Web of Science. Optou-se por ambas as bases de dados em função de possuírem os bancos de dados mais completos e adequados para as pesquisas sobre o assunto. (ZUPIC; ČATER, 2015; SCHAEFER et al., 2020).

As buscas, conforme o protocolo da revisão sistemática da literatura sobre previsão de demanda em serviço de saúde ilustrado na Figura 3, foram refinadas

pelos termos de busca demand forecasting, demand forecasting models, health care demand forecasting e emergency department demand forecasting, restringindo-as apenas a documentos do tipo “artigo” e em língua inglesa. Definiu-se documentos do tipo “artigo” devido a revisão ocorrer por pares, proporcionando assim resultados confiáveis. Foi utilizado o horizonte de tempo de publicação do ano de 2016 a 2019 como medida para se ter uma base de pesquisas recentes. (ZUPIC; ČATER, 2015). Foram desconsiderados artigos repetidos e que apresentaram temas e objetivos de pesquisa diferentes dos propostos neste trabalho.

Figura 3 - Protocolo da revisão sistemática da literatura sobre previsão de demanda em serviço de saúde



Fonte: Elaborado pelo autor.

A quarta etapa do trabalho foi a construção do referencial teórico com os 19 artigos resultantes do levantamento bibliográfico. Com base na leitura completa destes artigos, os achados do referencial teórico permitiram, na etapa cinco, definir os métodos de previsão de demanda que melhor se ajustam a realidade da pesquisa. Na sexta etapa, os dados de um período de 66 meses foram coletados do sistema de gestão informatizado de um Pronto Atendimento e Hospital Dia privado de propriedade conjunta e sem fins lucrativos localizado no Rio Grande do Sul. São

relevantes a quantidade de pacientes atendidos por dia, separados pelos especialistas da unidade de pronto atendimento.

Na etapa sete foi construído o modelo de previsão de demanda. A modelagem dos dados foi realizada com o uso do software Microsoft Excel para a coleta e organização dos dados do hospital de pronto atendimento e do software livre R Versão 3.6.2 para construção do modelo ARIMA de previsão demanda e análises estatísticas. (R DEVELOPMENT CORE TEAM, 2020). O software R é uma linguagem e ambiente para computação estatística que inclui análise de séries temporais. Um modelo alternativo de previsão de demanda foi proposto por meio de mapa logístico, e foi construído com o software Excel. A partir desse processamento de dados, foi definido um horizonte de previsão de 1, 7, 14 e 30 dias para as séries temporais, caracterizando assim previsões de curto prazo. A execução das simulações foi um processo dinâmico visando em um primeiro momento reproduzir a realidade e, após, gerar cenários futuros de possíveis demandas.

A análise dos resultados das simulações, etapa oito deste trabalho, incorreu no aprofundamento da verificação das informações geradas e na identificação da melhor performance de replicação da realidade do departamento de emergência objeto de pesquisa. A validação dos resultados, e consequentemente do modelo desenvolvido, foi caracterizada pela robustez das informações obtidas para uso em situação real de aplicação. A análise dos resultados das simulações também se caracterizou como um processo dinâmico em que com base nas informações geradas pelo modelo foram realizados os ajustes necessários no modelo de previsão de demanda desenvolvido na etapa anterior.

Como etapa final, portanto nona etapa do trabalho, tem-se a apresentação da pesquisa, contendo as conclusões, os resultados e as limitações impostas ao projeto, a inovação obtida na aplicação de ferramentas probabilísticas em previsão de demanda hospitalar, bem como as considerações a respeito dos resultados gerados na pesquisa.

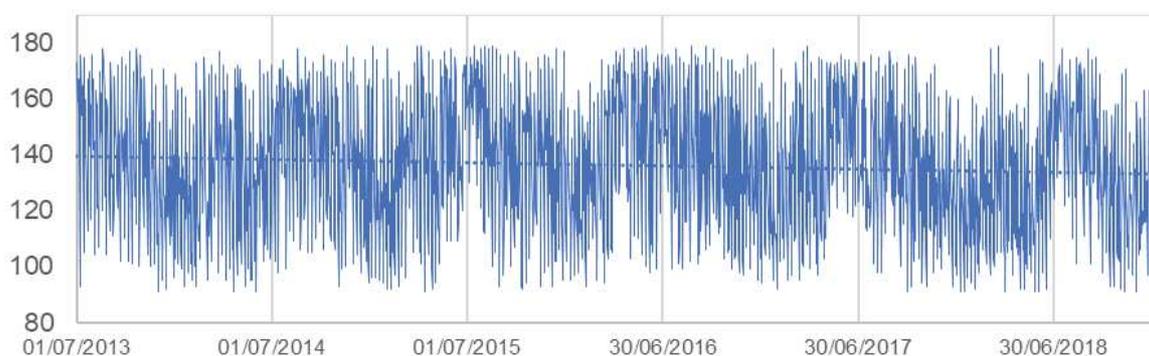
4.4 RESULTADOS E DISCUSSÃO

No período de análise deste estudo as duas especialidades de atendimento mais requisitadas no serviço de urgência, foram o clínico geral adulto sendo responsável por 58% dos atendimentos e o clínico geral pediátrico com 24% dos

atendimentos. Assim, definiu-se como objeto de pesquisa as especialidades de clínico geral adulto e clínico geral pediátrico. Com base nas séries temporais destes especialistas foi possível obter um modelo adequado para realizar as previsões dos números de atendimentos para os próximos dias.

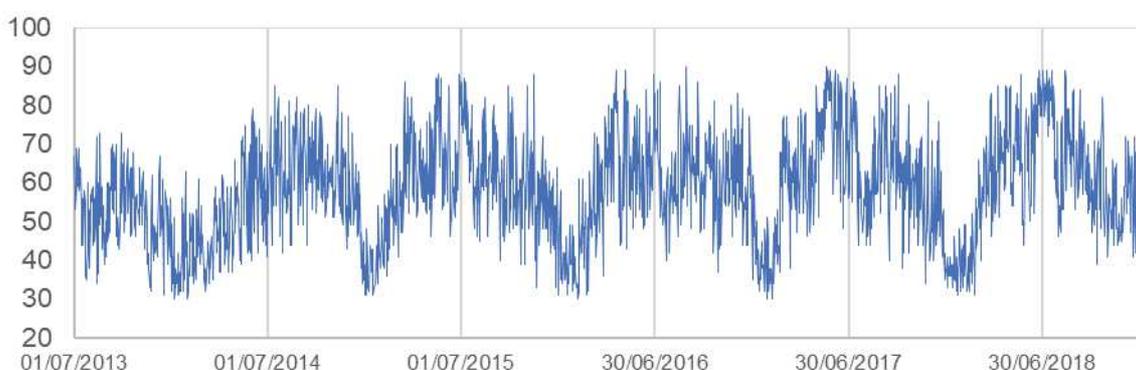
O primeiro passo na análise de uma série temporal é a construção de seu gráfico, que permite revelar características importantes como tendência, sazonalidade, variabilidade, outliers etc. (DE BRITO et al., 2019). A série cronológica original do número de pacientes atendidos por dia do clínico geral adulto está exposta no Gráfico 1 e do pediatra no Gráfico 2, sendo ambas as séries do período de 01 de julho de 2013 a 31 de dezembro de 2018. Não é possível perceber a presença de tendência e sazonalidade nas séries dos atendimentos das duas especialidades estudadas.

Gráfico 1 - Nº de consultas clínico geral adulto de julho 2013 a dezembro 2018



Fonte: Elaborado pelo autor.

Gráfico 2 - Nº de consultas pediatra de julho 2013 a dezembro 2018



Fonte: Elaborado pelo autor.

As séries temporais foram separadas em períodos diferentes em conjuntos de treinamento e de teste, estratégia que reflete a prática de treinar o modelo usando dados do passado, gerando as previsões de demanda e comparando com os valores reais, por meio das medidas de acurácia. (GOPAKUMAR et al., 2016; WHITT; ZHANG, 2019). Os dados de treinamento são usados para estimar os parâmetros do método de previsão e os dados de teste são usados para avaliar a precisão. Assim, os dados de teste não são usados para determinar as previsões e fornecem uma indicação confiável de quão bem o modelo gera as previsões. (HYNDMAN; ATHANASOPOULOS, 2018). Os dados de treinamento consistiram em 01 de julho de 2013 a 30 de novembro de 2018. Os dados de teste são do mês de dezembro de 2018, separados em conjuntos de 1, 7, 14 e 30 dias em função se estar trabalhando em previsão de curto prazo.

Além da inspeção gráfica, também é necessário realizar testes estatísticos das séries temporais a fim de verificar que elas sejam estacionárias, caso contrário, deve-se transformar os dados originais até torná-las séries estacionárias. A transformação mais comum é fazer diferenças sucessivas da série original até que uma série estacionária seja obtida (JOO; KIM, 2015). Outro recurso estatístico amplamente utilizado é a autocorrelação que é a dependência auto linear de uma variável em momentos diferentes, e indica a relação entre valores de uma mesma variável separados no tempo. Os testes de autocorrelação medem o grau de associação entre duas observações, Y_t e Y_{t-k} , eliminando-se os efeitos dos períodos anteriores a k (1,2,3,..., $k - 1$). (CARVALHO-SILVA et al., 2018).

Auto Correlação (ACF) é uma ferramenta estatística que avalia se os valores anteriores da série estão associados a valores posteriores e Auto Correlação Parcial (PACF) captura a quantidade de correlação entre uma variável e uma defasagem da referida variável que não é explicada pela correlação em todas as defasagens de ordem inferior, removendo o efeito das observações. (JUANG et al., 2017). Os testes de ACF e PACF evidenciaram forte correlação de chegadas em 7 dias nas séries de atendimentos de ambos os especialistas.

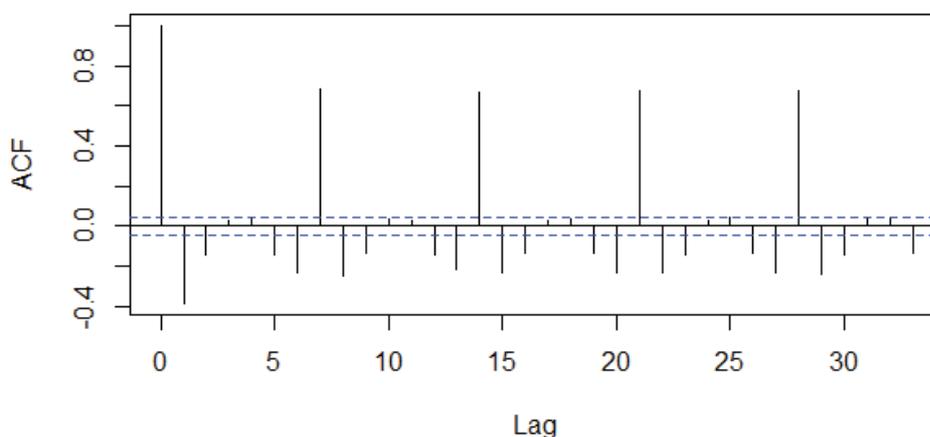
4.4.1 Previsões com Modelo ARIMA

Proposto por Box-Jenkins em 1976, o modelo ARIMA usa uma combinação dos componentes (p, d, q), em que p é a ordem do processo autorregressivo (AR), d

é o grau de diferenciação envolvido (I) e q é a ordem do processo de média móvel (MA). Nesta pesquisa foi utilizada uma versão automática com a função `auto.arima` da biblioteca `forecast` do software R, também aplicado em Gopakumar et al., (2016), Ordu, Demir e Tofallis (2019a) e Ordu, Demir e Tofallis (2019b), em que o componente d é escolhido com base em repetidos testes de raiz unitária de Kwiatkowski Phillips Schmidt Shin (KPSS) e depois são selecionados os valores de p e q , com base no menor resultado do Critério de Informação Akaike (AIC). (R DEVELOPMENT CORE TEAM, 2020).

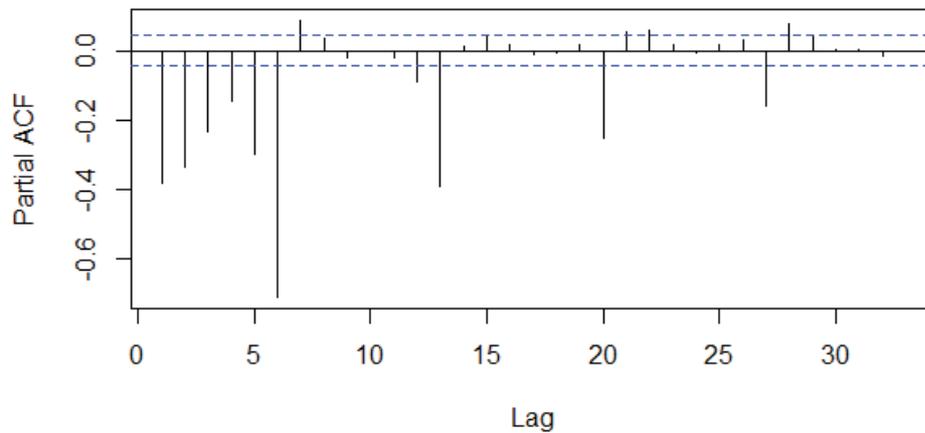
A função `auto.arima` resultou no modelo ARIMA (1, 1, 4) com MAPE de 13,69% para a especialidade de clínico geral adulto. O parâmetro d com valor de 1 indica que, visando tornar a série temporal estacionária para remover tendência, foi aplicada uma diferença entre os seus dados. Na Figura 5, percebe-se que por meio da PACF, p ser 1, em função da lag 1 apresentar maior valor em módulo até iniciar novo ciclo de 7 observações. Pela Figura 4, nota-se que por meio da ACF, q ser 4, devido à mudança de módulo em lag 4.

Figura 4 - Função autocorrelação da série temporal clínico geral



Fonte: Elaborado pelo autor.

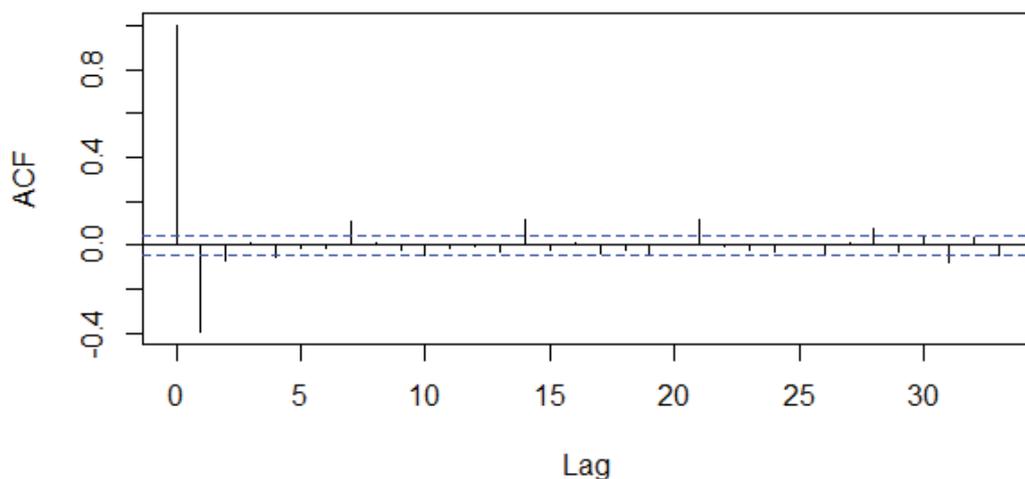
Figura 5 - Função autocorrelação parcial da série temporal clínico geral



Fonte: Elaborado pelo autor.

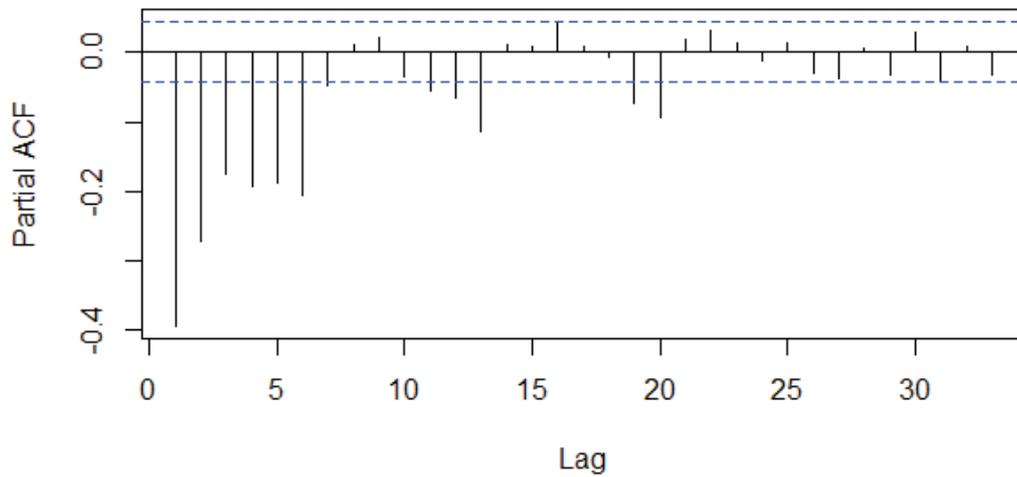
Para a especialidade pediatria a função auto.arima resultou no modelo ARIMA (4, 1, 1) com MAPE de 13,65%. No sentido de tornar a série temporal estacionária para remover tendência, foi aplicada uma diferença entre os seus dados, uma vez que o parâmetro d obteve valor igual a 1. Na Figura 7, percebe-se que por meio da PACF, p ser 4, já que da lag 1 a 3 encontra-se declinante e na lag 4 mostrar aumento repentino de valor em módulo. Pela Figura 6, nota-se que por meio da ACF, q ser 1, já que a lag 1 apresenta maior valor em módulo e os demais valores próximos a zero até iniciar novo ciclo de 7 observações.

Figura 6 - Função autocorrelação da série temporal pediatria



Fonte: Elaborado pelo autor.

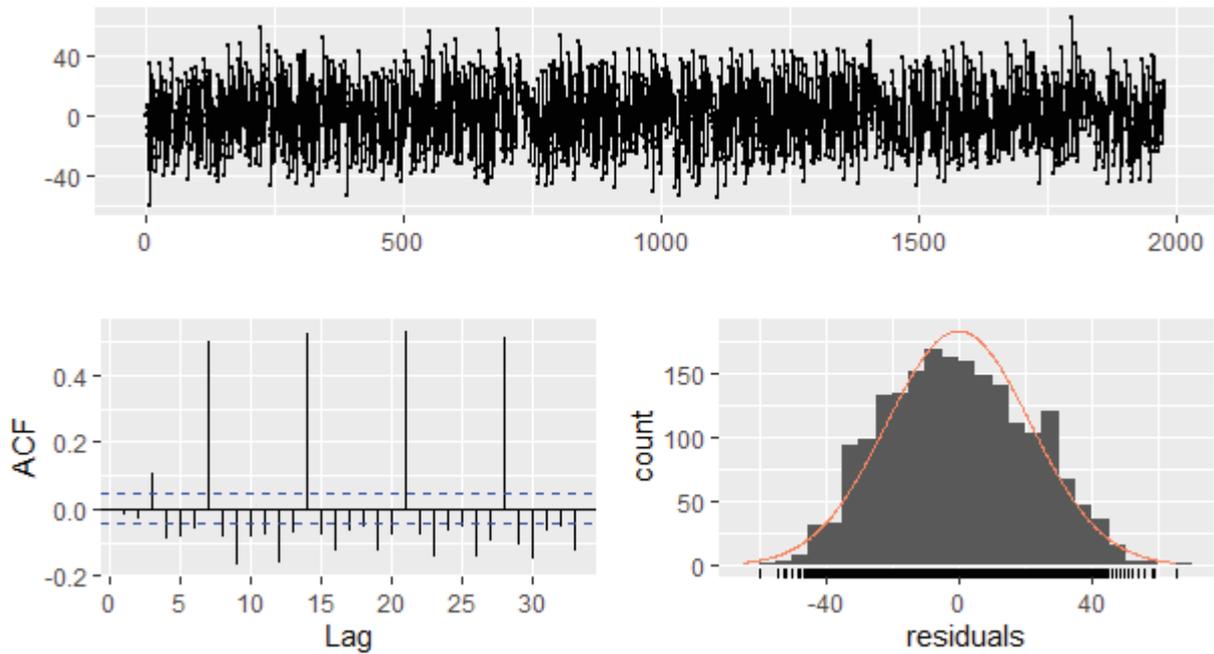
Figura 7 - Função autocorrelação parcial da série temporal pediatria



Fonte: Elaborado pelo autor.

Também buscou-se verificar a adequação dos modelos, avaliando por meio de correlação residual e dos gráficos de normalidade e de teste de ruído branco em que a hipótese nula se refere a resíduos não correlacionados. (JUANG et al., 2017). Assim, a fim de avaliar os resíduos contidos do modelo ARIMA (1, 1, 4) do clínico geral, no Gráfico 3, o gráfico ACF mostra que todas as autocorrelações estão próximas a zero dentro dos ciclos de 7 observações, indicando que os resíduos se comportam como ruído branco. A da série temporal dos resíduos não indica a presença de tendência e sazonalidade, e o histograma dos resíduos demonstram característica de normalidade.

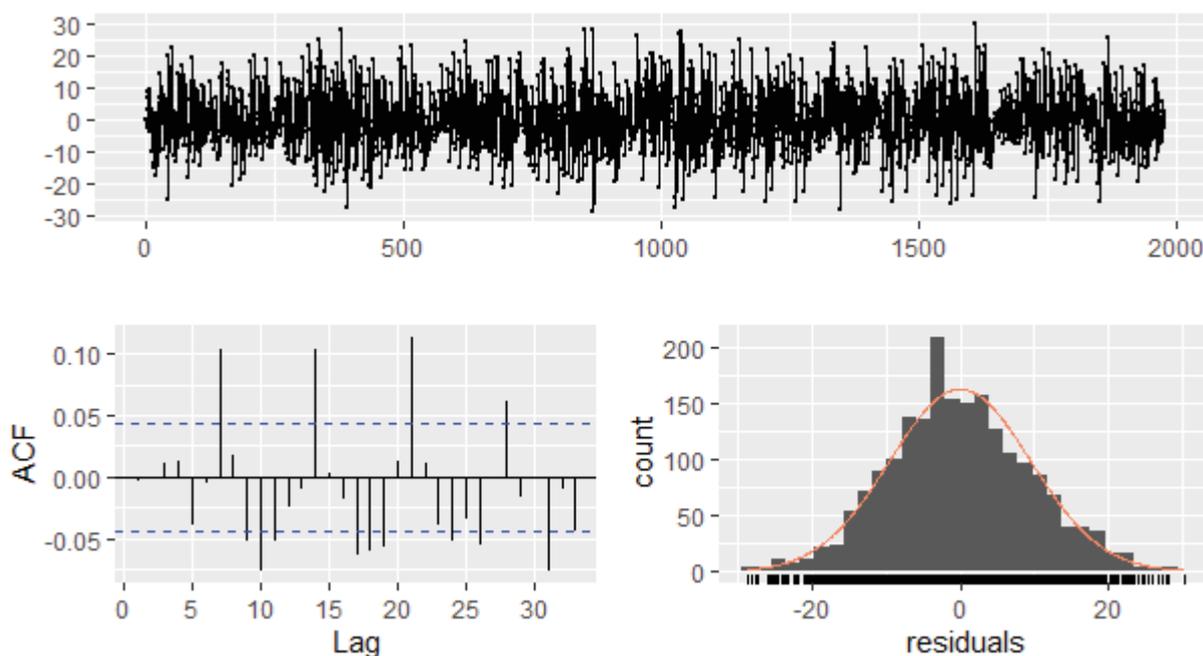
Gráfico 3 - Gráfico de resíduos ARIMA (1, 1, 4) do clínico geral



Fonte: Elaborado pelo autor.

No Gráfico 4, o gráfico ACF dos resíduos do modelo ARIMA (4, 1, 1) para o pediatra, demonstra que as autocorrelações estão dentro dos limites nos ciclos de 7 observações, portanto, é possível afirmar que os resíduos se comportam como ruído branco. Pela série temporal dos resíduos não há presença de tendência e de sazonalidade, e o histograma dos resíduos indica normalidade.

Gráfico 4 - Gráfico de resíduos ARIMA (4, 1, 1) do pediatra

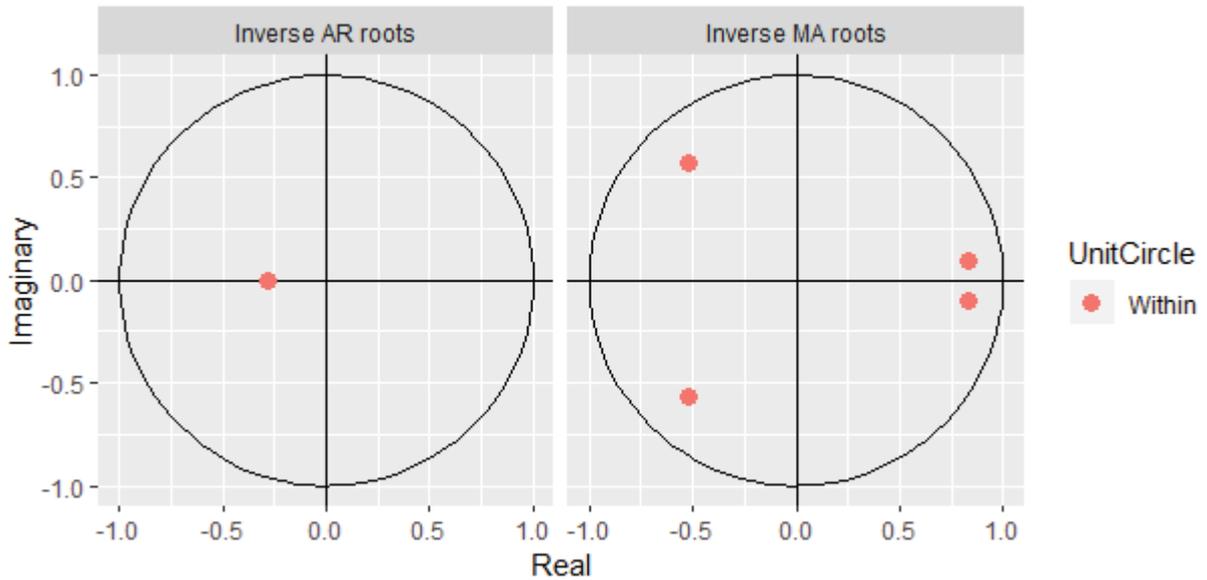


Fonte: Elaborado pelo autor.

Em um modelo ARIMA, a condição de estacionariedade é que o parâmetro p deve ficar dentro do círculo de raízes inversas unitárias complexas e a condição de invertibilidade é que o parâmetro q estejam dentro do círculo de raízes inversas unitárias complexas. Desse modo, podemos ver se o modelo está próximo da invertibilidade ou estacionariedade. Espera-se, portanto, que todas as raízes inversas estejam dentro do círculo unitário. (HYNDMAN; ATHANASOPOULOS, 2018).

Para o modelo ARIMA (1, 1, 4) ajustado ao clínico geral adulto, conforme a Figura 8, o ponto vermelho do gráfico à esquerda corresponde à raiz da componente AR, já os pontos vermelhos do gráfico à direita são das raízes de MA. Todos os pontos estão dentro do círculo unitário, indicando que este modelo atende as condições de invertibilidade e de estacionariedade.

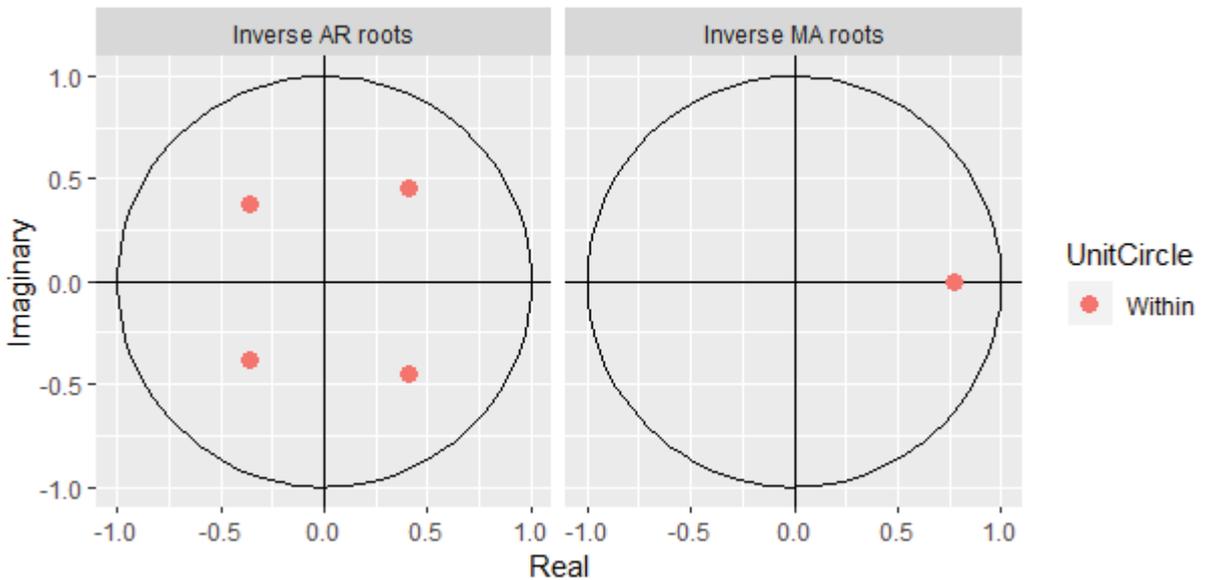
Figura 8 - Raízes inversas do modelo ARIMA (1, 1, 4)



Fonte: Elaborado pelo autor.

Na Figura 9, referente ao modelo ARIMA (4, 1, 1) ajustado ao pediatra, os pontos vermelhos do gráfico à esquerda que correspondem as raízes de AR e o ponto vermelho do gráfico à direita da raiz de MA, estão dentro do círculo unitário. É possível, então, afirmar que o modelo possui as condições de invertibilidade e de estacionariedade.

Figura 9 - Raízes inversas do modelo ARIMA (4, 1, 1)



Fonte: Elaborado pelo autor.

Com base na escolha dos modelos de previsão com o melhor ajuste para as séries temporais de cada um dos especialistas, foram realizados os cálculos dos valores previstos, utilizando a função forecast do software R, em um nível de confiança de 95%. Foram utilizados horizontes de previsão de 1, 7, 14 e 30 dias.

As medidas MAE, RMSE e MAPE revelam as diferenças entre os dados reais e valores previstos, cujos resultados destas medidas estão expostos na Tabela 4. As medidas de acurácia MAE, RMSE e MAPE apresentam a precisão dos modelos de previsão em comparação com os dados reais.

Tabela 4 - Medidas de acurácia das previsões

		MAE	RMSE	MAPE
Clínico Geral	1 dia	3,62	3,62	3,15%
	7 dias	17,13	20,18	14,31%
	14 dias	15,16	17,83	12,43%
	30 dias	17,68	19,81	17,96%
Pediatra	1 dia	6,77	6,77	12,31%
	7 dias	8,82	10,80	14,37%
	14 dias	9,81	11,71	15,79%
	30 dias	8,33	8,88	21,11%

Fonte: Elaborado pelo autor.

Uma característica percebida neste conjunto de dados é que as previsões de 1 dia a frente apresentaram melhor desempenho para ambas especialidades. O clínico geral obteve a previsão do número de consultas para o dia próximo dia com um erro de 3,15%. O modelo de previsão do pediatra teve um erro de 12,31% associado ao dia seguinte, com desempenho próximo aos horizontes de previsão de 7 e de 14 dias. Nota-se também, que as previsões de 30 dias do pediatra tiveram um índice alto de erro (21,11%), entretanto, MAE e RMSE próximos a 8 indicando que se utilize para este especialista horizontes de previsão inferiores a 30 dias.

Para o clínico geral, além da previsão de 1 dia a frente, percebe-se que previsões de 14 dias apresentam desempenho absoluto e percentual superior a previsões de 7 dias. Assim, sugere-se para este especialista que se utilize horizontes de 1 ou 14 dia de previsão, preferencialmente.

4.4.2 Previsões com Modelo Caótico

Como método alternativo de previsão de demanda, este estudo propôs a utilização do modelo caótico. O mapa logístico, conforme Capeáns et al., (2016) e Sellitto et al., (2018), possui grande potencial de aplicação em análises de séries temporais em sistemas complexos. Apesar de não ter sido aplicado na área da saúde, e tão pouco em previsão de demanda de consultas médicas, este método demonstrou aderência e facilidade de utilização neste contexto de pesquisa.

A Tabela 5 mostra a evolução temporal, com um passo de cinco posições, do mapa logístico para a especialidade clínico geral. Por meio da função de otimização Solver do software Excel foram obtidos $s(0)$ de 0,393275 e a de 3,677766. Com base na equação (51) do modelo do mapa logístico, são demonstrados nas equações (59) e (60) os cálculos dos valores ótimos dos passos 1 e 41.

Tabela 5 - Evolução temporal do mapa logístico do clínico geral

Passo	$s(\text{Passo})$	Nº At. CG Norm.	SE
1	0,878	0,861	0,000
6	0,876	0,875	0,000
11	0,867	0,854	0,000
16	0,821	0,785	0,001
21	0,759	0,674	0,007
26	0,902	1,000	0,010
31	0,901	0,944	0,002
36	0,904	0,924	0,000
41	0,891	0,938	0,002

Fonte: Elaborado pelo autor.

$$s(1) = 3,677766 \cdot 0,393275 \cdot (1 - 0,393275) = 0,877550 \quad (59)$$

$$s(41) = 3,677766 \cdot 0,587814 \cdot (1 - 0,587814) = 0,891081 \quad (60)$$

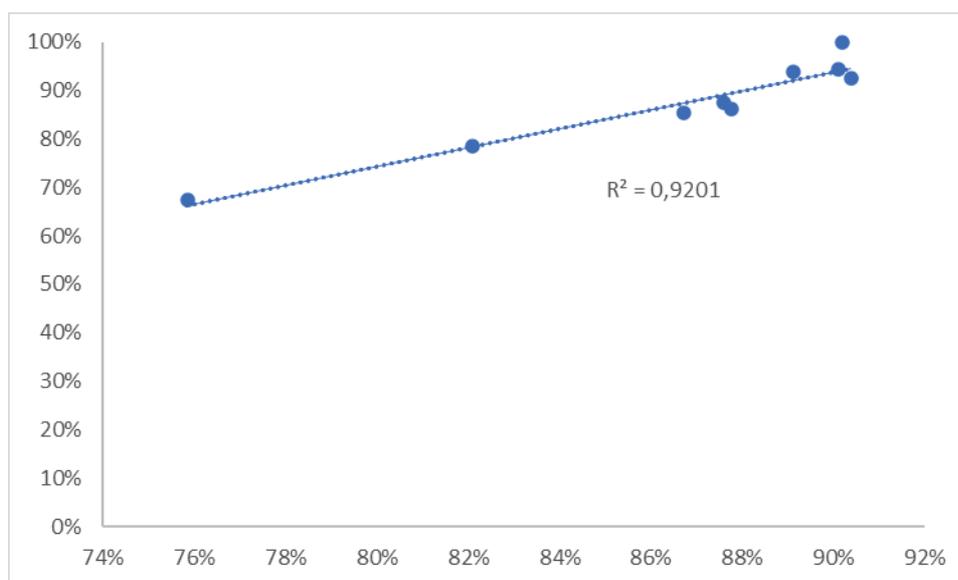
A previsão do número de atendimentos do clínico geral foi obtida, conforme as equações (61) e (62). Para o valor ótimo da previsão, foi considerado um passo à frente de $s(41)$ e multiplicado pela máxima demanda do conjunto de dados das últimas nove observações de demanda, imediatamente passada, do clínico geral. A acuracidade deste modelo de previsão por meio de RMSE foi de 0,05. A precisão das previsões de 1 dia a frente em comparação com os dados reais do clínico geral foi de MAE de 3,26, RMSE de 3,26 e MAPE de 2,53%.

$$s(\text{Previsão}) = 3,677766 \cdot 0,483773 \cdot (1 - 0,483773) = 0,918473 \quad (61)$$

$$\text{Previsão} = 144.0,918473 = 132,26 \quad (62)$$

A Figura 10 mostra a relação do coeficiente de ajuste dos dados ao modelo do mapa logístico, R^2 , para o clínico geral. R^2 de 0,9201, portanto, bastante próximo de 1, indica que as previsões fornecidas pelo modelo podem ser razoavelmente consideradas na previsão de demanda das consultas de urgência deste especialista.

Figura 10 - Relação de ajuste dos dados ao modelo do mapa logístico do clínico geral



Fonte: Elaborado pelo autor.

Para a especialidade pediatria, a Tabela 6 mostra a evolução temporal com um passo de cinco posições do mapa logístico. A função Solver do Excel obteve $s(0)$ de 0,303748 e a de 3,679890. Nas equações (63) e (64) são demonstrados os cálculos dos valores ótimos dos passos 1 e 41.

Tabela 6 - Evolução temporal do mapa logístico do pediatra

Passo	$s(\text{Passo})$	Nº At. Ped. Norm.	SE
1	0,778	0,786	0,000
6	0,915	0,929	0,000
11	0,796	0,804	0,000
16	0,861	0,839	0,000
21	0,789	0,839	0,003
26	0,889	0,911	0,000
31	0,916	1,000	0,007
36	0,778	0,804	0,001
41	0,915	0,911	0,000

Fonte: Elaborado pelo autor.

$$s(1) = 3,6798900,303748(1 - 0,303748) = 0,778242 \quad (63)$$

$$s(41) = 3,6798900,461884(1 - 0,461884) = 0,914626 \quad (64)$$

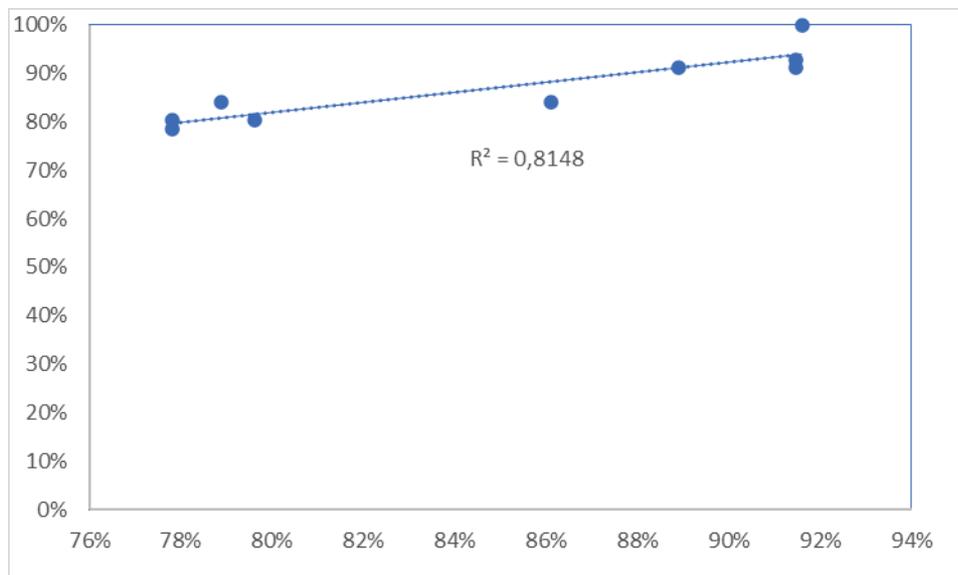
Para a previsão do número de atendimentos do pediatra, conforme as equações (65) e (66), foi considerado um passo à frente de $s(41)$ e multiplicado pela máxima demanda das últimas nove observações de demanda ocorrida imediatamente passada. A acuracidade do modelo de previsão foi de RMSE de 0,04. A precisão das previsões de 1 dia a frente comparada com os dados reais do pediatra foi de MAE de 2,41, RMSE de 2,41 e MAPE de 5,13%.

$$s(\text{Previsão}) = 3,6798900,683384(1 - 0,683384) = 0,796219 \quad (65)$$

$$\text{Previsão} = 56,0,796219 = 44,59 \quad (66)$$

O coeficiente de ajuste dos dados referente ao modelo do mapa logístico para o pediatra, exposta na Figura 11, indica R^2 em 0,8148. Significa que as previsões fornecidas pelo mapa logístico podem ser razoavelmente consideradas na previsão de demanda das consultas de urgência do pediatra.

Figura 11 - Relação de ajuste dos dados ao modelo do mapa logístico do pediatra



Fonte: Elaborado pelo autor.

4.4.3 Análise dos Modelos de Previsão

Com o objetivo de prever o número de atendimentos no curto prazo, portanto, nos próximos dias, os modelos de previsão de demanda propostos se comportaram com bom desempenho. Esta constatação mostra que o conhecimento das

quantidades de atendimentos nos dias anteriores é muito importante para uma previsão mais precisa. A previsão de demanda a partir da análise de séries temporais é uma ferramenta bastante útil para a análise de processos e a tomada de decisão nos serviços de saúde, contribuindo assim para a utilização mais eficiente dos recursos e elevação da percepção de qualidade. A correta e eficiente administração dos recursos passa a ser fator preponderante para a melhoria da saúde da sociedade e gestão das instituições. (DE BRITO et al., 2019).

A série temporal usada neste estudo foi limitada a 66 meses porque durante a pesquisa não havia mais informações disponíveis. Embora não haja na literatura a definição de um número mínimo de dados históricos, sugere-se a realização de novos estudos com um conjunto maior de observações ao longo do tempo e em outros hospitais de pronto atendimento.

Os resultados de todos os modelos, com base nas medidas de acuracidade, estão expostos na Tabela 7.

Tabela 7 - Resumo dos resultados obtidos por modelo

		MAE	RMSE	MAPE
Clínico Geral	1 dia	3,62	3,62	3,15%
	7 dias	17,13	20,18	14,31%
	14 dias	15,16	17,83	12,43%
	30 dias	17,68	19,81	17,96%
	Mapa Logístico	3,26	3,26	2,53%
Pediatria	1 dia	6,77	6,77	12,31%
	7 dias	8,82	10,80	14,37%
	14 dias	9,81	11,71	15,79%
	30 dias	8,33	8,88	21,11%
	Mapa Logístico	2,41	2,41	5,13%

Fonte: Elaborado pelo autor.

O mapa logístico em comparação com o modelo ARIMA, apresentou melhor desempenho para as duas especialidades. Pelo modelo ARIMA, a previsão do número de consultas para o dia próximo dia é a mais indicada tanto para clínico geral quanto para pediatra. Neste sentido, considera-se a utilização de modelos caóticos como possíveis para a previsão de demanda de curto prazo em consultas de urgência. Embora tenha-se aplicado 8 observações sequenciais com cinco posições, o mapa logístico demonstrou baixo erro associado as previsões.

Também deve-se ressaltar que emergências inesperadas e acidentes de grandes proporções não podem ser previstas. (JUANG et al., 2017). Em situações de acidente, ou emergência, com grande número de vítimas, a equipe médica depende dos protocolos e diretrizes regionais de atendimento de emergência. Como sugestão de trabalhos futuros, pode-se pesquisar os fatores associados a estas ocorrências e desenvolver um modelo de previsão de demanda incluindo estes acontecimentos.

4.5 CONSIDERAÇÕES FINAIS

Utilizando as séries temporais do número de pacientes atendidos, os resultados desta pesquisa sugerem o modelo ARIMA (1,1,4) para clínico geral adulto e ARIMA (4,1,1) para pediatra, considerando o melhor ajuste possível para as previsões. Conclui-se com base nas medidas de acurácia, que previsões de 1 dia a frente até 14 dias de previsão incorrem em erro próximos a 10%. A utilização de modelos caóticos como método de previsão de demanda de curto prazo em consultas de urgência demonstrou erro próximo a 5% associado as previsões. Assim, pode-se validar a utilização do mapa logístico em previsão de demanda em serviço de saúde. Além disso, o estudo demonstra a importância do uso de modelos matemáticos de previsão em serviços de atendimento em departamento de emergência.

As previsões de 1, 7 e 14 dias a frente, para ambas as especialidades, possibilitam aos gestores otimizar a alocação de recursos humanos, materiais e de custos com foco no gerenciamento do atendimento diário, sendo ferramenta útil que instrumentaliza a gestão de recursos operacionais, de especialistas e o número de postos de atendimento ao paciente. Previsões de consultas de urgência pouco precisas, como para 30 dias, acarretam em alocar recursos de forma incorreta, causando perdas operacionais, baixa eficiência na alocação de recursos e desempenho financeiro ineficaz. Realidade agravada em período de pandemia como a da COVID-19 em que os recursos devem ser muito bem administrados.

Os modelos matemáticos de previsão de demanda podem aprimorar as ferramentas e a gestão dos serviços de cuidado de saúde, contribuindo de forma extraordinária para o desenvolvimento científico e tecnológico. A aplicação desses

modelos deve ser vista pelos gestores como uma ferramenta de auxílio a decisões, por isso deve subsidiar processos de gestão e de planejamento.

A utilização da previsão de demanda em departamento de emergência possibilita diminuir os cancelamentos de admissões planejadas e otimiza a alocação de leitos à demanda real. A alocação de recursos humanos também é ajustada de acordo com as necessidades de leitos e o número de postos de atendimento aumentando a utilização dos recursos operacionais e por consequência elevando a qualidade dos serviços prestados.

5 CONCLUSÃO

Na presente pesquisa foi abordado o tema da previsão de demanda do serviço de urgência em um hospital de pronto atendimento. Pode-se identificar o comportamento da demanda das consultas de urgência e quantificar o número de atendimentos do recurso médico, sob o aspecto de utilização da prestação de serviços dos principais especialistas no curto prazo. O objetivo geral, e que foi alcançado, foi de propor um modelo de previsão de demanda para consultas de urgência.

Como base teórica deste estudo, foi apresentada uma revisão sistemática da literatura sobre a previsão de demanda, tratado em termos de métodos qualitativos, métodos quantitativos e métodos com base em inteligência artificial. Neste sentido, é possível afirmar que para previsões de longo, médio ou curto prazo o melhor método é aquele que fornece os valores mais próximos entre a previsão e a demanda real, independente do segmento de atuação empresarial.

Os métodos qualitativos e causais demonstram adaptar-se melhor às previsões de médio e longo prazo, enquanto a análise de séries temporais indica se adequar mais a previsões de curto prazo. A análise de séries temporais possui os métodos mais simples, oferece bons resultados e é a mais utilizada em previsão de demanda de um modo geral. Os métodos causais são os que melhor representam a relação entre os fatores a serem previstos e são úteis para prever pontos de inflexão na demanda. Métodos que utilizam inteligência artificial modelam situações simples e complexas e são recomendados para aplicações que requerem análises de realidades complexas e por isso demandam de recursos operacionais e computacionais mais qualificados.

Mostrou-se um recurso utilizado em diversas realidades a construção de um modelo próprio de previsão de demanda utilizando aspectos, conceitos e características de diferentes modelos conceituais. Entretanto, é fundamental validar o modelo adotado e sempre mantê-lo sob controle, de maneira a poder efetuar correções dentro do menor prazo possível. Portanto, é necessário testar diversos modelos até encontrar o mais adequado ao caso específico que se está analisando.

Neste estudo foi escolhido com base na revisão sistemática da literatura sobre previsão de demanda em serviço de saúde dos últimos quatro anos o modelo

ARIMA e se propôs a utilização do modelo caótico mapa logístico como modelo inovador de previsão de demanda na área da saúde. Por meio das séries temporais do número de pacientes atendidos por dia, em um total de 66 meses, os resultados sugerem o modelo ARIMA (1,1,4) para clínico geral adulto e ARIMA (4,1,1) para pediatra, considerando o melhor ajuste possível para as previsões. Modelos caóticos possuem baixo erro associado, próximo a 5%, para a previsão de demanda de curto prazo em consultas de urgência.

As melhores previsões foram obtidas por meio de horizonte 1 dia a frente para ambas especialidades, permitindo aos gestores otimizar a alocação de recursos humanos, materiais e de custos com foco no gerenciamento do atendimento diário. Previsões de 7 e de 14 dias também possuem bom desempenho, sendo ferramenta útil que instrumentaliza a gestão de recursos operacionais, de especialistas e o número de postos de atendimento ao paciente. Prever consultas de urgência para 30 dias pode acarretar em alocar recursos de forma incorreta, causando perdas operacionais, baixa eficiência na alocação de recursos e desempenho financeiro ineficiente. Realidade, esta, agravada em período de pandemia como a da COVID-19 em que os recursos devem ser muito bem administrados.

Os modelos de previsão de demanda propostos foram construídos a partir de dados comumente disponíveis e, desse modo, podem ser facilmente implementados e utilizados em grande parte dos hospitais de pronto atendimento do Brasil, Reino Unido e demais países que se enquadram em serviço de saúde de complexidade intermediária. Ao complementar as informações clínicas do paciente quando disponíveis, acredita-se que a utilização destes modelos pode ser estendida às unidades de atendimento complementares ao departamento de emergência, tais como internação e a realização de exames médicos, entre outras.

Outra contribuição é que o estudo demonstra a importância do uso de modelos matemáticos de previsão em serviços de atendimento em departamento de emergência. A aplicação dos modelos de previsão de demanda deve ser vista pelos gestores como uma ferramenta para auxiliar as decisões, apoiando processos de planejamento, gestão e avaliação no ambiente hospitalar, sendo um instrumento de atendimento e de serviços gerenciais. Também é útil como ferramenta no melhor gerenciamento de leitos, equipe e agendamento de atendimentos eletivos.

Conhecer o comportamento da demanda do hospital em sua totalidade permitirá que a administração planeje com antecedência, garanta que os recursos

necessários estejam disponíveis, gerencie melhor os orçamentos e venha a reduzir situações de risco para pacientes, funcionários e instituição. Além disso, permite aos diretores e gestores de serviços prever suas atividades e formar um plano estratégico com certa antecedência.

Por fim, o aprendizado obtido e os conhecimentos mobilizados nesta pesquisa permitiram associar técnicas, ferramentas e saberes de Gestão de Serviços de Saúde e de Engenharia de Produção. A pesquisa, utilização e disseminação desses saberes é essencial e contribuem para uma gestão eficaz e melhoria da qualidade na área da saúde e na agregação de valor aos usuários dos serviços prestados.

Em termos de trabalhos futuros, estudos relacionados à previsão de demanda de um modo geral apresentam oportunidades de maiores pesquisas, sendo oportuna a incorporação de conceitos adicionais, como inteligência artificial, finanças e contabilidades de custos. Outros estudos relevantes estão associados a pesquisas sobre os fatores associados a acidentes, ou emergências, com grande número de vítimas, no sentido de desenvolver um modelo de previsão de demanda considerando estes acontecimentos.

Sugere-se a realização de novos estudos com um conjunto maior de observações ao longo do tempo, em outros hospitais de pronto atendimento e em unidades de pronto atendimento caracterizadas como serviços de atendimento de saúde de complexidade baixa ou de complexidade alta. O modelo utilizado nesta pesquisa é recomendado a ser aplicado no Reino Unido e em outros países em que os serviços de atendimento de saúde possuam característica de complexidade intermediária, visando trazer maior assertividade nas previsões de demanda.

REFERÊNCIAS

- ABOAGYE-SARFO, P.; MAI, Q.; SANFILIPPO, F. M.; PREEN, D. B.; STEWART, L. M.; FATOVICH, D. M. A comparison of multivariate and univariate time series approaches to modelling and forecasting emergency department demand in western Australia **Journal of Biomedical Informatics**, v. 57, p. 62-73, 2015.
- AFILAL, M.; YALAOUI, F.; DUGARDIN, F.; AMODEO, L.; LAPLANCHE, D.; BLUA, B. Forecasting the emergency department patients flow. **Journal of Medical Systems**, v. 40(7), p. 175, 2016a.
- AFILAL, M.; YALAOUI, F.; DUGARDIN, F.; AMODEO, L.; LAPLANCHE, D.; BLUA, B. Emergency department flow: A new practical patients classification and forecasting daily attendance. **IFAC-PapersOnLine**, v. 49, n. 12, p. 721-726, 2016b.
- AIZENBERG, I.; SHEREMETOV, L.; VILLA-VARGAS, L.; MARTINEZ-MUÑOZ, J. Multilayer neural network with multi-valued neurons in time series forecasting of oil production. **Neurocomputing**, v. 175, p. 980-989, 2016.
- ANDRADE, P.; PEREIRA, V.; DEL CONTE, E. Value stream mapping and lean simulation: a case study in automotive company. **The International Journal of Advanced Manufacturing Technology**, v. 85, n. 1-4, p. 547-555, 2016.
- ARMSTRONG, J.; GREEN, K. Demand forecasting evidence-based methods. [2019?] Disponível em: <http://forecastingprinciples.com/paperpdf/DemandForecasting.pdf>. Acesso em: 26 abr. 2019.
- ARVAN, M.; FAHIMNIA, B.; REISI, M.; SIEMSEN, E. Integrating human judgement into quantitative forecasting methods: a review. **Omega**, 86, 237-252, 2019.
- BAIA MEDEIROS, D. T.; HAHN-GOLDBERG, S.; ALEMAN, D. M.; O'CONNOR, E. Planning capacity for mental health and addiction services in the emergency department: A discrete-event simulation approach. **Journal of Healthcare Engineering**, v. 2019, 2019.
- BAUER, J. M.; VARGAS, A.; SELBITTO, M. A.; SOUZA, M. C.; VACCARO, G. L. The thinking process of the theory of constraints applied to public healthcare. **Business Process Management Journal**, 2019.
- BENBELKACEM, S.; KADRI, F.; ATMANI, B.; CHAABANE, S. Machine learning for emergency department management. **International Journal of Information Systems in the Service Sector**, v. 11, n. 3, p. 19-36, 2019.
- BHAT, S.; GIJO, E. V.; JNANESH, N. A. Productivity and performance improvement in the medical records department of a hospital: an application of lean six sigma. **International Journal of Productivity and Performance Management**, v. 65, n. 1, p. 98-125, 2016.
- BOROOJENI, K. G.; AMINI, M. H.; BAHRAMI, S.; IYENGAR, S. S.; SARWAT, A. I.; KARABASOGLU, O. A novel multi-time-scale modeling for electric power demand

forecasting: from short-term to medium-term horizon. **Electric Power Systems Research**, 142, 58-73, 2017.

BRENTAN, B. M.; LUVIZOTTO JR, E.; HERRERA, M.; IZQUIERDO, J.; PÉREZ-GARCÍA, R. Hybrid regression model for near real-time urban water demand forecasting. **Journal of Computational and Applied Mathematics**, v. 309, p. 532-541, 2017.

CALEGARI, R.; FOGLIATTO, F. S.; LUCINI, F. R.; NEYELOFF, J.; KUCHENBECKER, R. S.; SCHAAN, B. D. Forecasting daily volume and acuity of patients in the emergency department. **Computational and Mathematical Methods in Medicine**, v. 2016, 2016.

CAPEÁNS, R.; SABUCO, J.; SANJUÁN, M. A. F. Parametric partial control of chaotic systems. **Nonlinear Dynamics**, v. 86, n. 2, p. 869-876, 2016.

CAPEÁNS, R.; SABUCO, J.; SANJUÁN, M. A. F.; YORKE, J. A. Partially controlling transient chaos in the Lorenz equations. **Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences**, v. 375, n. 2088, p. 20160211, 2017.

CARVALHO-SILVA, M.; MONTEIRO, M. T. T.; SÁ-SOARES, F.; NÓBREGA, S. D. Assessment of forecasting models for patients arrival at emergency department. **Operations Research for Health Care**, v. 18, p. 112-118, 2018.

CHAE, Y. T.; HORESH, R.; HWANG, Y.; LEE, Y. M. Artificial neural network model for forecasting sub-hourly electricity usage in commercial buildings. **Energy and Buildings**, v. 111, p. 184-194, 2016.

CORTEZ, C. A. T.; HITCH, M.; SAMMUT, C.; COULTON, J.; SHISHKO, R.; SAYDAM, S. Determining the embedding parameters governing long-term dynamics of copper prices. **Chaos, Solitons & Fractals**, v. 111, p. 186-197, 2018a.

CORTEZ, C. A. T.; SAYDAM, S.; COULTON, J.; SAMMUT, C. Alternative techniques for forecasting mineral commodity prices. **International Journal of Mining Science and Technology**, v. 28, n. 2, p. 309-322, 2018b.

DE BRITO, F. G.; RESENDE, E. S.; RODRIGUES, A. A. A.; JUNQUEIRA, M. A. B.; BARRETO, V. R.; DESTRO FILHO, J. B. Demand forecast in the emergency department in Minas Gerais, Brazil. **Bioscience Journal**, v. 35, n. 5, p. 1640-1650, 2019.

DE LÖE, R. C.; MELNYCHUK, N.; MURRAY, D.; PLUMMER, R. Advancing the state of policy delphi practice: A systematic review evaluating methodological evolution, innovation, and opportunities. **Technological Forecasting and Social Change**, v. 104, p. 78-88, 2016.

DE STEUR, H.; WESANA, J.; DORA, M. K.; PEARCE, D.; GELLYNCK, X. Applying value stream mapping to reduce food losses and wastes in supply chains: a systematic review. **Waste management**, v. 58, p. 359-368, 2016.

DEB, C.; ZHANG, F.; YANG, J.; LEE, S. E.; SHAH, K. W. A review on time series forecasting techniques for building energy consumption. **Renewable and Sustainable Energy Reviews**, v. 74, p. 902-924, 2017.

DIAS, K. C. F. **Proposição de um modelo matemático para elaboração e avaliação do quadro de lotação em uma instituição hospitalar com o uso de otimização combinatória**. 2015. Dissertação de Mestrado - Programa de Pós-Graduação em Engenharia de Produção e Sistemas, Universidade do Vale do Rio dos Sinos, 2015.

DOGAN, N.; UNUTULMAZ, O. Lean production in healthcare: a simulation-based value stream mapping in the physical therapy and rehabilitation department of a public hospital. **Total Quality Management Business Excellence**, v. 27, n. 1-2, p. 64-80, 2016.

EFENDI, R.; ISMAIL, Z.; DERIS, M. M. A new linguistic out-sample approach of fuzzy time series for daily forecasting of malaysian electricity load demand. **Applied Soft Computing**, v. 28, p. 422-430, 2015.

FAHIMNIA, B. Integrating human judgement into quantitative forecasting methods: a review. **Omega**, 2018.

FANG, T.; LAHDELMA, R. Evaluation of a multiple linear regression model and SARIMA model in forecasting heat demand for district heating system. **Applied Energy**, v. 179, p. 544-552, 2016.

FERREIRA, K. J.; LEE, B. H. A.; SIMCHI-LEVI, D. Analytics for an online retailer: Demand forecasting and price optimization. **Manufacturing and Service Operations Management**, v. 18, p. 69-88, 2016.

FIOT, J.; DINUZZO, F. Electricity demand forecasting by multi-task learning. **IEEE Transactions on Smart Grid**, 9(2), 544-551, 2016.

FORTSCH, S. M.; KHAPALOVA, E. A. Reducing uncertainty in demand for blood. **Operations Research for Health Care**, v. 9, p. 16-28, 2016.

GAUZE JÚNIOR, J. W. **Melhoria de processos em uma central de abastecimento farmacêutico: uma pesquisa-ação à luz do lean healthcare**. 2016. Dissertação de Mestrado - Programa de Pós-Graduação em Engenharia de Produção e Sistemas, Universidade do Vale do Rio dos Sinos, 2016.

GOPAKUMAR, S.; TRAN, T.; LUO, W.; PHUNG, D.; VENKATESH, S. Forecasting daily patient outflow from a ward having no real-time clinical data. **JMIR Medical Informatics**, v. 4, n. 3, p. e25, 2016.

GREEN, K. C.; ARMSTRONG, J. S. Simple versus complex forecasting: the evidence. **Journal of Business Research**, v. 68, n. 8, p. 1678-1685, 2015.

GUL, M.; GUNERI, A. F. Planning the future of emergency departments: Forecasting ED patient arrivals by using regression and neural network models. **International Journal of Industrial Engineering**, v. 23, n. 2, p. 137-154, 2016

GUO, H.; PEDRYCZ, W.; LIU, X. Fuzzy time series forecasting based on axiomatic fuzzy set theory. **Neural Computing and Applications**, p. 1-12, 2018.

HANKE, J.; WICHERN, D. **Business Forecasting**. Prentice Hall, 2001.

HENRIQUE, D. B.; RENTES, A. F.; GODINHO FILHO, M.; ESPOSTO, K. F. A new value stream mapping approach for healthcare environments. **Production Planning & Control**, v. 27, n. 1, p. 24–48, 2016.

HYNDMAN, R. J.; ATHANASOPOULOS, G. **Forecasting: principles and practice**. OTexts, 2018. *E-book*. Disponível em: <https://otexts.com/fpp2/>. Acesso em: 06 abr. 2020.

IBGE. INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA - IBGE. Séries estatísticas e séries históricas. Disponível em: [http://www.ibge.gov.br/seriesestatisticas=>](http://www.ibge.gov.br/seriesestatisticas) Acesso em: 29 abr. 2019:

JAMIL, M.; ZEESHAN, M. A comparative analysis of ann and chaotic approach-based wind speed prediction in india. **Neural Computing and Applications**, v. 2, p. 1-13, 2018.

JIANG, S.; CHIN, K.; TSUI, K. L. A universal deep learning approach for modeling the flow of patients under different severities. **Computer Methods and Programs in Biomedicine**, v. 154, p. 191-203, 2018.

JIANG, S.; CHIN, K.; WANG, L.; QU, G.; TSUI, K. L. Modified genetic algorithm-based feature selection combined with pre-trained deep neural network for demand forecasting in outpatient department. **Expert Systems with Applications**, v. 82, p. 216-230, 2017.

JILANI, T.; HOUSLEY, G.; FIGUEREDO, G.; TANG, P. S.; HATTON, J.; SHAW, D. Short and long term predictions of hospital emergency department attendances. **International Journal of Medical Informatics**, v. 129, p. 167-174, 2019.

JOO, T. W.; KIM, S. B. Time series forecasting based on wavelet filtering. **Expert Systems with Applications**, v. 42, n. 8, p. 3868-3874, 2015.

JUANG, W. C.; HUANG, S. J.; HUANG, F. D.; CHENG, P. W.; WANN, S. R. Application of time series analysis in modelling and forecasting emergency department visits in a medical centre in Southern Taiwan. **BMJ Open**, v. 7, n. 11, p. e018628, 2017.

JUN, S.; SUNG, T.; PARK, H. Forecasting by analogy using the web search traffic. **Technological Forecasting and Social Change**, v. 115, p. 37-51, 2017.

KATSIKOPOULOS, K. V.; DURBACH, I. A.; STEWART, T. J. When should we use simple decision models? a synthesis of various research strands. **Omega**, v. 81, p. 17-25, 2018.

KE, J.; ZHENG, H.; YANG, H.; CHEN, X. Short-term forecasting of passenger demand under on-demand ride services: A spatio-temporal deep learning approach.

Transportation Research Part C: Emerging Technologies, v. 85, p. 591-608, 2017.

KLUTE, B.; HOMB, A.; CHEN, W.; STELPFLUG, A. Predicting outpatient appointment demand using machine learning and traditional methods. **Journal of Medical Systems**, v. 43, n. 9, p. 288, 2019

KOCAK, C. Arma (p, q) type high order fuzzy time series forecast method based on fuzzy logic relations. **Applied Soft Computing**, v. 58, p. 92-103, 2017.

KRAJEWSKI, L. J.; RITZMAN, L. P.; MALHOTRA, M. K. **Administração de produção e operações**. Pearson Prentice Hall, 2009.

KUDLAK, R.; SZÖCS, I.; KRUMAY, B.; MARTINUZZI, A. The future of csr- selected findings from a europe-wide delphi study. **Journal of Cleaner Production**, v. 183, p. 282-291, 2018.

LACERDA, D. P.; DRESCH, A.; PROENÇA, A.; ANTUNES JÚNIOR, J. A. V. Design Science Research: método de pesquisa para a engenharia de produção. **Gestão & Produção**, v. 20, n. 4, p. 741-761, 2013.

LI, X.; PAN, B.; LAW, R.; HUANG, X. Forecasting tourism demand with composite search index. **Tourism Management**, v. 59, p. 57–66, 2017.

LIBRELATO, T. P.; LACERDA, D. P.; RODRIGUES, L. H.; VEIT, D. R. A process improvement approach based on the value stream mapping and the theory of constraints thinking process. **Business Process Management Journal**, v. 20, n. 6, p. 922–949, 2014.

LOË, R. C. de; MELNYCHUK, N.; MURRAY, D.; PLUMMER, R. Advancing the state of policy Delphi practice: a systematic review evaluating methodological evolution, innovation, and opportunities. **Technological Forecasting and Social Change**, v. 104, p. 78–88, 2016.

LUCAS, A.; ZHANG, X. Score-driven exponentially weighted moving averages and value-at-risk forecasting. **International Journal of Forecasting**, v. 32 n. 2, p. 293–302, 2016.

LUO, L.; LUO, L.; ZHANG, X.; HE, X. Hospital daily outpatient visits forecasting using a combinatorial model based on ARIMA and SES models. **BMC health services research**, v. 17, n. 1, p. 469, 2017.

LV, C.; XING, Y.; ZHANG, J.; NA, X.; LI, Y.; LIU, T.; CAO, D.; WANG, F. Levenberg–marquardt backpropagation training of multilayer neural network for state estimation of a safety-critical cyber-physical system. **IEEE Transactions on Industrial Informatics**, v. 14, n. 8, p. 3436-3446, 2017.

MAKRIDAKIS, S.; WHEELWRIGHT, S.; HYNDMAN, R. **Forecasting methods and applications**. John Wiley Sons, 1998.

MALLOR, F.; AZCÁRATE, C.; BARADO, J. Control problems and management policies in health systems: application to intensive care units. **Flexible Services and Manufacturing Journal**, v. 28, n. 1, p. 62–89, 2016.

MARCONI, M. D. A.; LAKATOS, E. M. **Fundamentos da metodologia científica**. Atlas, 2010.

MATHEWS, K. S.; LONG, E. F. A conceptual framework for improving critical care patient flow and bed use. **Annals of the American Thoracic Society**, v. 12, n. 6, p. 886–894, 2015.

MIGUEL, P. A. C.; FLEURY, A. C. C. **Metodologia de pesquisa em engenharia de produção e gestão de operações**. Elsevier, 2018.

MS. MINISTÉRIO DA SAÚDE, PORTARIA No342, DE 4 DE MARÇO DE 2013. Disponível em: <http://bvsms.saude.gov.br/bvs/saudelegis/gm/2013/prt034204032013.html> Acesso em: 05 mar. 2019.

NIKOLOPOULOS, K.; LITSA, A.; PETROPOULOS, F.; BOUGIOUKOS, V.; KHAMMASH, M. Relative performance of methods for forecasting special events. **Journal of Business Research**, v. 68, n. 8, p. 1785-1791, 2015.

OMS. ORGANIZAÇÃO MUNDIAL DE SAÚDE. Disponível em: <://www.who.int>. Acesso em: 29 abr. 2019.

ORDU, M.; DEMIR, E.; TOFALLIS, C. A comprehensive modelling framework to forecast the demand for all hospital services. **International Journal of Health Planning and Management**, v. 34, n. 2, p. 1257-1271, 2019a.

ORDU, M.; DEMIR, E.; TOFALLIS, C. A decision support system for demand and capacity modelling of an accident and emergency department. **Health Systems**, v. 9, n. 1, p. 31-56, 2019b.

PETROPOULOS, F.; KOURENTZES, N.; NIKOLOPOULOS, K.; SIEMSEN, E. Judgmental selection of forecasting models. **Journal of Operations Management**, v. 60, p. 34-46, 2018.

QIU, X.; REN, Y.; SUGANTHAN, P. N.; AMARATUNGA, G. A. J. Empirical mode decomposition based ensemble deep learning for load demand time series forecasting. **Applied Soft Computing Journal**, v. 54, p. 246-255, 2017.

R DEVELOPMENT CORE TEAM. R: A language and environment for statistical computing. [2020?] Disponível em: <https://www.r-project.org>. Acesso em: 9 mar. 2020.

RAMASWAMY, R.; ROTHSCHILD, C.; ALABI, F.; WACHIRA, E.; MUIGAI, F.; PEARSON, N. Using Value Stream Mapping to improve quality of care in low-resource facility settings. **International Journal for Quality in Health Care**, p. 1–5, 2017.

- RAZA, M. Q.; KHOSRAVI, A. A review on artificial intelligence based load demand forecasting techniques for smart grid and buildings. **Renewable and Sustainable Energy Reviews**, v. 50, p. 1352-1372, 2015.
- REN, Y.; SUGANTHAN, P. N.; SRIKANTH, N.; AMARATUNGA, G. Random vector functional link network for short-term electricity load demand forecasting. **Information Sciences**, v. 367, p. 1078-1093, 2016.
- RUIZ-PATIÑO, A.; ACOSTA-OSPINA, L. E.; RUEDA, J. D. Solving the negative impact of congestion in the postanesthesia care unit: a cost of opportunity analysis. **Journal of Surgical Research**, v. 210, p. 86–91, 2017.
- SALDIVA, P. H. N.; VERAS, M. Gastos públicos com saúde: breve histórico, situação atual e perspectivas futuras. **Estudos Avançados**, v. 32, n. 92, p. 47–61, 2018.
- SCHAEFER, J. L.; SILUK, J. C. M.; CARVALHO, P. S. D.; RENES PINHEIRO, J.; SCHNEIDER, P. S. Management Challenges and Opportunities for Energy Cloud Development and Diffusion. **Energies**, v. 13, n. 16, p. 4048, 2020.
- SEIFERT, M.; SIEMSEN, E.; HADIDA, A. L.; EISINGERICH, A. Effective judgmental forecasting in the context of fashion products. **Journal of Operations Management**, v. 36, p. 33-45, 2015.
- SELLITTO, M. A.; BALUGANI, E.; LOLLI, F. Spare parts replacement policy based on chaotic models. **IFAC-PapersOnLine**, v. 51, n. 11, p. 945-950, 2018.
- SELLITTO, M. A.; LUCHESE, J. Systemic cooperative actions among competitors: the case of a furniture cluster in brazil. **Journal of Industry, Competition and Trade**, v. 18, n. 4, p. 513 – 528, 2018.
- SELLITTO, M. A.; LUCHESE, J.; BAUER, J. M.; SAUERESSIG, G. G.; VIEGAS, C. V. Ecodesign practices in a furniture industrial cluster of southern brazil: from incipient practices to improvement. **Journal of Environmental Assessment Policy and Management**, v. 19, n. 1, p. 1750001 – 1750025, 2017.
- SHAIKH, F.; JI, Q. Forecasting natural gas demand in china: logistic modelling analysis. **International Journal of Electrical Power and Energy Systems**, v. 77, p. 25-32, 2016.
- SHOU, W.; WANG, J.; WU, P.; WANG, X.; CHONG, H. Y. A cross-sector review on the use of value stream mapping. **International Journal of Production Research**, v. 55, n. 13, p. 3906–3928, 2017.
- SOUZA, M. C. **Mapeamento do processo em laboratórios de análises clínicas para identificação de perdas produtivas**. 2015. Dissertação de Mestrado - Programa de Pós-Graduação em Engenharia de Produção e Sistemas, Universidade do Vale do Rio dos Sinos, 2015a.
- SOUZA, T. A. **Lean Healthcare**: aplicação dos conceitos de gestão de operações em centros cirúrgicos. 2015. Dissertação de Mestrado - Programa de Pós-Graduação em Engenharia de Produção e Sistemas, Universidade do Vale do Rio dos Sinos, 2015b.

SYNTETOS, A. A.; BABAI, M. Z.; GARDNER JR., E. S. Forecasting intermittent inventory demands: Simple parametric methods vs. bootstrapping. **Journal of Business Research**, v. 68, n. 8, p. 1746-1752, 2015.

TAKAGI, T.; SUGENO, M. Fuzzy identification of systems and its applications to modeling and control. **Systems, Man and Cybernetics**, v. 15, n. 1, p. 116-132, 1985.

TARASOVA, V. V.; TARASOV, V. E. Logistic map with memory from economic model. **Chaos, Solitons and Fractals**, v. 95, p. 84-91, 2017.

TAYLOR, L. J.; NAYAK, S. Goldratt's Theory Applied to the Problems Associated with an Emergency Department at a Hospital. **Administrative Science**, v. 2, n. 4, p. 235-249, 2012.

TONGAL, H.; BERNDTSSON, R. Impact of complexity on daily and multi-step forecasting of streamflow with chaotic, stochastic, and black-box models. **Stochastic environmental research and risk assessment**, v. 31, n. 3, p. 661-682, 2017.

TRATAR, L. F. Forecasting method for noisy demand. **International Journal of Production Economics**, v. 161, p. 64-73, 2015.

TRATAR, L. F.; MOJŠKERC, B.; TOMAN, A. Demand forecasting with four-parameter exponential smoothing. **International Journal of Production Economics**, v. 181, p. 162-173, 2016.

TYAGI, S.; CHOUDHARY, A.; CAI, X.; YANG, K. Value stream mapping to reduce the lead-time of a product development process. **International Journal of Production Economics**, v. 160, p. 202-212, 2015.

VACCARO, A. R.; GETZ, C. L.; COHEN, B. E.; COLE, B. J.; DONNALLY III, C. J. Practice management during the COVID-19 pandemic. **The Journal of the American Academy of Orthopaedic Surgeons**, v. 28, n.11, p. 464-470, 2020.

VAN DER LAAN, E.; VAN DALEN, J.; ROHRMOSER, M.; SIMPSON, R. Demand forecasting and order planning for humanitarian logistics: an empirical assessment. **Journal of Operations Management**, v. 45, p. 114-122, 2016.

VILLANI, M.; EARNEST, A.; NANAYAKKARA, N.; SMITH, K.; DE COURTEN, B.; ZOUNGAS, S. Time series modelling to forecast prehospital EMS demand for diabetic emergencies. **BMC Health Services Research**, v. 17, n. 1, p. 332, 2017.

VON BRIEL, F. The future of omnichannel retail: a four-stage delphi study. **Technological Forecasting and Social Change**, v. 132, p. 217-229, 2018.

VOSE, C. A. Using LEAN to Improve a Segment of Emergency Department Flow. **Journal of Nursing Administration**, v. 44, n. 11, p. 558-563, 2014.

WANG, Q.; LI, S.; LI, R. Forecasting energy demand in china and india: using single-linear, hybrid-linear, and non-linear time series forecast techniques. **Energy**, v. 161, p. 821-831, 2018.

WANG, T. K.; YANG, T.; YANG, C. Y.; CHAN, F. T. S. Lean principles and simulation optimization for emergency department layout design. **Industrial Management and Data Systems**, v. 115, n. 4, p. 678–699, 2015.

WANG, W.-c.; CHAU, K.-w.; XU, D.-m.; CHEN, X.-Y. Improving forecasting accuracy of annual runoff time series using ARIMA based on EEMD decomposition. **Water Resources Management**, v. 29, n. 8, p. 2655–2675, 2015.

WEE, B. V.; BANISTER, D. How to write a literature review paper?. **Transport Reviews**, v. 36, n. 2, p. 278-288, 2016.

WHITT, W.; ZHANG, X. Forecasting arrivals and occupancy levels in an emergency department. **Operations Research for Health Care**, v. 21, p. 1–18, 2019.

WONG, T. C.; XU, M.; CHIN, K. S. A two-stage heuristic approach for nurse scheduling problem: a case study in an emergency department. **Computers Operations Research**, v. 51, p. 99–110, 2014.

WU, D. C.; SONG, H.; SHEN, S. New developments in tourism and hotel demand modeling and forecasting. **International Journal of Contemporary Hospitality Management**, v. 29, n. 1, p. 507-529, 2017.

ZHAO, Y. A. Bottleneck detection for improvement of Emergency Department efficiency. **Business Process Management Journal**, v. 21, n. 3, p. 564–585, 2015.

ZHU, T.; LUO, L.; ZHANG, X.; SHI, Y.; SHEN, W. Time-series approaches for forecasting the number of hospital daily discharged inpatients. **IEEE Journal of biomedical and health informatics**, v. 21, n. 2, p. 515–526, 2015.

ZUPIC, I.; ČATER, T. Bibliometric methods in management and organization. **Organizational Research Methods**, v. 18, n. 3, p. 429-472, 2015.