

RONNIE VINÍCIUS ARRUDA

**Desenvolvimento de modelo auto-regressivo para previsão de
atendimentos em um Ambulatório**

Ronnie Vinícius Arruda

**Desenvolvimento de modelo auto-regressivo para previsão de
atendimentos em um Ambulatório**

Trabalho de Graduação apresentado ao Conselho de Curso de Graduação em Engenharia de Materiais, da Faculdade de Engenharia do Campus de Guaratinguetá, Universidade Estadual Paulista, como parte dos requisitos para obtenção do diploma de Graduação em Engenharia Mecânica.

Orientador: Prof. Dr. Aneirson Francisco da Silva

Guaratinguetá - SP
2018

A779d	Arruda, Ronnie Vinícius Desenvolvimento de modelo auto regressivo para a previsão de demanda em um ambulatório / Ronnie Vinícius Arruda – Guaratinguetá, 2019. 36 f. : il. Bibliografia: f. 29-30 Trabalho de Graduação em Engenharia de Materiais – Universidade Estadual Paulista, Faculdade de Engenharia de Guaratinguetá, 2019. Orientador: Prof. Dr. Aneirson Francisco da Silva 1. Modelos matemáticos. 2. Combinações (Matemática). 3. Hospital – Administração. I. Título. CDU 510.67
-------	--


Luciana Máximo

Bibliotecária CRB-8/3595


Ronnie Vinícius Arruda


ESTE TRABALHO DE GRADUAÇÃO FOI JULGADO ADEQUADO COMO
PARTE DO REQUISITO PARA A OBTENÇÃO DO DIPLOMA DE
“GRADUADO EM ENGENHARIA DE MATERIAIS”


APROVADO EM SUA FORMA FINAL PELO CONSELHO DE CURSO DE
GRADUAÇÃO EM ENGENHARIA DE MATERIAIS


Prof. Dr. Miguel Angel Ramirez Gil
Coordenador

BANCA EXAMINADORA:


Prof. Dr. Aneirson Francisco da Silva
Orientador/UNESP-FEG


Dra. Maribel Perez Ramos da Silva
Membro Externo


Prof(a). Dra. Erica Ximenes Dias
Membro Externo

Dezembro de 2018

RESUMO

Definido pela constituição nacional, a vida é um bem supremo e por tal motivo a saúde como condição fundamental para a preservação da mesma se torna obrigação do Estado, dando o direito a qualquer pessoa enferma ser tratada em um hospital público (CF, art. 196). Tendo em vista as definições da constituição, este trabalho visa gerar uma previsão diária de atendimentos por um ambulatório por meio de um modelo matemático Auto-regressivo. Utilizando o modelo de médias móveis integradas sazonais auto regressivas (SARIMA), espera-se a construção de um modelo confiável e aderente ao problema analisado, possibilitando assim uma melhor organização do ambulatório para que haja uma melhoria tanto na qualidade de atendimento quanto no aproveitamento dos recursos.

PALAVRAS CHAVE: Sarima. Ambulatório. Auto-regressivo.

ABSTRACT

Defined by the national constitution, life is a supreme good and for this reason health as a fundamental condition for the preservation of it becomes the obligation of the State, giving the right to any sick person to be treated in a public hospital (CF, art. 196). In view of the definitions of the constitution, this work aims to generate a daily forecast of care by an ambulatory by means of a mathematical Auto Regressive model. Using the integrated seasonally-adjusted auto-regressive moving average (SARIMA) model, it is expected to build a reliable and adherent model of the analyzed problem, thus enabling a better organization of the outpatient clinic so that there is an improvement both in the quality of care and in the utilization of the resources.

KEYWORDS: Sarima. First aid post. Auto regressive.

SUMÁRIO

1	INTRODUÇÃO	6
1.1	CONTEXTUALIZAÇÃO DA PESQUISA	6
1.2	JUSTIFICATIVA E CONTRIBUIÇÃO CIENTÍFICA	6
1.3	OBJETIVOS E DELIMITAÇÕES.....	9
1.4	MATERIAIS E MÉTODOS	9
1.5	ESTRUTURA DO TRABALHO	10
2	FUNDAMENTAÇÃO TEÓRICA.....	11
2.1	MODELO DE PREVISÃO	11
2.1.1	Modelo matemático de previsão.....	11
2.1.2	Modelo Auto-regressivos lineares estacionários.....	12
2.1.2.1	Modelo Auto-regressivo (AR(p)).....	13
2.1.2.2	Função de autocorrelação.....	13
2.1.2.3	Modelo médias móveis auto regressivas ARMA (p,q).....	14
2.1.3	Modelos Auto-regressivos lineares não estacionários.....	14
2.1.3.1	O modelo Auto-regressivo Integrado Médias Móveis (ARIMA (p,d,q)).....	14
2.1.3.2	Modelo Médias Móveis Integradas Auto Regressivas Sazonais SARIMA (p,d,q) x (P,D,Q).....	15
2.2	ERROS DE PREVISÃO.....	15
2.2.1	Erro Percentual Absoluto Médio – MAPE.....	16
2.2.2	Erro Percentual Médio - MPE.....	16
3	DESCRIÇÃO E MODELAGEM DO PROBLEMA.....	17
3.1	ETAPAS PARA O DESENVOLVIMENTO DO MODELO DE PREVISÃO AUTO-REGRESSIVO	17
3.1.2	Identificação do Modelo SARIMA	18
3.1.3	Validação do modelo	21
4	CONCLUSÕES E RECOMENDAÇÕES PARA FUTURAS PESQUISAS	26
4.1	VERIFICAÇÃO DOS OBJETIVOS.....	26
4.2	RECOMENDAÇÕES PARA FUTURAS PESQUISAS	26
	REFERÊNCIAS	27
	ANEXO A: VALIDAÇÃO DO MODELO DE PREVISÃO	29

1 INTRODUÇÃO

1.1 CONTEXTUALIZAÇÃO DA PESQUISA

No Brasil existe uma política de descentralização da saúde, onde os municípios são responsáveis pela gestão local e a execução dos serviços e ações de saúde (Santos, 2010). Segundo Scatena (2000), 97% dos municípios estavam habilitados em algum tipo de gestão. Deve-se avaliar a municipalização observando sua capacidade de monitorar e cobrir sua população alvo, e capacidade de promover ações em saúde (Silva, 1999).

Desta forma, o sistema de saúde pública juntamente a vigilância sanitária trabalham para detectar surtos epidemiológicos e diminuir seus efeitos, pois quanto mais cedo detectado menor será os custos para atenuar os danos causados (Baer, Olson e Brownstein, 2011).

A compreensão de como os gastos com saúde variam pode ajudar os pesquisadores e formuladores de políticas do sistema de saúde a identificar quais condições, grupos etários e de sexo e tipos de atendimento estão gerando aumentos de gastos. Em particular, essa informação pode ser usada para identificar onde novas tecnologias e processos podem gerar um potencial retorno do investimento (Dieleman *et al.*, 2016).

Apenas algumas das publicações de previsão de demanda prestam atenção suficiente ao componente sazonal mensal claramente existente na série, e também poucas publicações estudam as intervenções ocorridas e incluem essa componente de flutuações irregulares nos modelos de previsão (Goh e Law, 2002). Uma comparação utilizando médias móveis integradas sazonais auto regressivas (SARIMA), pode minimizar os potenciais efeitos de confusão causado pelas desigualdades socioeconômicas e outras diferenças (Abbas, 2001).

1.2 JUSTIFICATIVA E CONTRIBUIÇÃO CIENTÍFICA

O Brasil possui 5.570 municípios, sendo estes marcados por enormes diferenças, tanto socioculturais, contingente populacional e principalmente economicamente (Santos, 2010). Logo, quando se fala de políticas de saúde, há uma complexidade inerente a área, devido a sua heterogeneidade, de modo que diferentes regiões necessitem de diferentes ações de saúde (Ribeiro, 1997).


Os modelos SARIMA têm sido tradicionalmente usados para previsão em economia e estão bem estabelecidos nos campos comercial e industrial (Helfenstein, 1996). Pesquisadores são forçados a usar regressão de Poisson ou modelos SARIMA mais tradicionais, porque há

uma escassez de modelos para dados de contagem de séries temporais e de software disponíveis que permitem a implementação da teoria desenvolvida anteriormente (Hu *et al.*, 2007). Esses modelos permitem uma descrição mais explícita das mudanças sazonais e outras mudanças temporais em conjuntos de dados complexos (Hu et al, 2007).

O GRETl, software utilizado na criação do modelo SARIMA, segundo Chen e Wang (2005), atende desde pesquisadores que necessitam apenas técnicas de mínimos quadrados, como serve para criação de modelos Auto-regressivos, o que o torna uma opção atraente para este tipo de análise.


As figuras 1 e 2 mostram o crescimento da utilização e aplicação do modelo SARIMA principalmente a partir de 2006, observa-se um crescimento expressivo do número de citações.

Figura 1 - Número de Publicações utilizando a palavra-chave “SARIMA”



Fonte: Web of Science (2018).


Figura 2 - Número de citações do termo SARIMA.



Fonte: Web of Science (2018).

A figura 3, nota-se ausência de pesquisas na área de saúde, principalmente sob tema aqui abordado, “*Health Care*” ou pronto atendimento.

Figura 3 - Áreas de conhecimento com aplicações do SARIMA



Fonte: Web of Science (2018).

Mesmo que haja o tópico “*Public Environmental Occupational Health*” que não compreende a área de pesquisa deste trabalho, este tópico representa apenas 8% das aplicações do modelo SARIMA.

1.3 OBJETIVOS E DELIMITAÇÕES

Visa-se criar uma previsão diária do número de atendimentos no ambulatório da sessão técnica de saúde na UNESP de Guaratinguetá.

Como objetivo específico tem-se: Utilizar um modelo auto-regressivo integrado de médias móveis sazonais - SARIMA na previsão diária de atendimentos ambulatoriais na unidade dentro do campus da UNESP de Guaratinguetá com uma precisão de 95%.

O presente trabalho restringe-se a modelagem de séries temporais lineares, desta forma, não serão estudados modelos de séries temporais não lineares.


1.4 MATERIAIS E MÉTODOS

Com objetivos bem definidos, esta pesquisa visa aumentar o acervo disponível sobre modelos auto-regressivos. Dos procedimentos adotados para a construção do mesmo, percebe-se a natureza aplicada, com objetivos empíricos descritivos, e abordagem quantitativa, sendo a modelagem e simulação o procedimento metodológico (Bertrand e Fransoo, 2002)

O modelo Box & Jenkins funciona com um ciclo iterativo, onde se escolhe o modelo a partir dos dados colhidos. Para se determinar o modelo de previsão que simula a curva formada pelos dados de entrada deve-se seguir as três etapas descritas na figura 4 (Morretin e Toloí, 2006).

Dentro dos modelos auto-regressivos, para este caso foi selecionado o modelo SARIMA – Médias Móveis Integradas Sazonais Auto Regressivas.

Figura 4 - Quadro Representativo dos Estágios do Ciclo Iterativo de Box-Jenkins



Fonte: Adaptado de Marchezan (2007).

1.5 ESTRUTURA DO TRABALHO

Além da introdução, este trabalho contém outros três capítulos. Sendo que o capítulo dois descreve a fundamentação teórica, desenvolvimento matemático e aprofundamento no modelo auto-regressivo. No capítulo três constam os resultados obtidos juntamente a identificação do modelo, estimativas produzidas, previsões criadas, e validação do modelo. Finalizando este estudo o capítulo quatro resume as conclusões obtidas, e recomenda futuras pesquisas que complementares a esta, seguido por referências bibliográficas e anexos.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 MODELO DE PREVISÃO

Conforme foi citado no capítulo anterior o uso de series temporais como o SARIMA já é amplamente difundido em áreas como economia, comércio e indústria (Helfenstein, 1996). Ainda para Morettin e Toloi (2006), as observações dos dados devem servir para descrever um modelo que represente a curva de dados, de modo que possam ser tiradas conclusões lógicas e estatísticas e, posteriormente adaptar o modelo para realizar previsões.

A funcionalidade de uma series temporal se dá quando o comportamento extrapolado do passado e do futuro se assemelhem, mostrando que o modelo carregou características comuns ao seu comportamento (WHEEL, WRIGHT, 1985, GOOIJER, 2006).

2.1.1 Modelo matemático de previsão

A principal diferença entre os métodos utilizados é a maneira como os dados foram contabilizados. Portanto, é importante conhecer o princípio por trás de cada um dos modelos de previsão para entender melhor as diferenças na saída da previsão.

Morettin e Toloi (2004), definem uma série histórica como a coleta de dados em períodos regulares, por um prazo determinado de modo que apresentem uma dependência seriada. Para representação matemática da série temporal utiliza-se Z_t , e t como momento, compondo assim Z_t , em que $t = 1, 2, 3, \dots, n$ indica o t amanho da série.

No intuito de descrever séries temporais, utilizam-se processos controlados por leis probabilísticas, denominados processos estocásticos (ESPINDOLA, 2013). Uma série é considerada estacionária quando esta se desenvolve no tempo ao redor de uma média refletindo uma certa estabilidade. É frequente a suposição de que séries temporais são estacionarias, entretanto, a maior parte encontrada se apresenta como não-estacionaria, justificada por pelo menos um dos quatro seguintes fatores:

- *Tendência*: verifica o deslocamento da série ao longo do tempo.
- *Sazonalidade*: movimento ondulatório de curta duração, em geral, inferior a um ano; geralmente associada a mudança climática.
- *Ciclo*: movimento ondulatório que ao longo de vários anos tende a ser periódico


- *Ruído Aleatório*: Compreende a variedade intrínseca aos dados e não pode ser modelado.

Modelos auto-regressivos (AR) e médias móveis auto regressivas (ARMA) estão diretamente ligados a linearidade e estacionaridade, como grande parte dos métodos utilizados em séries temporais (Moretin, 2006). Neste Contexto, um processo é estacionário quando, distribuições unidimensionais não variam ao passar do tempo, sendo a média e a variância constantes (Moretin, 2006).

2.1.2 Modelo Auto-regressivos lineares estacionários

Conforme citado em trechos anteriores os modelos estacionários são aqueles em que sua média, variância e autocovariância são constantes em relação ao tempo, e podem ser classificados em, Auto-regressivos (AR), Médias Móveis (MA) e a combinação de ambos formando Auto-regressivo de Médias Móveis (ARMA) (Tubino, 2007). A Figura 5 exibe um ruído branco, processos em que todas as suas variáveis aleatórias são expressas por meio de uma distribuição normal de média 0 com variância constante e covariância nula, que é estacionário.

Figura 5 - Ruído Branco



Fonte: Moretin e Toloi (2006).

2.1.2.1 Modelo Auto-regressivo (AR(p))

Um modelo simples que funciona como um bloco de construção para modelos mais complexos é o modelo Auto-regressivo (AR). O modelo AR(1) pode ser escrito como

$$y_t = \phi_0 + \phi_1 y_{t-1} + a_t,$$

Onde a_t é o ruído da série. Generalizando, o modelo AR pode ser descrito por

$$y_t = \phi_0 + \sum_{i=1}^P \phi_i y_{t-i} + a_t.$$

2.1.2.2 Função de autocorrelação

A função de autocorrelação é definida como a dependência linear entre y_t e seu valor anterior y_{t-s}

$$\rho_s = \frac{\text{Cov}(y_t; y_{t-s})}{\sqrt{\text{var}(y_t) \text{var}(y_{t-s})}}.$$

Sob a hipótese de estacionaridade fraca, isso se torna

$$\rho_s = \frac{\text{Cov}(y_t; y_{t-s})}{\text{var}(y_t)}.$$

Com $-1 \leq \rho_s \leq 1$. Para uma dada série, a Autocorrelação de amostras segue a função para y_t com $\text{lag} = s$ é definida como

$$\hat{\rho}_s = \frac{\sum_{t=s+1}^T (y_t - \bar{y})(y_{t-s} - \bar{y})}{\sum_{t=1}^T (y_t - \bar{y})^2}.$$

A autocorrelação parcial fornece a correlação de diferentes defasagens para a série de tempos condicionada nos defasamentos mais curtos. Através do conceito dos modelos AR (p) demonstra-se a autocorrelação parcial

$$y_t = \phi_{0,1} + a_t + \phi_{1,1} y_{t-1}$$

$$y_t = \phi_{0,2} + a_t + \phi_{1,2} y_{t-1} + \phi_{2,2} y_{t-2}$$

$$y_t = \phi_{0,3} + a_t + \phi_{1,3} y_{t-1} + \phi_{2,3} y_{t-2} + \phi_{3,3} y_{t-3}$$

.

.

As equações acima estão na forma de regressão linear e poder ser estimadas através do método dos mínimos quadrados, e podem ser usadas para determinar a ordem de um modelo AR.

$$y_t - \phi_1 y_{t-1} = \phi_0 + a_t - \phi_1 a_{t-1},$$

Onde a_t é o ruído branco da série. O lado esquerdo da equação é o componente AR, e do lado direito o componente MA. Este modelo pode ser reescrito como

$$y_t = \phi_1 y_{t-1} + \phi_0 + a_t - \phi_1 a_{t-1},$$

Generalizando o modelo ARMA (p,q) pode-se escrever

$$y_t = \sum_{i=1}^p \phi_i y_{t-i} + \phi_0 + a_t - \sum_{i=1}^q \phi_i a_{t-i},$$

Onde a_t é o ruído branco e p e q são números inteiros e não negativos.

2.1.2.3 Modelo médias móveis auto regressivas ARMA (p,q)

O modelo ARMA combina os modelos Auto-regressivos e Médias variáveis em um modelo, um benefício dessa idéia é que o número de parâmetros no modelo pode ser mantido pequeno. Uma série temporal y_t é considerada um modelo ARMA (1,1) se satisfaz

2.1.3 Modelos Auto-regressivos lineares não estacionários

Modelos não estacionários são aqueles que apresentam uma média e variância que variam com o tempo. São classificados em: Auto-regressivo Integrado de Médias Móveis (ARIMA) e Auto-regressivos Sazonais Integrados de Médias Móveis (SARIMA).

2.1.3.1 O modelo Auto-regressivo Integrado Médias Móveis (ARIMA (p,d,q))

O modelo cuida de séries temporais que precisam ser diferenciadas antes que qualquer modelo possa ser aplicado. Utilizando operador *backshift*. O ARIMA geral (p,d,q) pode ser escrito com:

$$(1 - \sum_{i=1}^p \phi_i B^i)(1 - B)^d y_t = (1 - \sum_{i=1}^q \theta_i B^i) a_t$$

Onde a_t é o ruído da série.

2.1.3.2 Modelo Médias Móveis Integradas Auto Regressivas Sazonais SARIMA (p,d,q) x (P,D,Q)

SARIMA em uma tradução seria Média Móvel Integrada Autorregressiva Sazonal. O modelo é útil ao modelar dados que exibem efeitos sazonais, ou seja, quando os dados são diferenciados com um atraso maior que 1. O modelo SARIMA tem um conjunto de parâmetros para os componentes sazonais e não sazonais. SARIMA (p,d,q)(P,D,Q) pode ser escrito como:

$$(1 - \sum_{i=1}^P \phi_i B^{si})(1 - B^s)^D (1 - \sum_{i=1}^p \phi_i B^i)(1 - B)^d y_t = (1 - \sum_{i=1}^q \theta_i B^i) (1 - \sum_{i=1}^Q \theta_i B^{si}) a_t$$

Onde a_t é o ruído branco e p,q,P e Q são inteiros não negativos. Um exemplo de utilização real do SARIMA ocorre nos países nórdicos, para definir o valor da eletricidade são considerados os efeitos sazonais diariamente, semanalmente e anualmente, onde o efeito semanal é o mais pronunciado.

2.2 ERROS DE PREVISÃO

A precisão da previsão é referida à quão perto as previsões chegam dos dados reais. Os indicadores são utilizados para verificar medidas de desempenho do nível de precisão que o modelo de previsão possui. Quando as previsões estão muito próximas dos dados reais, significam erros de precisão baixos, logo são mais aceitáveis. Quando os erros de precisão são maiores é sinal que o modelo de previsão deve ser alterado ou ajustado.

Considere um erro de previsão entre X real e o valor previsto $\hat{X}$ representado por:

$$e = X - \hat{X}.$$

Para analisar e decidir o melhor modelo de previsão que se ajusta aos dados deve-se levar em conta os indicadores listados nas seções seguintes.

2.2.1 Erro Percentual Absoluto Médio – MAPE

A primeira métrica que vamos introduzir é o erro percentual absoluto médio – MAPE (mean absolute percentage error) que geralmente é expressa em termos percentuais, pode ser definida da seguinte maneira:

$$MAPE = \frac{\sum_{i=1}^n \left| \frac{x_t - \bar{F}_t}{x_t} \right| (100)}{n}$$

Onde n é o numero de previsões pontuais, x_t é o valor real e F_t é o valor previsto. Uma limitação do MAPE é que a divisão por zero pode ocorrer se $x_t = 0$, no entanto, não vamos nos deparar com este problema, uma vez que toda a nossa observação é diferente de zero.

2.2.2 Erro percentual médio - MPE

Outro métrica de previsão útil é o erro percentual médio, que é definido como:

$$MPE = \frac{\sum_{i=1}^n \frac{x_t - F_t}{x_t} (100)}{n}$$

Como MPE não usa valores absolutos, erros de previsão positivos e negativos cancelarão um ao outro, fazendo do MPE uma métrica complementar ao MAPE e uma boa maneira de avaliar o viés na previsão.

A descrição matemática expressa no capítulo dois se baseia na livre tradução da tese de Christopher Hellesnes (Hellesnes, 2017).

3 DESCRIÇÃO E MODELAGEM DO PROBLEMA

O Ambulatório forneceu o número de atendimentos diários, nos últimos 2 anos, totalizando 511 observações. Os dados foram agrupados na Tabela (Anexos) de forma contínua para serem introduzidos no *software* o que possibilita um tratamento mais robusto.


3.1 ETAPAS PARA O DESENVOLVIMENTO DO MODELO DE PREVISÃO AUTO-REGRESSIVO

3.1.1 Dados ambulatoriais

Os dados foram recebidos em forma de relatórios diários que continham o número de atendimentos no ambulatório da Faculdade de Engenharia de Guaratinguetá. Como o trabalho visa a previsão do número de atendimentos sem a distinção de tipo de atendimento, os números em análises são dados pelas somas dos números (diários) de atendimentos efetuado pelos três médicos sendo apresentados no Anexo A.

A Figura 6 representa o número de atendimentos de 05/01/2015 à 19/12/2016, totalizando 511 dias, pois o funcionamento do pronto atendimento da faculdade não funciona aos sábados, domingos e feriados. É necessário confirmar o comportamento sazonal da série temporal demonstrada na figura 6. Os meses subsequentes foram deixados para o acompanhamento e validação do modelo de previsão.

Figura 6 – Atendimentos Diários




Fonte: Produção do próprio autor.

3.1.2 Identificação do Modelo SARIMA

Inicialmente é necessário definir d , para isso gera-se correlogramas até que haja uma normalização do gráfico de modo que a média se torne constante, que ocorre para $d = 1$ como é visível na figura 7.

Figura 7 - Correlograma para primeira diferenciação da série temporal



Fonte: Produção do próprio autor.

Para seguir identificando o modelo, é necessário que se determine p (filtro auto-regressivo) e q (filtro de médias), também utiliza-se correlogramas, e como critério de seleção é feito um cálculo de $2/(\text{Raiz de } n)$, onde n , é o número de valores da amostra após a definição de d , no caso 510, efetuando o cálculo obtemos o valor de 0,0886 que será o ponto de referência. Então geramos novamente correlogramas, com apenas 5 pontos de defasagem, tendo em vista que a literatura já comenta que os valores de p e q não serão maiores que cinco. Para selecionarmos p , este será o ultimo valor de FACP (função auto regressiva parcial) acima do ponto de referência e q é o último valor abaixo da referência em FAC (função auto regressiva), conforme a figura 8, selecionamos 5 para p e 1 para q , já que todos os valores são menores que a referência. Então no momento temos definido o Modelo como (5,1,1).

Figura 8 - Função de autocorrelação para o modelo


Função de autocorrelação para d_v1
 ***, **, * indicam significância aos níveis de 1%, 5% e 10%
 usando erro padrão $1/T^{0,5}$

Defas.	FAC		FACP		Estat. Q	[p-valor]
1	-0,4320	***	-0,4320	***	85,4825	[0,000]
2	0,0211		-0,2035	***	85,6869	[0,000]
3	-0,0370		-0,1461	***	86,3165	[0,000]
4	-0,0636		-0,1850	***	88,1789	[0,000]
5	0,0697		-0,0731		90,4262	[0,000]

Fonte: Produção do próprio autor.

Para determinar se o modelo é sazonal, gera-se um periódograma, observa-se um pico muito destacado, o que caracteriza um ponto de sazonalidade, para a construção do modelo é necessário atenuar esses picos, para isso são feitas duas defasagens sazonais de modo que obtém-se o gráfico expresso na figura 9, onde os picos estão atenuados.

Figura 9 - Periódograma da série temporal



Fonte: Produção do próprio autor.

Como o modelo é sazonal, precisa-se definir os filtros sazonais P, D e Q. Com $D = 2$, necessita-se da determinação dos faltantes. Para tanto, realiza-se as análises de sua função de auto correlação apresentada na Figura 10. Seguindo o mesmo procedimento para determinar p e q , determina-se os valores de P e Q.

Figura 10 - Função de autocorrelação sazonal

Função de autocorrelação para sd_sd_v1
 ***, **, * indicam significância aos níveis de 1%, 5% e 10%
 usando erro padrão $1/T^{0,5}$

Defas.	FAC		FACP		Estat. Q	[p-valor]
1	0,3371	***	0,3371	***	51,0350	[0,000]
2	0,1613	***	0,0537		62,7372	[0,000]
3	-0,0696		-0,1574	***	64,9192	[0,000]
4	-0,2449	***	-0,2156	***	92,0327	[0,000]
5	-0,6878	***	-0,6333	***	306,3588	[0,000]

Fonte: Produção do próprio autor.

Para a aproximação do índice P, busca-se o último valor (em módulo) que está acima do ponto de referência (0,0894), portanto $P = 3$ e para Q o último valor abaixo do ponto de referência: $Q = 4$. Apesar de apresentar indicativos, os fatores sazonais só serão estabelecidos após ajustes, afim de determinar a melhor solução. O modelo SARIMA no momento é $(5,1,1) \times (3,2,4)$.

3.1.3 Validação do modelo

A validação do modelo pode ser feita através da análise de resíduos e avaliação da ordem do modelo (Fava, 2000). Para a validação foram gerados modelos no Gretl, e analisados os P-valores, até que estes estivessem dentro dos 5% de tolerância como definido no objetivo. Tal resultado foi obtido no modelo $(2,1,1) \times (3,2,4)$, utilizando o X-12 ARIMA e removendo as constantes.

Figura 11 - Modelo definido - todos p-valores menores de 5%

Modelo 5: ARIMA, usando as observações 2015-01-20:2016-10-03 (T = 445)
 Estimado usando X-12-ARIMA (Máxima verossimilhança exata)
 Variável dependente: (1-L)(1-Ls)^2 vl


	coeficiente	erro padrão	z	p-valor	
phi_1	0,258801	0,0539025	4,801	1,58e-06	***
phi_2	0,112499	0,0503369	2,235	0,0254	**
Phi_1	-1,30044	0,0632981	-20,54	8,60e-094	***
Phi_2	-0,733392	0,0849328	-8,635	5,87e-018	***
Phi_3	0,114978	0,0490845	2,342	0,0192	**
theta_1	-0,902873	0,0303999	-29,70	7,71e-194	***
Theta_1	-0,627004	0,0477573	-13,13	2,25e-039	***
Theta_2	-0,870362	0,0592890	-14,68	8,66e-049	***
Theta_3	-0,366232	0,0601679	-6,087	1,15e-09	***
Theta_4	0,869484	0,0461430	18,84	3,34e-079	***
Média var. dependente	-0,006742	D.P. var. dependente	10,07349		
Média de inovações	-0,039855	D.P. das inovações	3,560420		
Log da verossimilhança	-1232,814	Critério de Akaike	2487,628		
Critério de Schwarz	2532,707	Critério Hannan-Quinn	2505,404		

Fonte: Produção do próprio autor.

3.1.4 Análise de aderência

Após definido o modelo é necessário avaliar o seu comportamento e aderência ao real, quando gerado o gráfico do modelo sobre a curva real, obtemos a figura 12, onde é visível que o modelo consegue simular o comportamento da curva real.

Figura 12 - Gráficos efetivo e ajustado sobrepostos




Fonte: Produção do próprio autor.

3.1.5 Avaliação da ordem do modelo

A verificação da ordem do modelo se dá pela análise do erro padrão dos coeficientes. Se o coeficiente considerado quando comparado ao seu erro padrão for pequeno, pode-se considera-lo inexpressivo e descartá-lo (Werner e Ribeiro, 2003). Verifica-se na Figura 11, que o modelo SARIMA de filtros $(2,1,1) \times (3,2,4)$, se mostram significativos, pois apresentam p-valor menor que 5% ou 0,05(nível de significância).

Observa-se na figura 11 o grau de aderência do modelo pelo p-valor onde os maiores valores não chegam a metade da referência (0,0865). Na Figura 12, pode-se observar a aderência do modelo quando a partir dos dados preditos geramos uma previsão com precisão de 95%. A curva se comporta como no mesmo período do ano anterior, uma queda considerável e se mantém dentro do intervalo de confiança.


Figura 13 - Gráfico de Previsão



Fonte: Produção do próprio autor.

Observa-se o comportamento ajustado do modelo quando se faz o teste do qui-quadrado para observar os valores dentro de uma curva gaussiana. Mostrando assim a veracidade do modelo SARIMA (2,1,1) x (3,2,4), e como a margem de erro é muito baixa, menor até mesmo que os 5% estipulados no início do trabalho.

Figura 14 - Gráfico de Curva Gaussiana



Fonte: Produção do próprio autor.

4 CONCLUSÕES E RECOMENDAÇÕES PARA FUTURAS PESQUISAS

4.1 VERIFICAÇÃO DOS OBJETIVOS

Como apresentado no tópico anterior, foi visível que o modelo SARIMA (2,1,1) x (3,2,4) atendeu os requisitos, aderindo fortemente a curva real, podendo assim ser utilizado para gerar previsões.

Esta pesquisa gera uma contribuição à instituição e a sociedade, sendo uma nova aplicação do modelo SARIMA, quando se observa no âmbito científico, além de cumprir seu objetivo de gerar uma previsão para que se pudesse fazer melhor uso dos recursos do ambulatorio, melhorando sua eficiência e até mesmo sua capacidade de atendimentos sem comprometer a qualidade do mesmo.

O modelo se apresentou resistente e sua aderência com a proposta foi grande, podendo ser demonstrado algebricamente utilizando-se as diretrizes da literatura.

4.2 RECOMENDAÇÕES PARA FUTURAS PESQUISAS

- Recomenda-se utilizar a combinação de múltiplos métodos de previsão afim de uma melhor robustez do dado predito em relação ao real.
- Vale ressaltar que é de suma importância a extensão da aplicação destes métodos para diversas áreas que ainda não possuem em sistema eficiente de gestão e planejamento.
- Verificar a aplicação do modelo auto-regressivo em outras séries temporais, delimitando novos intervalos em virtude de outras prioridades da gestão.
- Utilizar o modelo de Redes Neurais Artificiais.

REFERÊNCIAS

- ABBAS, K. **Gestão de custos em organizações hospitalares**. Dissertação (Mestrado em Engenharia de Produção) – Universidade Federal de Santa Catarina, Florianópolis, 2001. Disponível em: <https://core.ac.uk/download/pdf/30360695.pdf>. Acesso em: 09 jul. 2018.
- BAER, A.; OLSON, D. R.; BROWNSTEIN, J. S. Enhancing the synergy between research, informatics, and practice in public health. International society for disease surveillance conference 2010. **Emerging Health Threats Journal**, v. 1, p. 3-4, 2011.
- Bertrand, J.; and Fransoo, J. Operations Management Research Methodologies Using Quantitative Modeling. **International Journal of Operations & Production Management**, v. 22, p. 241-264, 2002.
- CHEN, K. Y.; WANG, C. H. A. Hybrid SARIMA and support vector machines in forecasting the production values of the machinery industry in Taiwan. **Expert Systems with Applications**, v. 32, n. 1, p. 254-264, 2007. Disponível em: <https://doi.org/10.1016/j.eswa.2005.11.027>. Acesso em: 09 jul. 2018.
- DIELEMAN, J. L.; BARAL, R.; BIRGER M. US Spending on personal health care and public health 1996-2013. JAMA NETWORK, December 27, 2016. Disponível em: <https://jamanetwork.com/journals/jama/fullarticle/2594716>. Acesso em: 09 jul. 2018.
- ESPÍNDOLA, A. M. S. **Inteligência competitiva e modelos de séries temporais para previsão de consumo: o estudo de uma empresa do setor metalúrgico**. 2013. 148 f. Dissertação (Mestrado em Administração) Caixias do Sul: Universidade Caixias do Sul, 2013.
- FAVA, V. L. Análise de séries de tempo. In: VASCONCELLOS, M. A. S.; Alves, D. **Manual de econometria: nível intermediário**. São Paulo: Atlas, 2000.
- GOH, C.; LAW, R. Modeling and forecasting tourism demand for arrivals with stochastic nonstationary seasonality and intervention. **Tourism Management**, v. 23, ed. 5, p. 499-510 Elsevier, 2002.
- HELFENSTEIN, U. Box-Jenkins modelling in medical research. **SAGE Journals**, Zurique, v. 5, p. 3-22, 1996.
- HELLESNES, C. **Forecast evaluation of dynamic regression and sarima models applied to Electricity Spot Prices- Time Series Analysis**. 2017. 30 f. Dissertação (Bacharel em Matemática Estatística) - Stockholms universitet, Estocolmo, 2017.
- HU, W.; TONG, S.; MENGERSEN, K.; CONNELL, D. **Weather variability and the incidence of cryptosporidiosis: Comparison of time series Poisson regression and SARIMA models**. 2007. 88 f. Centre for Health Research, School of Public Health, Queensland University of Technology, Brisbane, Queensland, Australia, 2007.
- MORETTIN, P. A.; TOLOI, C. M. C. **Análise de séries temporais**. São Paulo: Edgar Blucher, 2006. 564 p.

RIBEIRO, J. M. Conselhos de saúde, comissões intergestores e grupos de interesses no Sistema Único de Saúde (SUS). **Caderno de saúde pública**, Rio de Janeiro, v. 13, n. 1, p. 81-92, jan./mar.1997.

SANTOS, M. **Atlas nacional do Brasil**. Rio de Janeiro: IBGE, 2010. p. 28-31.

SCATENA J. H. **Avaliação da Descentralização da Assistência a Saúde no Estado do Mato Grosso do Sul**. Tese. (Doutorado em Saúde Pública) Faculdade de Saúde Pública, Departamento de Saúde Materno-Infantil, São Paulo, 2000.

SILVA, L. M. V. Avaliação do processo de descentralização das ações de saúde. **Ciência & Saúde Coletiva**, v. 4, n. 2, p. 331-339, 1999.

TUBINO, D. F. **Planejamento e controle da produção**. Sao Paulo: Atlas, 2007. 190 p.

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

ANEXO A: VALIDAÇÃO DO MODELO DE PREVISÃO

Tabela 1 - Número de atendimentos diários

Data	Total de Atendimentos		
05/01/2015	6	04/03/2015	12
06/01/2015	4	05/03/2015	9
07/01/2015	8	06/03/2015	8
08/01/2015	5	09/03/2015	16
09/01/2015	4	11/03/2015	9
12/01/2015	5	12/03/2015	16
13/01/2015	6	13/03/2015	17
14/01/2015	6	16/03/2015	13
15/01/2015	5	17/03/2015	11
16/01/2015	6	18/03/2015	11
19/01/2015	6	19/03/2015	7
20/01/2015	6	20/03/2015	7
21/01/2015	7	23/03/2015	11
22/01/2015	6	24/03/2015	12
23/01/2015	5	25/03/2015	11
26/01/2015	7	26/03/2015	8
27/01/2015	12	27/03/2015	11
28/01/2015	10	30/03/2015	11
29/01/2015	10	31/03/2015	14
30/01/2015	10	01/04/2015	6
02/02/2015	11	02/04/2015	13
03/02/2015	7	07/04/2015	13
04/02/2015	9	08/04/2015	10
05/02/2015	11	09/04/2015	10
06/02/2015	9	10/04/2015	15
09/02/2015	12	13/04/2015	13
10/02/2015	15	14/04/2015	13
11/02/2015	13	15/04/2015	11
12/02/2015	11	16/04/2015	13
13/02/2015	5	17/04/2015	12
19/02/2015	8	22/04/2015	13
20/02/2015	8	23/04/2015	11
23/02/2015	14	24/04/2015	9
24/02/2015	10	27/04/2015	14
25/02/2015	5	28/04/2015	5
26/02/2015	4	29/04/2015	12
27/02/2015	5	30/04/2015	16
02/03/2015	11	04/05/2015	11
03/03/2015	12	05/05/2015	16
		06/05/2015	12
		07/05/2015	11

08/05/2015	12
11/05/2015	14
13/05/2015	15
14/05/2015	13
15/05/2015	17
18/05/2015	18
19/05/2015	14
20/05/2015	15
21/05/2015	11
22/05/2015	11
25/05/2015	11
26/05/2015	10
28/05/2015	14
29/05/2015	15
01/06/2015	12
02/06/2015	12
03/06/2015	11
08/06/2015	11
09/06/2015	8
10/06/2015	8
11/06/2015	16
12/06/2015	4
15/06/2015	12
16/06/2015	10
17/06/2015	15
18/06/2015	11
19/06/2015	4
22/06/2015	12
23/06/2015	13
24/06/2015	3
25/06/2015	3
26/06/2015	6
29/06/2015	7
30/06/2015	9
01/07/2015	13
02/07/2015	11
03/07/2015	17
06/07/2015	7
07/07/2015	10
08/07/2015	3
13/07/2015	2
15/07/2015	3
16/07/2015	4
17/07/2015	1
21/07/2015	10

22/07/2015	9
23/07/2015	8
24/07/2015	6
27/07/2015	2
28/07/2015	3
29/07/2015	4
30/07/2015	12
31/07/2015	9
03/08/2015	10
04/08/2015	14
05/08/2015	14
06/08/2015	9
07/08/2015	1
10/08/2015	6
11/08/2015	11
12/08/2015	8
13/08/2015	11
14/08/2015	6
17/08/2015	16
18/08/2015	15
19/08/2015	14
20/08/2015	15
21/08/2015	11
24/08/2015	13
25/08/2015	12
26/08/2015	13
27/08/2015	9
28/08/2015	7
31/08/2015	1
01/09/2015	4
02/09/2015	18
03/09/2015	12
04/09/2015	14
08/09/2015	12
09/09/2015	12
10/09/2015	11
11/09/2015	6
14/09/2015	13
15/09/2015	10
16/09/2015	11
17/09/2015	13
18/09/2015	8
21/09/2015	12
22/09/2015	16
24/09/2015	9

25/09/2015	9
28/09/2015	13
29/09/2015	7
30/09/2015	10
01/10/2015	5
02/10/2015	10
05/10/2015	4
06/10/2015	12
07/10/2015	15
08/10/2015	6
09/10/2015	12
12/10/2015	6
13/10/2015	7
14/10/2015	5
15/10/2015	7
16/10/2015	7
19/10/2015	12
20/10/2015	15
21/10/2015	8
22/10/2015	8
23/10/2015	12
26/10/2015	14
27/10/2015	16
28/10/2015	9
29/10/2015	16
03/11/2015	14
04/11/2015	18
05/11/2015	8
06/11/2015	10
09/11/2015	13
10/11/2015	15
11/11/2015	13
12/11/2015	13
13/11/2015	10
16/11/2015	9
17/11/2015	10
18/11/2015	10
19/11/2015	10
20/11/2015	11
23/11/2015	20
24/11/2015	9
25/11/2015	11
26/11/2015	11
27/11/2015	9
30/11/2015	8

01/12/2015	9
02/12/2015	3
03/12/2015	5
04/12/2015	7
08/12/2015	5
09/12/2015	5
10/12/2015	6
11/12/2015	4
15/12/2015	6
16/12/2015	6
17/12/2015	5
04/01/2016	2
05/01/2016	10
06/01/2016	4
07/01/2016	7
08/01/2016	9
11/01/2016	3
12/01/2016	10
13/01/2016	8
14/01/2016	3
15/01/2016	5
18/01/2016	10
19/01/2016	7
20/01/2016	5
21/01/2016	5
22/01/2016	7
25/01/2016	8
26/01/2016	7
27/01/2016	12
28/01/2016	14
29/01/2016	5
01/02/2016	8
02/02/2016	14
03/02/2016	14
04/02/2016	13
05/02/2016	18
11/02/2016	9
12/02/2016	9
15/02/2016	10
16/02/2016	12
17/02/2016	12
18/02/2016	15
19/02/2016	13
22/02/2016	13
23/02/2016	8

24/02/2016	10
25/02/2016	18
26/02/2016	17
29/02/2016	18
02/03/2016	2
03/03/2016	14
04/03/2016	14
07/03/2016	16
08/03/2016	11
09/03/2016	8
10/03/2016	13
11/03/2016	20
14/03/2016	14
15/03/2016	11
16/03/2016	16
17/03/2016	14
18/03/2016	11
21/03/2016	19
22/03/2016	12
23/03/2016	11
24/03/2016	14
29/03/2016	8
30/03/2016	13
31/03/2016	11
01/04/2016	18
04/04/2016	12
05/04/2016	15
06/04/2016	12
07/04/2016	17
08/04/2016	18
11/04/2016	14
12/04/2016	17
13/04/2016	7
14/04/2016	11
15/04/2016	10
18/04/2016	13
19/04/2016	14
20/04/2016	11
25/04/2016	15
26/04/2016	13
27/04/2016	11
28/04/2016	17
29/04/2016	9
02/05/2016	15
03/05/2016	11

04/05/2016	14
05/05/2016	13
06/05/2016	7
09/05/2016	13
10/05/2016	13
11/05/2016	15
12/05/2016	13
13/05/2016	14
16/05/2016	10
17/05/2016	12
18/05/2016	12
19/05/2016	8
20/05/2016	13
23/05/2016	11
24/05/2016	12
25/05/2016	15
30/05/2016	17
31/05/2016	15
01/06/2016	14
02/06/2016	18
03/06/2016	15
06/06/2016	8
07/06/2016	6
08/06/2016	4
09/06/2016	4
10/06/2016	5
13/06/2016	9
14/06/2016	9
15/06/2016	9
16/06/2016	9
17/06/2016	9
20/06/2016	9
21/06/2016	9
22/06/2016	9
23/06/2016	9
24/06/2016	9
27/06/2016	9
28/06/2016	9
29/06/2016	9
30/06/2016	9
01/07/2016	13
04/07/2016	11
05/07/2016	17
06/07/2016	7
07/07/2016	10

08/07/2016	3
11/07/2016	2
12/07/2016	3
13/07/2016	4
14/07/2016	1
15/07/2016	10
18/07/2016	9
19/07/2016	8
20/07/2016	6
21/07/2016	2
22/07/2016	3
25/07/2016	4
26/07/2016	12
27/07/2016	9
28/07/2016	10
29/07/2016	14
01/08/2016	14
02/08/2016	9
03/08/2016	1
04/08/2016	6
05/08/2016	11
08/08/2016	8
09/08/2016	11
10/08/2016	6
11/08/2016	16
12/08/2016	15
15/08/2016	14
16/08/2016	15
17/08/2016	11
18/08/2016	13
19/08/2016	12
22/08/2016	13
23/08/2016	9
24/08/2016	7
25/08/2016	1
26/08/2016	4
29/08/2016	18
30/08/2016	12
31/08/2016	14
01/09/2016	12
02/09/2016	12
05/09/2016	11
06/09/2016	6
08/09/2016	13
09/09/2016	10

12/09/2016	11
13/09/2016	13
14/09/2016	8
15/09/2016	12
16/09/2016	16
19/09/2016	9
20/09/2016	9
21/09/2016	13
22/09/2016	7
23/09/2016	10
26/09/2016	5
27/09/2016	10
28/09/2016	4
29/09/2016	7
30/09/2016	12
03/10/2016	12
04/10/2016	13
05/10/2016	13
06/10/2016	14
07/10/2016	15
10/10/2016	15
11/10/2016	8
13/10/2016	12
14/10/2016	6
17/10/2016	17
18/10/2016	12
19/10/2016	17
20/10/2016	17
21/10/2016	12
24/10/2016	12
26/10/2016	15
27/10/2016	7
31/10/2016	18
01/11/2016	6
03/11/2016	6
04/11/2016	6
07/11/2016	1
08/11/2016	1
09/11/2016	3
10/11/2016	3
21/11/2016	3
22/11/2016	4
23/11/2016	5
24/11/2016	5
25/11/2016	5

28/11/2016	3
29/11/2016	1
30/11/2016	1
01/12/2016	8
02/12/2016	6
05/12/2016	6
06/12/2016	5
07/12/2016	7

08/12/2016	5
09/12/2016	4
12/12/2016	5
13/12/2016	1
14/12/2016	4
15/12/2016	10
16/12/2016	6
19/12/2016	3