

Comparação dos modelos ARIMA, RNA e híbrido ARIMA-RNA para a previsão dos custos de internações hospitalares pelo Sistema Único de Saúde (SUS) na região Centro-Oeste do Brasil

Comparison of ARIMA, RNA and ARIMA-RNA hybrid models for the prediction of hospitalization costs by the Unique Health System (UHS) in the Central-West region of Brazil

Comparación de modelos híbridos ARIMA, RNA y ARIMA-RNA para la previsión de costos de hospitalización por el Sistema Único de Salud (SUS) en la región Centro-Oeste de Brasil

Recebido: 07/11/2022 | Revisado: 20/11/2022 | Aceitado: 22/11/2022 | Publicado: 28/11/2022

Celso Correia de Souza

ORCID: <https://orcid.org/0000-0002-2689-8264>
Pesquisador Produtividade do CNPq, Brasil
E-mail: csouza939@gmail.com

Joao Bosco Arbués Carneiro Junior

ORCID: <https://orcid.org/0000-0001-7094-2245>
Universidade Federal de Rondonópolis, Brasil
E-mail: jbacj@hotmail.com

Márcia Ferreira Cristaldo

ORCID: <https://orcid.org/0000-0001-8790-7163>
Instituto Federal de Mato Grosso do Sul, Brasil
E-mail: marcia.cristaldo@ifms.edu.br

Raul Asseff Castelão

ORCID: <https://orcid.org/0000-0002-4677-6088>
Universidade Anhuera Uniderp, Brasil
E-mail: raulassefcastelao@gmail.com

Daniel Massen Frainer

ORCID: <https://orcid.org/0000-0003-0813-214X>
Universidade Estadual do Mato Grosso do Sul, Brasil
E-mail: danielfrainer@gmail.com

Hevelyne Henn da Gama Viganó

ORCID: <https://orcid.org/0000-0001-6951-7903>
Instituto Federal de Mato Grosso do Sul, Brasil
E-mail: hevelyne.vigano@ifms.edu.br

Celso Fabricio Correia de Souza

ORCID: <https://orcid.org/0000-0002-4593-2798>
Universidade Estadual de Campinas, Brasil
E-mail: celsofabricio76@gmail.com

Juliana Maria Correia de Souza Vieira

ORCID: <https://orcid.org/0000-0003-4478-9405>
Universidade Anhuera Uniderp, Brasil
E-mail: julianamaria2002@hotmail.com

Resumo

É de suma importância para os gestores de instituições brasileiras de saúde pública utilizarem ferramentas computacionais que propiciem a estimação de seus custos de modo a auxiliá-los nas tomadas de decisões. Essa importância ganha mais relevância quando se trata de instituições de saúde pública brasileira, que precisam manter o gasto mensal dentro do limitado repasse de verbas do Sistema Único de Saúde (SUS). Sendo assim, este estudo propõe o uso do modelo híbrido ARIMA-RNA como técnica e método de previsão dos custos totais de internações em instituições públicas no Centro-Oeste brasileiro, comparando-o com os modelos ARIMA e RNA_MLP, tratados separadamente, para a escolha do melhor. Utilizou-se dados pertencentes aos bancos de dados no site do Departamento de Informática do SUS (DATASUS), no período de 2017 a 2021, num total de 60 observações. Utilizou-se o software *Statistical Package for the Social Sciences (SPSS)* para as execuções dos modelos ARIMA e RNA_MLP. Como resultado, foi confirmado o desempenho superior do modelo híbrido ARIMA-RNA quando comparado aos métodos ARIMA e RNA_MLP, tratados individualmente, confirmando assim sua aplicabilidade ao objetivo, pois foi o método híbrido que produziu o menor erro, de 2,20%, em

detrimento dos modelos ARIMA e RNA_MLP, com erros de 11,05% e 6,55%, respectivamente.

Palavras-chave: Centro-Oeste brasileiro; Gestão de custos; Internações hospitalares; Previsão de custos; Sistema único de saúde.

Abstract

It is extremely important for managers of Brazilian public health institutions to use computational tools that allow the estimation of their costs in order to assist them in decision making. This importance becomes more relevant when it comes to Brazilian public health institutions, which need to keep monthly expenditures within the limited transfer of funds from the Unified Health System (SUS). Therefore, this study proposes the use of the ARIMA-RNA hybrid model as a technique and method for forecasting the total costs of hospitalizations in public institutions in the Brazilian Midwest, comparing it with the ARIMA and RNA_MLP models, treated separately, for the choice of the best. Data belonging to the databases on the website of the Department of Informatics of the SUS (DATASUS) were used, from 2017 to 2021, in a total of 60 observations. The Statistical Package for the Social Sciences (SPSS) software was used to run the ARIMA and RNA_MLP models. As a result, the superior performance of the ARIMA-RNA hybrid model was confirmed when compared to the ARIMA and RNA_MLP methods, treated individually, thus confirming its applicability to the objective, as it was the hybrid method that produced the lowest error, 2.20%, in detriment of the ARIMA and RNA_MLP models, with errors of 11.05% and 6.55%, respectively.

Keywords: Brazilian midwest; Cost management; Hospital admissions; Cost forecast; Unique health system.

Resumen

Es de suma importancia que los gestores de las instituciones públicas de salud brasileñas utilicen herramientas computacionales que permitan la estimación de sus costos para auxiliarlos en la toma de decisiones. Esta importancia se vuelve más relevante cuando se trata de instituciones de salud pública brasileñas, que necesitan mantener los gastos mensuales dentro de la limitada transferencia de fondos del Sistema Único de Salud (SUS). Sendo assim, este estudo propõe o uso do modelo híbrido ARIMA-RNA como técnica e método de previsão dos custos totais de internações em instituições públicas no Centro-Oeste brasileiro, comparando-o com os modelos ARIMA e RNA_MLP, tratados separadamente, para a escolha de lo mejor. Se utilizaron datos pertenecientes a las bases de datos del sitio web del Departamento de Informática del SUS (DATASUS), de 2017 a 2021, en un total de 60 observaciones. Se utilizó el software Statistical Package for the Social Sciences (SPSS) para ejecutar los modelos ARIMA y RNA_MLP. Como resultado, se confirmó el desempeño superior del modelo híbrido ARIMA-RNA al compararlo con los métodos ARIMA y RNA_MLP, tratados individualmente, confirmando así su aplicabilidad al objetivo, ya que fue el método híbrido que produjo el menor error, 2,20%, en detrimento de los modelos ARIMA y RNA_MLP, con errores del 11,05% y 6,55%, respectivamente.

Palabras clave: Medio Oeste brasileño; Gestión de costos; Hospitalizaciones; Previsión de costos; Sistema único de salud.

1. Introdução

Em todo setor da economia a busca pelo menor custo de funcionamento nas organizações, sem afetar a qualidade e a funcionalidade dos serviços é necessário, principalmente em instituições públicas ligadas à saúde, e que possuem limitação de recursos financeiros e, por isso, necessitam do uso constante de ferramentas econômicas que as auxiliem no gerenciamento eficiente dos seus gastos (Souza et al., 2013).

Fazer previsões futuras mensais sobre despesas com a saúde custeadas pelo SUS, em uma determinada região, auxilia os gestores do Órgão nas tomadas de decisões sobre o provisionamento de gastos, otimizando o seu planejamento. Existem modelos alguns matemáticos que possuem a capacidade de estabelecer relações entre diversas variáveis e que permitem fazer previsões ao longo do tempo com bastante eficiência. Um dos modelos mais famosos utilizados para previsão é o modelo denominado Auto-Regressive Integrated Moving Average (ARIMA), que utiliza dados passados para prever o futuro, baseado em autocorrelação e médias móveis (Box & Jenkins, 1976). Um segundo modelo, também bastante conhecido e utilizado em previsões é o modelo de Rede Neural Artificial (RNA), que é modelo computacional inspirado nos neurônios biológicos do sistema nervoso de seres vivos inteligentes, e que possuem a capacidade de aprendizagem e manutenção do conhecimento adquirido, baseado em informações recebidas na forma de exemplos (Souza et al., 2022; Carneiro Junior & Souza., 2022).

Segundo Babu e Reddy (2014) e Riachi et al. (2013), existe um modelo de previsão mais recente na literatura, ainda pouco abordado pelos estudiosos da área, mas que vem alcançando resultados muito interessantes e promissores, que é o modelo, resultado da integração dos modelos ARIMA e RNA, denominado de modelo Híbrido ARIMA_RNA para a previsão, cujos

resultados, em geral, são melhores do que os modelos ARIMA e RNA, separadamente. Daí, a necessidade de se explorar mais esse modelo, comparando o seu desempenho e acurácia com os seus progenitores. O presente estudo pretende responder a seguinte questão de pesquisa: será que o modelo Híbrido ARIMA-RNA, para previsões, tem desempenho superior aos modelos ARIMA e RNA tratados separadamente?

Desse modo, este estudo tem como objetivo avaliar o desempenho e a acurácia dos modelos ARIMA, RNA e Híbrido ARIMA-RNA na previsão de custos totais de internações hospitalares, custeados pelo SUS, na região Centro-Oeste do Brasil, para orientação às tomadas de decisões pelos gestores desse Órgão. A importância deste estudo é justificada pela necessidade da evidência de resultados de previsões futuras de custos totais de internações hospitalares na região Centro-Oeste do Brasil, para que as autoridades competentes possam executar políticas públicas no sentido de melhorias das condições de vida da população da região. Também, a relevância está na importância das políticas de desenvolvimento do governo e da integração nacional, que se faz necessário analisar a eficácia da aplicação dos recursos do SUS, minorando as desigualdades regionais do país.

2. Metodologia

2.1 Área e objeto de Estudo

Esta pesquisa teve como área de estudo a região Centro-Oeste do Brasil, formada pelos estados de Goiás, Mato Grosso, Mato Grosso do Sul e Distrito Federal (Figura 1). Além de fazer limite com todas as outras regiões geográficas do Brasil, o Centro-Oeste faz fronteira com a Bolívia e o Paraguai. Segundo o IBGE (2022), a região tem cerca de 16,09 milhões de habitantes, uma extensão territorial de 1,612 milhões de quilômetros quadrados e com a média de R\$ 44.486,34 do PIB por habitante. As principais atividades econômicas da região são a prestação de serviços, o comércio e a agropecuária.

Figura 1 - Mapa do Brasil, com destaque para a região Centro-Oeste, em 2022.



Fonte: Região Centro-Oeste (2022).

O objeto desta pesquisa são os recursos financeiros mensais aplicados pelo SUS na região Centro-Oeste, relativos às

internações hospitalares totais.

2.2 Variáveis e tipo de pesquisa

As variáveis utilizadas nesta pesquisa para a construção dos modelos ARIMA, RNA e Híbrido (ARIMA-RNA) foram: o mês como variável independente e, como variável dependente, os custos totais mensais das internações hospitalares demandadas pelo SUS na região Centro-Oeste, no período de 2017 a 2021.

Este estudo pode ser classificado como descritivo-exploratória, pois teve como finalidade utilizar os modelos de ARIMA, RNA e Híbrido (ARIMA-RNA) para prever anualmente os custos das internações hospitalares custeadas pelo SUS na região Centro-Oeste do Brasil, nos cinco primeiros meses de 2022. Para o desenvolvimento desta pesquisa, a metodologia foi dividida em duas etapas: a primeira etapa, caracterizada como uma pesquisa bibliográfica que, de acordo com Gil (2010), é uma atividade importante para identificar, conhecer e acompanhar o desenvolvimento da pesquisas em determinadas áreas do conhecimento humano.

Pelo uso da pesquisa bibliográfica procura-se explicar um problema a partir de referências teóricas já publicadas. Nessa fase, nesta pesquisa serão abordados os aspectos relacionados às práticas de predição dos custos no ambiente hospitalar e, em seguida, na segunda etapa será feito um estudo mais detalhado dos modelos de previsão a ser investigadas neste estudo (ARIMA, RNA e Híbrido ARIMA-RNA).

2.3 Coleta de Dados

Esses dados foram obtidos no site do Departamento de Informática do SUS (DATASUS) (DATASUS, 2022). Essa série de 60 observações de custos foi deflacionada no período de 2017 a 2021, utilizando a série de índices do Índice de Preços ao Consumidor Amplo (IPCA) (IBGE, 2022).

2.4 Previsão pelo Modelo ARIMA

A metodologia de Box e Jenkins (1976) segue algumas etapas para a formulação do modelo matemático e determinação dos parâmetros. São descritas a seguir:

- Etapa 1: identificação de modelos candidatos que melhor represente os comportamentos dos dados;
- Etapa 2: definição dos parâmetros (p , d , q) do modelo, com base na Função de Autocorrelação (FAC) e Função de Autocorrelação parcial (FACP);
- Etapa 3: verificação e validação do modelo – avaliar o modelo quanto ao aspecto de estabilidade (raízes unitárias) e validação dos coeficientes (teste estatístico - valor p), parcimônia, resíduos na forma de ruído branco e homocedasticidade;
- Etapa 4: inserção dos dados no modelo proposto.

2.5 Previsão pelo Modelo RNA

Para responder a questão de pesquisa proposta e, conseqüentemente, atingir os objetivos, este estudo construiu um modelo de RNA com o auxílio do *software Statistical Package for the Social Sciences* (Laureano & Botelho, 2022). A variável independente foi o mês, no período de 2017 a 2021 e, como variável dependente, os custos mensais das internações hospitalares demandados pelo SUS na região, no período considerado. O quadro 1 apresenta as informações sobre as variáveis independente, dependente e predita da RNA dos custos mensais das internações hospitalares demandados pelo SUS, de 2017 a 2021.

Quadro 1 - Variáveis independente e dependente dos custos mensais das internações hospitalares demandados pelo SUS, de 2017 a 2021.

Variável independente	Variável dependente	Variável predita
Mês	Custos mensais das internações hospitalares demandados pelo SUS	Custos mensais das internações hospitalares demandados pelo SUS

Fonte: Autores (2022).

Os percentuais de dados da série utilizados para treinamento e para teste foram definidas e otimizadas pelo próprio software. Por fim, a camada de saída também utilizou o método de reescalonamento padronizado, a função de ativação foi do tipo identidade, que usa argumentos com valores reais e retorna-os inalterados. Essa função é utilizada para variáveis dependentes numérica. O ajuste e o desempenho do um modelo de previsão foi dado pelo Erro Percentual Médio Absoluto (MAPE), equação (2).

2.6 Previsão pelo Modelo Híbrido ARIMA-RNA

Já, na fase de desenvolvimento do modelo híbrido, o mesmo segue procedimentos adotados por Rossi et al. (2013), de modo que, obtidas as previsões individuais para cada modelo ARIMA e RNA, procedeu-se a aplicação da equação (1) para o cálculo do modelo Híbrido ARIMA_RNA.

Para a comparação dos resultados do modelo híbrido em relação aos modelos de previsão individuais ARIMA(p, d, q) e RNA, foram calculados e comparados os erros das previsões tanto do modelo híbrido quanto dos modelos individuais das previsões, equação (2).

2.7 Tópicos sobre modelos de gestão de custos da saúde

Existem muitos estudos sobre a gestão de custos na saúde, mas poucos deles se preocupam com a previsão a médio e longo prazos de gastos na saúde, como no artigo de Cardoso et al. (2020), cujo objetivo era o de apresentar como a gestão de custo hospitalar, por meio do método de custeio por absorção e por centros de custos, realiza a apuração dos custos em um hospital de grande porte na Zona da Mata mineira. Para alcançar esse objetivo foi realizada uma pesquisa descritiva e qualitativa, adotando a ferramenta de estudo de caso como forma de observar as práticas de gestão de custos adotadas, além da análise documental e observação direta no ambiente estudado. A partir da pesquisa, os autores afirmaram que foi possível identificar os procedimentos de apuração de custos, e concluir que a empresa estudada apresentava um sistema de custo eficiente e bem estruturado, auxiliando no alcance dos objetivos, tomada de decisão e na administração dos recursos financeiros.

Já, para Souza et al. (2013), que afirmavam que a disponibilidade de informações relacionadas ao custo auxilia na aplicação e no controle dos recursos reconhecidamente escassos, principalmente em hospitais prestadores de serviços ao Sistema Único de Saúde (SUS), de modo a possibilitar a compreensão e o eficiente gerenciamento dos custos. Sabe-se que o SUS financia serviços de atenção hospitalar e ambulatorial em todo o país, além de exercer funções de saúde pública típicas do estado, tais como vigilância sanitária e epidemiológica, e que o SUS deve assistir a toda a população brasileira de forma universal, igualitária e hierarquizada, segundo a Constituição Brasileira (CONASS, 2007).

Segundo Matos et al. (2002), em muitas unidades hospitalares a geração de resultados está intimamente relacionada à liberação de verbas por parte das entidades governamentais para o aprimoramento e aquisição de novas tecnologias, de modo que, para as organizações hospitalares as informações de custos compreendem um insumo indispensável ao alcance de padrões de gestão mais seguros.

O uso de regressão linear fez parte dos estudos de vários autores, como de Marandi e Khan (2015) e Smith et al. (2015),

já, Freishman e Cohen (2010), fizeram uso da regressão logística como método de previsão de custos. Cao et al. (2012) realizaram a previsão da taxa de inflação dos custos médicos a partir dos modelos ARIMA e de RNA, onde verificou-se uma substancial melhora do desempenho do modelo RNA se comparado ao primeiro.

Não só na previsão de custos da saúde, vários autores tem aplicado essa tecnologia na previsão de outros custos, como Silva et al. (2019), em seu artigo sobre o modelo Híbrido ARIMA-RNA, sobre na previsão do custo da cesta básica na cidade de Ilhéus, afirmaram que técnicas de modelagem computacional têm sido extensivamente aplicadas na análise e previsão de series temporais de dados socioeconômicos. Os modelos estatísticos e os modelos baseados em redes neurais oferecem resultados satisfatórios na previsão de series temporais.

Entretanto, diversos autores destacam que o uso de modelos híbridos, que combinem ambas as abordagens, devem gerar previsões de maior qualidade. Segundo Rosa et al. (2016), a construção do modelo híbrido envolve selecionar o modelo ARIMA apropriado e a estimação de seus parâmetros através da análise das funções de correlação e, em relação a RNA deve-se selecionar a topologia da rede e calcular os pesos sinápticos de cada neurônio mediante um algoritmo de treinamento. O modelo híbrido resultante é utilizado para gerar previsões em curto e médio prazo, avaliando os resultados através de medidas estatísticas de acurácia.

2.8 Tópicos sobre a metodologia do modelo Box-Jenkins: modelos ARIMA

Difundida pela metodologia proposta Box e Jenkins (1976), os modelos ARIMA (*Auto-Regressive Integrated Moving-Average*) geram previsões através de informações contidas na própria série cronológica. Ainda, segundo Box e Jenkins (1976) e Souza et al. (2022), a identificação do modelo ARIMA é a fase mais crítica do processo, pois implica no ajuste dos dados que consiste em determinar os valores de p, d, q do modelo ARIMA(p, d, q), em que (p) é o parâmetro autorregressivo, que consiste no número de termos do modelo que descreve a dependência entre observações sucessivas; (d) é o parâmetro de diferenciações, que consiste em avaliar o aspecto estacionário da série e em caso negativo realiza processos de diferenciação até alcançar a estacionariedade dos dados e; (q) é o parâmetro das médias móveis, que consiste no número de termos para o cálculo das médias aritméticas, que se baseia no impacto dos dados mais recentes da série (Monsueto, 2014).

Como o modelo ARIMA está ligado aos conceitos de autocorrelação e autocorrelação parcial, julgou-se interessante, no próximo parágrafo colocar as suas conceituações. A autocorrelação é caracterizada como uma observação em um determinado instante de uma série de valores está relacionada às observações passadas de diversas ordens, denominadas de lags (Souza et al., 2022).

Uma autocorrelação de primeira ordem caracteriza séries onde uma observação está correlacionada com a observação imediatamente anterior. A autocorrelação de segunda ordem está correlacionada com as observações a 2 unidades de tempo no passado e, assim, sucessivamente. A identificação da autocorrelação é feita através da Função de Autocorrelação (FAC), discutida mais adiante. A autocorrelação parcial é a correlação entre as observações, em uma série temporal, que não é contabilizada por todos os intervalos mais curtos entre essas observações (Moretin & Tolo, 2006).

O modelo ARIMA foi desenvolvido na década de 1970, conhecido como modelo de Box e Jenkins, e consiste em ajustar modelos auto-regressivos integrados de médias móveis, ARIMA(p, d, q), a um conjunto de dados, (onde p é o número de parâmetros auto-regressivos, d é o número de diferenciações da série para torná-la estacionária e q é o número de parâmetros de médias móveis) (Moretin & Tolo, 2006; Box & Jenkins, 1976).

As séries estacionárias podem ser identificadas por três modelos básicos, sendo denominados de auto-regressivos AR(p), média móvel MA(q), e média móvel auto-regressivo, ARMA(p, q), que ao se combinarem em adição à diferenciação, tornam-se o modelo ARIMA(p, d, q), onde ocorre então a integração e o procedimento de diferenciação (d).

Segundo Medeiros et al. (2006), a aplicação do modelo ARIMA(p, d, q) deve ser precedido de três passos:

I – Identificação da estacionaridade: se a série não for estacionária, ela deve ser diferenciada d vezes até atingir a condição de estacionariedade. Segundo Fracaro (2018), as séries temporais na sua maioria são não estacionárias, sendo necessária a aplicação de uma transformação nas séries temporais.

II – Estimação e teste: como o valor de d já foi obtido no passo I, obtém-se intuitivamente os valores apropriados para os parâmetros p e q do modelo ARIMA, usando-se as representações gráficas da Função de Autocorrelação (FAC) e Função de Autocorrelação Parcial (FACP) contra o tamanho da defasagem. A FAC é utilizada para verificar como as defasagens da série podem impactar seu valor atual. (Verificar se x_{t-k} está correlacionado com x_t). A FACP é utilizada para verificar a relação entre lags diferentes sem influência dos lags intermediários (Verificar se x_{t-k} está puramente correlacionado com x_t) (Morettin & Tolo, 2006).

Alternativamente, a estimação dos parâmetros do modelo pode ser feita por meio de mínimos quadrados ou pelo método de estimativa não-linear. O modelo estimado deve ajustar bem aos dados se os resíduos do modelo são ruídos brancos. Caso sejam, aceita-se o modelo. Caso contrário, o processo deve ser recomeçado a fim de se identificar outro modelo (Morettin & toloi, 2006).

III – Previsão: o modelo obtido dos passos anteriores é usado para fazer previsões. Observe que a previsão pode não ser tão precisa, pois, a modelagem matemática é complexa e idealizada para permitir a inclusão de incertezas no modelo (Medeiros et al., 2006).

2.9 Tópicos sobre a metodologia de Redes Neurais Artificiais - RNA

As RNA são modelos computacionais, inspirados nos neurônios biológicos do sistema nervoso de seres vivos inteligente, e que possuem a capacidade de aprendizagem e manutenção do conhecimento adquirido, baseado em informações recebidas, na forma de exemplos do fenômeno em tela. As RNA são compostas por neurônios artificiais que são interligados por um grande número de interconexões afetadas de pesos sinápticos (Freeman & Skapura, 1991; Haykin, 2001; Kovács, 2006).

De acordo com Braga et al. (2012), as principais características das RNA são: i) organização de dados; ii) adaptação do modelo por experiência; iii) capacidade de aprendizado; iv) armazenamento distribuído; v) tolerância a falhas; vi) habilidade de generalização; vii) controle e otimização de sistemas; viii) processamento de sinais e predição. Essas características das RNA conduzem à busca por processos que possam realizar a predição de fenômenos biológicos como a dos índices zootécnicos, que geram dados satisfatórios próximos dos valores reais.

O processo de funcionamento das RNA é composto basicamente pelo tripé: uma arquitetura, uma topologia e um treinamento. A arquitetura define a forma como os neurônios estão dispostos, a topologia define as diferentes formas de composições estruturais assumidas pela rede e o treinamento está associado ao algoritmo de aprendizagem, ou seja, consiste no conjunto de passos ordenados visando os ajustes dos pesos, sintonizando as respostas de saída da rede próximas dos valores desejados (Braga et al., 2012).

Segundo Haykin (2001), em 1950 foi criado o primeiro modelo de RNA que consistia em uma rede de múltiplos neurônios artificiais distribuídos em três camadas, denominado *perceptron* ou discriminador linear. Os *perceptrons* eram dispostos em camadas de entrada e de saída, com os pesos das ligações adaptados para alcançar a eficácia sináptica. Um *perceptron* pode aprender conceitos através de exemplos e responder quando um novo exemplo é apresentado, com 1, se é verdade, ou com 0 se ele é falso, com base nos exemplos apresentados inicialmente. A Figura 1 mostra a estrutura de uma RNA *perceptron*.

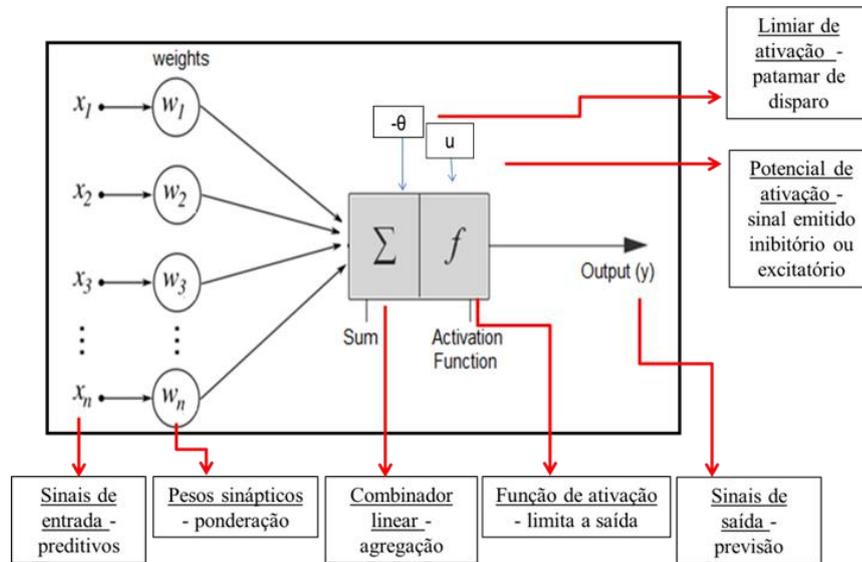
As RNA_MLP pertencem à classe de arquitetura *feedforward* (alimentação à frente), e são constituídas de uma camada de entrada de neurônios, uma ou mais camadas ocultas (ou intermediárias) e uma camada de saída. O algoritmo de aprendizado utilizado no treinamento supervisionado da rede MLP é o *backpropagation* ou algoritmo de retropropagação de erros, baseado na regra Delta generalizada (Gomes et al., 2014). As redes MLP são caracterizadas por conter pelo menos uma camada intermediária

de neurônios, pelas elevadas possibilidades de aplicação e são consideradas versáteis pela abrangência no potencial de aproximação universal de funções, reconhecimento de padrões, identificação e controle de processos, previsão de séries temporais e otimização de sistemas (Braga et al., 2012).

A RNA_MLP possui uma estrutura composta basicamente por três camadas ou mais camadas, sendo, respectivamente, de uma camada de entrada, uma ou mais camadas intermediárias ou ocultas e uma camada de saída. Na camada de entrada são inseridos os parâmetros das variáveis que serão predictoras no processo, ou seja, as variáveis independentes, na camada intermediária ocorrem o processamento dos neurônios e ajustes das funções e pesos sinápticos e na camada de saída estão os parâmetros a serem previstos, dados como variáveis dependentes. Cada um dos neurônios da camada de entrada se conecta a todos os outros neurônios da camada intermediária e estes por sua vez aos neurônios da camada de saída e dependendo da estimulação gerada pela soma ponderada do produto dos neurônios de entrada por seus pesos sinápticos, a função de transferência e emissão dos sinais de saída, serão diferentes (Kovács, 2006; Braga et al., 2012).

Os sinais de entrada $\{x_1, x_2, \dots, x_n\}$ são os sinais inseridos para as variáveis da aplicação específica. Esses sinais são normalizados na rede visando incrementar a eficiência computacional dos algoritmos de aprendizagem; Pesos sinápticos $\{w_1, w_2, \dots, w_n\}$, que são os valores que servem para a ponderação de cada variável x_i de entrada da rede ($w_i \times x_i$), e que permite quantificar a relevância em relação à funcionalidade de cada neurônio (Kovács, 2006; Braga et al., 2012). A Figura 2 mostra a estrutura de uma RNA_MLP.

Figura 2 - Arquitetura de uma RNA_MLP.



Fonte: Adaptado de Silva (2016).

As variáveis da camada de entrada foram analisadas de forma padronizada, ou seja, de cada variável subtrai-se a média e divide o resultado pelo desvio-padrão. A quantidade de observações utilizadas para treinamento e para teste foram definidas e otimizadas pelo próprio *software*. A função de ativação das camadas ocultas foi do tipo tangente hiperbólica, sendo que seus argumentos são valores reais compreendidos entre os valores -1 e 1. A camada de saída utilizou o método de reescalonamento padronizado, a função de ativação foi do tipo identidade que utiliza argumentos expressos em valores reais e os retorna de forma inalterada, específica para variáveis numéricas (Braga et al., 2012).

Dependendo do estímulo gerado pela soma ponderada das entradas pelos pesos, os neurônios ativam a função de transferência, que emite uma resposta para a próxima camada. A camada de saída, dada por y_i , recebe os estímulos da camada

intermediária e gera um padrão de resposta. Portanto, as camadas intermediárias funcionam como extratoras de características dos padrões de entrada, codificadas pelos pesos e permitem que a rede represente o problema com os sinais de saída mais detalhados. Para iniciar esse processo, os pesos iniciais são escolhidos aleatoriamente; em seguida inicia-se o mento ou aprendizagem. Existem duas abordagens de mento principais: supervisionado e não supervisionado. O mento supervisionado exige o fornecimento da saída desejada para a rede, seja por modo manual de “classificação” do desempenho da rede, seja fornecendo os resultados desejados com as entradas (Haykin, 2001).

Para que a RNA apresente resultados de saída é necessário aplicar o processo de aprendizagem da rede, cuja resposta é resultado do processo obtido do mento dessa rede através de um algoritmo. O algoritmo de aprendizagem adotado para a RNA_MLP foi o de retropropagação de erros, ou também denominado de *backpropagation*, que trata de uma técnica de mento supervisionada e realiza o ajuste dos pesos através do cálculo da diferença entre o valor previsto e o valor observado.

O algoritmo *backpropagation* é um algoritmo supervisionado que utiliza pares (entradas, saída desejada) para, por meio de um mecanismo de correção de erros, ajustar os pesos da rede. O treinamento ocorre em duas fases, em que cada fase percorre a rede em um sentido. Estas duas fases são chamadas de fase *forward* e fase *backward*. A fase *forward* é utilizada para definir a saída da rede para um dado padrão de entradas, ao mesmo tempo em que, atualiza os pesos de suas conexões. Um conjunto de elementos da amostra de treinamento são inseridos nas entradas e propagados camada a camada até a reprodução das respectivas saídas, os pesos sinápticos e limiares dos neurônios permanecem inalterados durante a execução desse processo. A fase *backward* é baseada na propagação reversa em que os ajustes dos pesos sinápticos e limiares de todos os neurônios ocorrem no decorrer da fase (Braga et al., 2012).

2.10 Modelo Híbrido ARIMA-RNA

Para a determinação de previsão utilizando o modelo híbrido ARIMA-RNA adotou-se a metodologia de Rossi et al. (2013) que, a partir das previsões individuais de cada modelo, obtém o modelo híbrido pelo somatório da série, previsão do modelo ARIMA(p, d, q), com o erro da previsão das RNA, conforme equação (1).

$$MH = Prev(ARIMA(p, d, q)) + Erro(Prev(RNA)) \quad (1)$$

Em que:

- *MH* = Modelo híbrido;
- *Prev(ARIMA(p, d, q))* = Série prevista pelo ARIMA;
- *Erro (Prev(RNA_MLP))* = Erro obtido na presvisão pela RNA.

Para a comparação dos resultados do modelo híbrido em relação aos modelos de previsão individuais ARIMAS (p, d, q) e RNA, foram calculados e comparados os erros das previsões tanto do modelo híbrido quanto dos modelos individuais das previsões. Esses erros consistem em mensurar o distanciamento dos valores previstos pelos modelos em relação aos dados reais observados que, segundo Montgomery et al. (2008), seria a avaliação da qualidade do ajuste (acurácia), e do desempenho de um modelo de previsão, dado pelo Erro Percentual Médio Absoluto (MAPE), dado pela equação (2).

$$MAPE = \frac{1}{R_t} \sum_{t=1}^N |R_t - P_t| \quad (\%) \quad (2)$$

Onde N é o número de períodos da série temporal, R_t é o valor real observado da variável e P_t é o valor previsto da variável. Quanto menor for essa medida, melhor será o desempenho do modelo de previsão tendo em vista que essa medida avalia o quanto o modelo está errando (Riahi et al., 2013).

3. Resultados e Discussão

O Quadro 2 apresenta os custos totais de internações hospitalares custeados pelo SUS na região Centro-Oeste do Brasil, no período de janeiro de 2017 a dezembro de 2021, deflacionados pelo IPCA, referidos a maio de 2022,

Quadro 2 - Custos totais de internações hospitalares custeados pelo SUS na região Centro-Oeste do Brasil, no período de janeiro de 2017 a dezembro de 2021, deflacionados pelo IPCA, referidos a maio de 2022.

Período	Custos SUS	Período	Custos SUS	Período	Custos SUS
jan/17	107.295.622,76	set/18	98.526.952,41	mai/20	91.085.245,59
fev/17	105.330.074,87	out/18	95.556.424,43	jun/20	95.465.609,45
mar/17	112.545.144,74	nov/18	91.119.385,87	jul/20	108.328.711,11
abr/17	109.294.410,85	dez/18	88.676.261,09	ago/20	120.074.712,84
mai/17	110.040.204,58	jan/19	96.421.432,33	set/20	111.679.154,50
jun/17	103.903.479,10	fev/19	95.074.810,37	out/20	114.562.393,50
jul/17	105.396.757,32	mar/19	102.869.741,26	nov/20	111.746.348,22
ago/17	107.647.889,96	abr/19	99.567.287,89	dez/20	113.087.396,95
set/17	108.798.861,29	mai/19	103.142.814,42	jan/21	116.355.136,05
out/17	103.288.615,73	jun/19	103.059.975,12	fev/21	115.912.744,62
nov/17	103.369.747,41	jul/19	105.918.698,76	mar/21	145.596.974,04
dez/17	98.449.313,63	ago/19	106.252.646,81	abr/21	166.413.987,03
jan/18	100.302.361,51	set/19	99.113.188,65	mai/21	158.221.304,55
fev/18	96.800.607,69	out/19	98.546.835,64	jun/21	168.227.734,22
mar/18	106.720.280,15	nov/19	96.964.912,10	jul/21	177.949.265,30
abr/18	101.966.814,76	dez/19	94.527.461,99	ago/21	179.310.311,34
mai/18	101.930.903,89	jan/20	73.516.399,54	set/21	161.053.991,48
jun/18	105.164.710,87	fev/20	98.454.875,20	out/21	138.710.966,30
jul/18	105.194.378,70	mar/20	99.447.959,22	nov/21	116.192.356,00
ago/18	101.635.528,39	abr/20	88.713.016,50	dez/21	111.154.581,78

Fonte: Adaptada de DATASUS (2022).

Os custos apresentados no Quadro 2, deflacionados pelo IPCA, referidos a maio de 2022, são aqueles relativos a todos os procedimentos custeados pelo SUS na região Centro-Oeste do Brasil tais como: Clínicas Cirúrgicas, Obstetrícia, Clínica Médica, Cuidados Prolongados (Crônicos), Psiquiatria, Pneumologia Sanitária (Tisiologia), Pediatria, Reabilitação, Clínica Cirúrgica (Hospital-Dia), Aids (Hospital-Dia), Fibrose Cística (hospital-dia), Intercorrência Pós-transplante (hospital-dia), Geriatria (hospital-dia), Saúde Mental (hospital-dia), Saúde Mental (Clínico) e Não Discriminado.

O próximo passo é aplicar os três modelos construídos em um mesmo banco de dados sobre custos hospitalares custeados pelo SUS na região Centro-Oeste brasileira e comparar os seus desempenhos relativos dos seus valores preditos com os valores observados, calculando os erros cometidos. Segundo Sun et al. (2009) e Jones et al. (2008), esses desempenhos podem ser feitos através dos cálculos dos erros percentuais médios absolutos (*Mean Absolute Percentual Error - MAPE*) que, quanto mais próximo de zero, melhor.

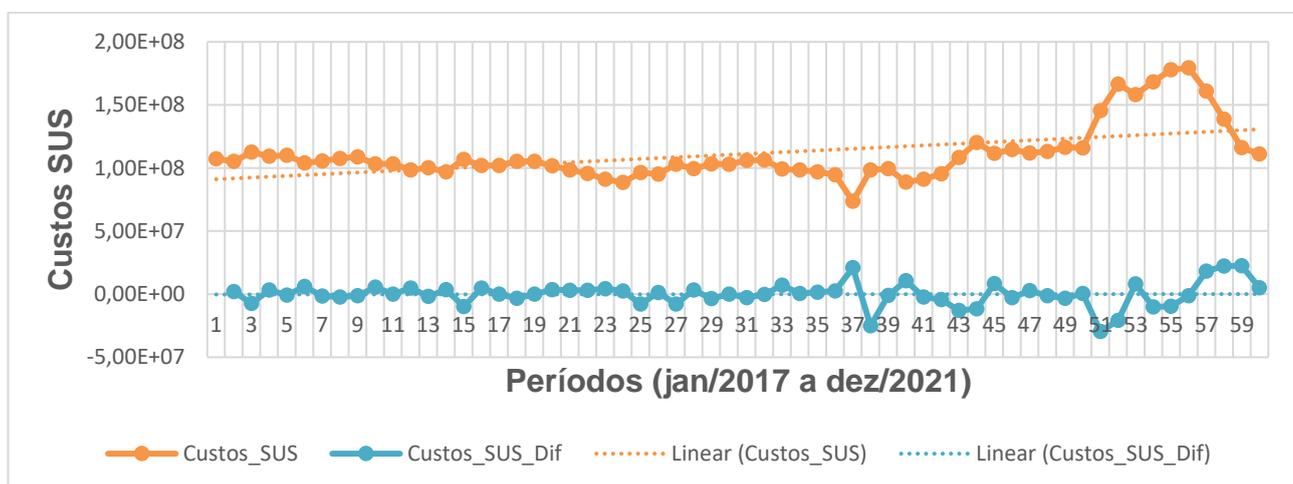
3.1 Previsão pelo Modelo Box-Jenkins (ARIMA)

Nesta primeira etapa, que envolve conceituação matemática mais robusta, em que se utilizou os procedimentos

metodológicos Box-Jenkins - ARIMA, para a predição dos custos de internações hospitalares da região Centro-Oeste, nos cinco primeiros meses de 2022, utilizando a série histórica desses custos, no período de 2017 a 2021, deflacionada pelo IPCA. Seguindo a metodologia, na primeira etapa foi construído um gráfico da sequência em que se verificou que a série não era estacionária. Neste caso realizou-se duas diferenciações ($d = 2$), resultando em uma série estacionária. A variável independente “mês”, que no período de 2017 a 2021, totalizou 60 meses, foi substituída por uma sequência numérica de 1 a 60, com a finalidade de simplificação dos cálculos no software SPSS.

A Figura 3 apresenta dois gráficos (verde) e (azul) da série de dados do problema, Período x Custos SUS, em que no gráfico (verde) está representada a série de dados observados dos custos de internações hospitalares da região Centro-Oeste, desembolsados pelo SUS no período de janeiro de 2017 a dezembro de 2021, deflacionada pelo IPCA do período e, no gráfico (azul) está representada a mesma sequência, diferenciada uma vez ($d = 2$).

Figura 3 - Séries temporais dos custos de internações demandadas pelo SUS na região Centro-Oeste do Brasil, de jan/2017 a dez/2021.

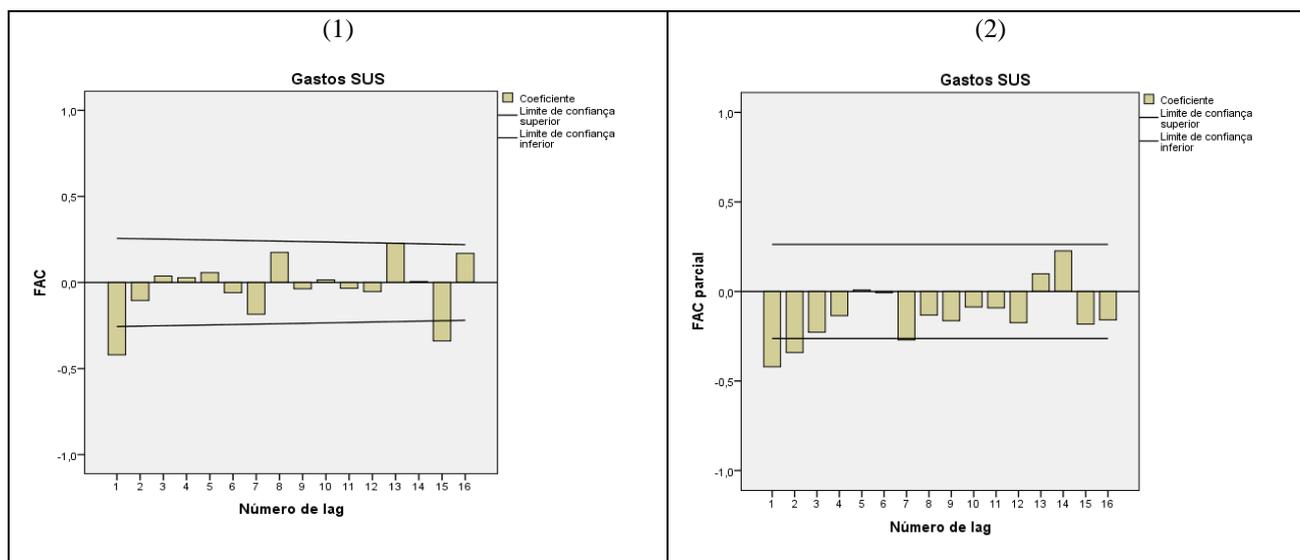


Fonte: Autores (2022).

Observe, da Figura 3, que o gráfico da sequência de custos do SUS (verde) apresenta uma tendência de crescimento (linha pontilhada verde), não sendo possível, teoricamente, fazer previsões confiáveis com essa sequência utilizando o modelo ARIMA. Já o gráfico da sequência de custos SUS (azul), diferenciada duas vezes resultou numa série estacionária (linha pontilhada azul), podendo ser usada para fazer previsões com o modelo ARIMA. Desse modo, no modelo ARIMA(p, d, q), o parâmetro d já se encontra determinado ($d = 2$).

Para a determinação dos parâmetros (p) e (q), analisou-se o FAC e FACP dos correlogramas da Figura 4 da série diferenciada. Foi constatado pela FAC que nos lags 1, 13 e 15 há presença de picos fora do intervalo de confiança (as duas linhas paralelas ao eixo das abscissas dos dois gráficos). Assim, se pode ter o MA(1), MA(13) e MA(15). Por outro lado, verificou-se que a FACP apresenta um picos significativos nos lags 1, 2 e 7, sugerindo a inclusão dos modelos AR(1), AR(2) e AR(7).

Figura 4 - Gráficos de correlações (FAC e FACP), utilizando 16 lags, sobre os Custos SUS, de 2017 a 2021.



Fonte: Autores (2022).

Após construídos todos os modelos possíveis, adotou-se o modelo ARIMA(1, 2, 1) para fazer previsões com a série de dados em estudo, pois, foi aquele que satisfaz todas as condições matemáticas do ARIMA, com menores erros. No próximo passo é realizado o diagnóstico de resíduos com o intuito de validar o modelo ARIMA acima proposto. Analisando os Correlogramas dos Resíduos de FAC e FACP, cuja hipótese nula H_0 é que: existem correlações entre os resíduos; observou-se que $\text{Valor}_p = 0$, portanto, muito significativo, rejeitando a hipótese nula H_0 , de modo que os resíduos apresentaram aspectos de ruídos brancos, de modo que o modelo é capaz de realizar uma boa estimação para o conjunto de dados do problema, apresentando $R^2 = 0,825$ indicando um bom ajuste do modelo e o valor de $\text{MAPE} = 5,989\%$ indica um erro pequeno em relação aos dados do problema. Já quanto à estatística de Ljung-Box, em que a hipótese nula H_0 afirma que: o modelo adotado não exhibe falha de ajuste, apresentou $\text{Valor}_p = 0,348 > 0,05$, não significativo, aceitando-se a hipótese nula H_0 de que não existem falhas de ajustes no modelo (Monsueto, 2014).

Desse modo, após essas análises chegou-se a conclusão que o modelo proposto ARIMA(1, 2, 1) é um modelo capaz de estimar os custos de internações no período considerado, isto é, de janeiro/2022 a maio/2022. A tabela 1 apresenta os dados de saída do SPSS para os valores da previsão dos custos de internações hospitalares pelo modelo ARIMA(1, 2, 1), de janeiro de 2022 a maio de 2022.

Tabela 1 - Valores da previsão do modelo ARIMA(1, 2, 1) dos custos de internações hospitalares da região Centro-Oeste do Brasil, de janeiro de 2022 a maio de 2022.

Modelo	Jan/2022 (R\$)	Fev/2022 (R\$)	Mar/2022 (R\$)	Abr2022 (R\$)	Mai/2022 (R\$)
ARIMA(1,2,1)	107.453.995,60	103.748.023,30	99.770.043,09	95.460.407,63	90.799.283,80

Fonte: Autores (2022).

3.2 Previsão do Modelo RNA_MLP

Utilizou-se na aplicação das RNA_MLP os mesmos dados utilizados no ARIMA, do quadro 1. As variáveis da camada de entrada foram analisadas de forma padronizada, a quantidade de observações utilizadas para treinamento e para teste foram definidas e otimizadas pelo próprio *software*, com a sugestão de que se usasse 70% do banco de dados para treinamento e 30% para

teste. A função de ativação das camadas ocultas foi do tipo tangente hiperbólica. A camada de saída utilizou o método de reescalonamento padronizado, a função de ativação foi do tipo identidade.

Para a previsão em RNA_MLP, diferentemente da previsão por meio do modelo ARIMA, não necessita da realização de testes estatísticos para validação de modelos, já que o método não desenvolve um modelo específico e a previsão é gerada a partir da rede treinada com os dados do período anterior à previsão. Após a execução do software relativo à RNA_MLP para previsão, o número de observações para o treinamento foi de 73,3% e para o teste de 26,7% e erro relativo de 6,20%. Na Tabela 2 estão os valores das previsões e do do MAPE, determinados pelo software SPSS utilizando RNA_MLP. A Tabela 2 apresenta os valores da previsão do modelo RNA_MLP dos custos de internações hospitalares da região Centro-Oeste do Brasil, de janeiro de 2022 a maio de 2022.

Tabela 2 - Valores da previsão do modelo RNA_MLP dos custos de internações hospitalares da região Centro-Oeste do Brasil, de janeiro de 2022 a maio de 2022.

Modelo	Jan/2022 (R\$)	Fev/2022 (R\$)	Mar/2022 (R\$)	Abr2022 (R\$)	Mai/2022 (R\$)
RNA_MLP	117.801.600,02	110.837.729,21	104.721.291,31	99.453.135,94	94.987.009,10

Fonte: Autores (2022).

3.3 Previsão pelo Modelo Híbrido – ARIMA_RNA

Com relação ao modelo Híbrido ARIMA_RNA para a previsão, utilizou-se a equação (1), substituindo-se na mesma os resultados já encontrados para os dois primeiros modelos, ARIMA e RNA_MLP, das Tabelas 1 e 2, respectivamente. Na tabela 3 estão os valores da previsão do modelo Híbrido ARIMA-RNA dos custos de internações hospitalares da região Centro-Oeste do Brasil, de janeiro de 2022 a maio de 2022..

Tabela 3 - Valores da previsão do modelo híbrido ARIMA-RNA dos custos de internações hospitalares da região Centro-Oeste do Brasil, de janeiro de 2022 a maio de 2022.

Modelo	Jan/2022 (R\$)	Fev/2022 (R\$)	Mar/2022 (R\$)	Abr2022 (R\$)	Mai/2022 (R\$)
Híbrido ARIMA_RNA	116.419.571,90	114.660.615,70	113.466.373,70	112.549.711,80	111.779.053,10

Fonte: Autores (2022).

4. Discussão

Na Tabela 4 estão os valores observados, os valores observados dos modelos ARIMA(1, 2, 1) e RNA_MLP, juntamente com os valores do modelo híbrido ARIMA_RNA, das previsões dos custos hospitalares custeados pelo SUS na região Centro-Oeste do Brasil, no período de janeiro de 2022 a maio de 2022, bem como, os erros médios absolutos percentuais (MAPE), determinados pela equação (2).

Tabela 3 - Valores observados e previstos pelos modelos ARIMA(1, 2, 1), RNA_MLP, Híbrido ARIMA_RNA e erros MAPE de cada um desses modelos, dos custos de internações hospitalares custeados pelo SUS na região Centro-Oeste, de jan/2022 a maio/2022.

Mês/Ano	Observado	ARIMA(1, 2,1)	RNA_MLP	Híbrido ARIMA_RNA
jan/2022	115.146.731,96	107.453.995,60	117.801.600,02	116.419.571,90
fev/2022	114.137.780,72	103.748.023,30	110.837.729,21	114.660.615,70
mar/2022	114.347.912,53	99.770.043,09	104.721.291,31	113.466.373,70
abr/2022	107.331.387,23	95.460.407,63	99.453.135,94	112.549.711,80
mai/2022	107.700.799,71	90.799.283,80	94.987.009,10	111.779.053,10
MAPE (%)	--	11,05	6,55	2,20

Fonte: Autores (2022).

Verificou-se, da Tabela 3, que todos os modelos apresentaram desempenhos satisfatórios para estimar os custos de internações hospitalares custeados pelo SUS na região Centro-Oeste do Brasil, no período de janeiro de 2017 a dezembro de 2022, visto que, os percentuais dos erros encontrados no MAPE foram pequenos, se comparados aos valores envolvidos. O resultado do modelo híbrido ARIMA_RNA foi o modelo que apresentou o melhor desempenho, pois foi o que teve o menor erro percentual entre os três modelos, que foi de 2,20%. Os resultados alcançados vão de encontro aos estudos de Rosa et al. (2016), que também obtiveram em seus estudos desempenho superior do modelo híbrido em relação aos modelos ARIMA e RNA_MLP.

5. Conclusão

O estudo desenvolvido alcançou plenamente a questão de pesquisa colocada, bem como, os objetivos propostos, pois os três modelos de previsão estudados foram aplicados em um mesmo banco de dados sobre custos hospitalares do SUS, de janeiro de 2017 a dezembro de 2021. As previsões de custos hospitalares foram realizadas pelos três modelos num horizonte de cinco meses, de janeiro de 2022 a maio de 2022, meses fora do banco de dados utilizado, e comparou-se seus desempenhos, com de cálculos dos erros cometidos. Concluiu-se que o melhor desempenho ficou com o modelo Híbrido ARIMA-RNA, com erro MAPE de 2,20%, seguido do modelo RNA_MLP, com 6,55% e, em último lugar, ficou o modelo ARIMA, com erro de 11,05%.

Pelo que se tem na literatura até o presente momento e o que foi obtido neste trabalho, aponta o modelo Híbrido ARIMA-RNA para previsão como o mais promissor para realizar previsões, pois tem a melhor precisão (acurácia), quando comparado com os modelos ARIMA e RNA_MLP, tratados separadamente.

Certamente, estudos futuros sobre o assunto deverão ser realizados com outros modelos de previsão não tratados neste estudo, baseados em modelos tradicionais ou modelos heurísticos, no sentido de melhorar os resultados até hoje alcançados, para que se possa fornecer aos tomadores de decisão melhores informações e previsões mais confiáveis, para que as suas decisões sejam as mais acertadas possível e os investimentos sejam melhor aproveitados.

Agradecimentos

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) pela concessão da Bolsa de Produtividade em Pesquisa. Processo n.º.: 304563/2019-6

Referências

Marandi, A. K., & Khan, D. A. (2015). An impact of linear regression models for improving the software quality with estimated cost. *Procedia Computer Science*, 54, 335-342.

- Babu, C. N., & Reddy, B. E. (2014). A moving-average filter based hybrid ARIMA–RNA model for forecasting timeseries data. *Journal Applied Soft Computing*, 23, 27–38.
- Box, G. E. P., & Jenkins, G. M. (1976). *Time series analysis: Forecasting and control*. Holden-Day: San Francisco, CA, p 85-95.
- Braga, A. P., Carvalho, A. P. L. F., & Ludermir, T. B. (2012). *Redes Neurais Artificiais: Teoria e Aplicações*. (2a ed.): LTC. p. 228.
- Cao, Q., Ewing, B. T., & Thompson, M. A. (2012). Forecasting medical cost inflation rates: A model comparison approach. *Decision Support Systems*, 53(1), 154-160.
- Cardoso, A. A. B., Souza, L. M., Reis, A. de O., & Palha, V. M. (2020). Gestão de custos em organizações hospitalares: sistemática por centro de custos. *Semina: Ciências Sociais e Humanas, Londrina*, 41(1), 123-138.
- Carneiro Junior, J. B. A., & Souza, C. C. Aplicação de redes neurais artificiais na previsão do produto interno bruto do Mato Grosso do Sul em função da produção de cana-de-açúcar, açúcar e etanol. *Revista Ibero-Americana de Ciências Ambientais (RICA)*. 10(5). 2020.
- CONASS. (2007). Para entender a gestão do SUS (Sistema Único de Saúde). Conselho Nacional de Secretários de Saúde. Coleção ProGestores. http://bvsm.saude.gov.br/bvs/publicacoes/colec_progestores_livro1.pdf.
- DATASUS – Sistema Único de Saúde. (2022). Internações Hospitalares do SUS – por local de internação – Brasil. <<http://tabnet.datasus.gov.br/cgi/deftohtm.exe?sih/cnv/sxuf.def>>.
- Fracaró, N. (2018). Estacionaridade das séries temporais do modelo matemático arimax de propulsores eletromecânicos. Universidade Regional do Noroeste do Estado do Rio Grande do Sul – UNIJUÍ.
- Freeman, J. A., & Skapura, D. M. (1991). *Neural Networks: Algorithms, Applications, and Programming Techniques*. (2ª ed.): CNS, 414p.
- Gil, A. C. (2010). *Como elaborar projetos de pesquisa*. (5a ed.), Atlas.
- Gomes, A. C. dos S., Robaina, A. D., Peiter, M. X., Soares, F. C., & Parizi, A. R. C. (2014). Modelo para estimativa da produtividade para a cultura da soja. (portuguese). *Model to estimate the yield for soybean. (English)*, 44(1), 43–49.
- Haykin, S. (2001). *Redes Neurais: Princípios e Práticas*. Bookman, (2a ed.), 900.
- IBGE – Instituto Brasileiro de Geografia e Estatística. (2022). IPCA – Índice de Preços ao Consumidor Amplo. <<https://www.ibge.gov.br/estatisticas/todos-os-produtos-estatisticas.html>>.
- Laureano, R. M. S., & Botelho, M. do. C. (2022). SPSS Statistics: Meu Manual de Consulta Rápida. <<https://static.fnac-static.com/multimedia/PT/pdf/9789726188865.pdf>>.
- Jones, S. S., Thomas, A., Evans, R. S., Welch, S. J., Haung, P. J., & Snow, G. L. (2008). Forecasting daily patient volumes in the emergency department. *Academic Emergency Medicine*.
- Kovács, Z. L. (2006). *Redes Neurais Artificiais: Fundamentos e Aplicações*. (4a ed.): Livraria da Física, p. 169.
- Matos, A. J. (2002). *Gestão de custos hospitalares: técnicas, análise e tomada de decisão*. São Paulo: Editora STS.
- Medeiros, A. L., Montevechi, J. A. B., Rezende, M. L., & Reis, R. P. (2006). Modelagem ARIMA na previsão do preço da arroba do boi gordo. In: XLIV Congresso da Sociedade Brasileira de Economia e Sociologia Rural. Fortaleza: SOBER, v. 1.
- Monsueto, S. E. (2014). *Curso de análise de séries temporais – modelo ARIMA material de apoio*. Faculdade de Administração – UFG.
- Montgomery, D. C., Jennings, C. L., & Kulahci, M. (2008). *Introduction to time series analysis and forecasting*. John Wiley & Sons. Inc.
- Morettin, P. A., & Toloi, C. M. (2006). *Análise de séries temporais*. (2a ed.) Edgard Blücher.
- REGIÃO CENTRO-OESTE. (2022). Estados da região Centro-Oeste. <https://www.todamateria.com.br/regiao-centro-oeste/>.
- Riahi, N., Hosseini-Motlagh, S., & Teimourpour, B. A. (2013). Three-phase Hybrid Times Series Modeling Framework for Improved Hospital Inventory Demand Forecast. *International Journal of Hospital Research*, 2(3), 133-142.
- Rosa, N. M., Chang Junior, J., & Mattos, C. A. (2016). Aplicação do método híbrido ARIMA-RNA para a predição dos custos de internação pelo sistema único de saúde na cidade de São Paulo. XXXVI Encontro Nacional de Engenharia de Produção. João Pessoa/PB, Brasil. De 03 a 06 de outubro de 2016.
- Rossi, D. J., Lotufo, A. P. D., & Lopes, M. L. M. (2013). Previsão da velocidade dos ventos por redes neurais artificiais e ARIMA de Box & Jenkins. *Anais do Congresso de Matemática Aplicada e Computacional – CMAC – Sudeste*.
- Schweiger, L., Younger, J., Ionides, E., & Desmond, J. (2007). Autoregression models can reliably forecast emergency department occupancy levels 12 hours in advance. *Acad. Emerg. Med.*
- Silva, I. N. (2016). *Redes Neurais Artificiais para Engenharia e Ciências Aplicadas: Fundamentos Teóricos e Aspectos Práticos*. Editora Artliber. P. 431.
- Silva, D. R., Dominguez, D. S., Ambrosio, P. E., & Iglesias, S. M. (2019). Método híbrido de redes neurais e modelo ARIMA na previsão do custo da cesta básica na cidade de Ilhéus. *Revista Mundi Engenharia, Tecnologia e Gestão. Paranaguá, PR*, 4(3), maio de 2019.
- Smith, J., Banks, H., Campbell, H., Douglas, A., Fletcher, E., Mccallum, A., Moger, T. A., Peltola, M., Sveréus, S., Sarah, W., Williams, L. J., & Forbes, J. (2015).

Parameter heterogeneity in breastcancer cost regressions – evidence from five European countries. *Health Econ.*, 24, 23-37.

Souza, A. A., Xavier, A. G., & Lima, L. C. M. (2013). Análise de Custos em Hospitais: Comparação entre os custos de procedimentos de urologia e os valores repassados pelo Sistema Único de Saúde. *ABCustos Associação Brasileira de Custos*, 7(1).

Souza, C. C., Carneiro Junior, J. B. A., Cristaldo, M. F. R., Castelão, R. A., Frainer, D. M., & Viganó, H. H. de G. (2022). Previsão de produção de cana-de-açúcar e seus derivados, através de ARIMA, no período de 2020 a 2025, na macrorregião Centro-Sul do Brasil. *Research, Society and Development*, 11(4).

Souza, C. C., Carneiro Junior, J. B. A., Cristaldo, M. F. R., Castelão, R. A., & Frainer, D. M. (2022). Aplicação de inteligência artificial na previsão de produções de açúcar e etanol, no período de 2020 até 2025, nas macrorregiões Centro-Sul e Norte-Nordeste do Brasil. *Revista Brasileira de Geografia Física* 15(05).

Sun, Y., Heng, B. H., Seow, Y. T., & Seow, E. (2009). Forecasting daily attendances at an emergency department to aid resource planning. *BMC Emergency Medicine*. Singapura.

Tandberg, D., & Qualls, C. (1994). Time series forecasts of emergency department patient volume, length of stay, and acuity. *RNA Emerg. Med.*, 23, 299-306.

Wang, J. (2012). On quantifying and forecasting emergency department overcrowding at Sunnybrook hospital using statistical analyses and artificial neural networks. Thesis of masters, Mechanical and Industrial Engineering. University of Toronto, Canada.