

Visão Futura: Previsão de Demanda de UTI para Doenças Respiratórias em Hospitais de São Paulo com Mapa Interativo de Leitos

Eduardo Furlani Rodrigues. Thiago Marangoni de Melo
Vinicius Perez dos Santos. Rooney Albuquerque Coelho (Orientador)

Pontifícia Universidade Católica de São Paulo (PUC-SP), CEP: 05014-901; ra00297677@pucsp.edu.br,
ra00297703@pucsp.edu.br, ra00297669@pucsp.edu.br, rracoelho@pucsp.br

Abstract: The article analyzes and predicts respiratory diseases in public and private hospitals in the city of São Paulo and adjacent regions. With the significant demand for hospital beds related to these diseases, the study proposes a predictive model to assist healthcare units in effectively preparing for population care. The methodology includes the collection and analysis of epidemiological data, as well as the application of time series analysis techniques. The results provide valuable insights for hospital management and public health policies, improving resource allocation and response to emerging respiratory health demands. The work also includes a map identifying hospitals with the highest number of available beds and their geographic proximity to areas with the highest incidence of respiratory diseases. This facilitates strategic decision-making by hospital managers and health authorities.

Keywords: Respiratory diseases; predictive models; resource allocation; hospital management; time series analysis.

Resumo: O artigo analisa e prevê doenças respiratórias em hospitais públicos e privados na cidade de São Paulo e regiões adjacentes. Com a demanda significativa por leitos hospitalares relacionada a essas doenças, o estudo propõe um modelo preditivo para auxiliar as unidades de saúde a se prepararem de forma eficaz para o atendimento à população. A metodologia inclui a coleta e análise de dados epidemiológicos, bem como a aplicação de técnicas de análise de séries temporais. Os resultados fornecem insights valiosos para a gestão hospitalar e políticas de saúde pública, melhorando a alocação de recursos e a resposta às demandas emergentes em saúde respiratória. O trabalho também inclui um mapa que identifica hospitais com maior número de leitos disponíveis e sua proximidade geográfica em relação às áreas com maior incidência de doenças respiratórias. Isso facilita a tomada de decisões estratégicas pelos gestores hospitalares e autoridades de saúde.

Palavras-chaves: Doenças respiratórias; modelos preditivos; alocação de recursos; gestão hospitalar; análise de séries temporais.

1. INTRODUÇÃO

As doenças respiratórias representam um desafio significativo para o sistema de saúde, especialmente em áreas urbanas densamente povoadas como São Paulo. De acordo com a Organização Mundial da Saúde (OMS, 2019), as doenças respiratórias são uma das principais causas de morbidade e mortalidade em todo o mundo. Com a crescente urbanização e poluição do ar, há um aumento na incidência dessas doenças, resultando em uma demanda cada vez maior por leitos hospitalares (GBD, 2019).

Para lidar com essa demanda crescente, é crucial desenvolver estratégias proativas de gestão hospitalar. Vários estudos destacaram a importância da análise de dados epidemiológicos e modelos preditivos para prever a demanda por leitos hospitalares e facilitar uma melhor alocação de recursos. Para Chen et al. (2020) em um estudo recente, os autores utilizaram o modelo SARIMAX para prever surtos de doenças respiratórias em áreas urbanas. Além disso, Sami e Yasar

(2021), aplicaram o modelo Prophet para prever a demanda por leitos hospitalares em resposta a doenças respiratórias.

Neste contexto, este estudo propõe um modelo preditivo que combina dados epidemiológicos, análise de séries temporais e técnicas de SARIMAX e Prophet para prever a demanda por leitos hospitalares relacionados a doenças respiratórias em São Paulo e regiões adjacentes. Ao integrar essas abordagens, buscamos fornecer insights valiosos para a gestão hospitalar e políticas de saúde pública, visando melhorar a resposta a emergências de saúde respiratória.

2. FUNDAMENTAÇÃO TEÓRICA

2.1 Prophet

O Prophet é um modelo desenvolvido pelo Facebook para a previsão de séries temporais, especialmente projetado para lidar com dados que possuem forte sazonalidade, feriados e

tendências não lineares. Esse modelo é amplamente utilizado devido à sua simplicidade de uso e robustez em diferentes cenários de séries temporais. O Prophet é uma ferramenta poderosa para prever doenças respiratórias, que frequentemente apresentam padrões sazonais.

O modelo Prophet segue uma abordagem aditiva, onde a série temporal é decomposta em três componentes principais: tendência, sazonalidade e feriados/eventos especiais. Essa decomposição permite que o modelo capture padrões complexos e variáveis ao longo do tempo (Taylor & Letham, 2018).

O Prophet modela a série temporal como uma soma de quatro componentes principais: tendência, sazonalidade, feriados e erros aleatórios. A Equação (1) expressa o modelo, escrita no artigo de Sean J., *et al.* (2018). Este artigo descreve o modelo Prophet para previsão de séries temporais, que é expresso como na equação a seguir:

$$y(t) = g(t) + s(t) + h(t) + \epsilon_t \quad (1)$$

Em (1), temos que $y(t)$ é a observação da série temporal no tempo t , $g(t)$ é a função de tendência que modela a evolução de longo prazo da série temporal, $s(t)$ é a função de sazonalidade que captura os padrões periódicos, $h(t)$ é a função de feriados que modela os efeitos de feriados e eventos recorrentes, e ϵ_t é o termo de erro que captura a variabilidade não explicada pelos demais componentes.

A tendência $g(t)$ no Prophet pode ser modelada de duas formas principais: o crescimento saturado não linear e a tendência linear com pontos de mudança, ou changepoints.

O crescimento saturado não linear é uma variação da função logística utilizada para modelar crescimento não linear que eventualmente se satura. A Equação (2) modela um processo em que o crescimento começa de forma exponencial e, com o tempo, desacelera até atingir um limite máximo, formando uma curva sigmoideal característica da função logística.

$$g(t) = \frac{C}{1 + \exp(-k(t - m))} \quad (2)$$

Nesta equação, o termo $g(t)$ representa o valor da função de crescimento no tempo t , C é a capacidade de saturação, ou seja, o valor máximo que o crescimento pode alcançar, k é a taxa de crescimento, indicando a rapidez com que o valor de $g(t)$ se aproxima de C e m é o parâmetro de deslocamento que ajusta o ponto médio da curva de crescimento.

Já a tendência linear com pontos de mudança é quando o Prophet introduz pontos, onde a taxa de crescimento k pode se ajustar, denominados pontos de mudança. A fórmula apresentada em (3), descreve os pontos de mudança que permitem que a taxa de crescimento k se ajuste em diferentes

períodos, capturando mudanças estruturais, como novas políticas de negócio ou mudanças de mercado.

$$g(t) = \frac{C(t)}{1 + \exp(-(k + \mathbf{a}(t)^T \boldsymbol{\delta})(t - (m + \mathbf{a}(t)^T \boldsymbol{\gamma})))} \quad (3)$$

Em (3), o termo $C(t)$ é a capacidade de saturação que pode variar ao longo do tempo, k é a taxa de crescimento base, $\mathbf{a}(t)$ é um vetor indicador que sinaliza se t está após um ponto de mudança, $\boldsymbol{\delta}$ é um vetor de ajustes na taxa de crescimento nos pontos de mudança e $\boldsymbol{\gamma}$ é um vetor de ajustes para manter a continuidade da curva de crescimento.

A sazonalidade $s(t)$ no Prophet é modelada usando uma soma de senos e cossenos, o que permite capturar padrões periódicos de diferentes frequências.

$$s(t) = \sum_{n=1}^N \left(a_n \cos\left(\frac{2\pi n t}{P}\right) + b_n \sin\left(\frac{2\pi n t}{P}\right) \right) \quad (4)$$

Na Equação (4), o valor de $s(t)$ é a função sazonal no tempo t , A soma de $n=1$ a N indica que estamos somando múltiplos termos harmônicos. N é o número de termos harmônicos incluídos na série, a_n é o coeficiente que multiplica o termo do cosseno, ele determina a amplitude do componente de cosseno para a n -ésima frequência, e $\cos(2\pi n t / P)$ é o termo do cosseno que varia com o tempo t , onde a frequência do cosseno é determinada por $2\pi n / P$, onde P é o período da sazonalidade, b_n é o coeficiente que multiplica o termo do seno, ele determina a amplitude do componente de seno para a n -ésima frequência e $\sin(2\pi n t / P)$ é o termo do seno que varia com o tempo t , assim como no caso do cosseno, a frequência do seno é determinada por $2\pi n / P$.

Os efeitos dos feriados $h(t)$ são modelados de forma aditiva e podem ser específicos para diferentes dias ou períodos. Os feriados são incluídos como variáveis indicadoras, que permitem ao modelo ajustar automaticamente os efeitos desses dias.

$$h(t) = Z(t)\boldsymbol{\kappa} \quad (5)$$

Finalmente, em (5), temos que $h(t)$ representa o impacto total de todos os feriados e eventos no tempo t , este valor é adicionado à série temporal para capturar os efeitos específicos de feriados e eventos, $Z(t)$ é uma matriz de indicadores binários. Cada coluna da matriz representa um evento específico (ou feriado), e cada linha representa um ponto no tempo t . O valor é 1 se o evento ocorre no tempo t e 0 caso contrário. $\boldsymbol{\kappa}$ é um vetor de coeficientes que mede o impacto de cada feriado ou evento na série temporal. Cada elemento do vetor $\boldsymbol{\kappa}$ corresponde a um feriado ou evento específico e representa a magnitude do impacto desse evento.

2.2 SARIMAX

O modelo SARIMAX (Seasonal AutoRegressive Integrated Moving Average with eXogenous regressors) é uma extensão sofisticada do modelo ARIMA (Autoregressive Integrated Moving Average), projetado para lidar com séries temporais que apresentam sazonalidade e que são influenciadas por variáveis exógenas. Este modelo é particularmente útil em contextos onde padrões sazonais e fatores externos desempenham um papel significativo nas variações da série temporal.

O SARIMAX é uma combinação dos componentes ARIMA com uma parte sazonal (S) e variáveis exógenas (X). A notação do modelo é expressa na Figura 6.

$$\text{SARIMAX}(p, d, q)(P, D, Q, s) \quad (6)$$

Em (6) p é a ordem da parte autorregressiva (AR), d é o grau de diferenciação necessário para tornar a série estacionária, q é a ordem da média móvel (MA), P é a ordem da parte autorregressiva sazonal, D é o grau de diferenciação sazonal, Q é a ordem da média móvel sazonal e s é o período da sazonalidade (por exemplo, $s = 12$ para dados mensais com sazonalidade anual).

Como mencionado, o algoritmo ARIMA, combina três processos: AR (Autoregressive), que relaciona a variável com seus valores passados; I (Integrated), que é a diferenciação para tornar a série estacionária e o processo MA (Moving Average), que modela o erro como uma combinação linear dos erros passados.

O algoritmo é baseado no princípio da sazonalidade dos dados, onde adiciona componentes que capturam padrões sazonais. Estes são especificados em termos de ordem e periodicidade. Fora isso também se utiliza de variáveis exógenas, as quais podem influenciar a série temporal. Essas variáveis são integradas no modelo para melhorar a precisão das previsões.

Conforme descrito em Shumway e Stoffer (2016), o SARIMAX é amplamente utilizado devido à sua capacidade de capturar tanto os padrões sazonais quanto as influências exógenas nas séries temporais. Para Brockwell e Davis (2016) é fundamental que a seleção de parâmetros e a validação do modelo seja realizado com cautela para garantir previsões precisas e confiáveis.

3. METODOLOGIAS

3.1 Preparação dos Dados

No início deste estudo, iniciamos com a importação dos dados de internações hospitalares a partir de um arquivo Excel, os quais foram então submetidos a um processo de pré-processamento. Esta etapa visava principalmente a formatação adequada das datas e a criação de variáveis adicionais para facilitar a análise subsequente.

3.2 Análise Exploratória

Posteriormente, conduzimos uma análise exploratória dos dados. Essa análise teve como objetivo identificar tendências, sazonalidades e padrões nos registros de internações hospitalares. Um aspecto crucial dessa etapa foi a identificação da máxima ocupação de leitos por hospital ao longo da série histórica, o que permitiu uma compreensão abrangente da utilização dos recursos hospitalares. Além disso, calculamos a taxa de ocupação para cada registro, fornecendo insights sobre a capacidade operacional dos hospitais em relação às internações.

Para visualizar os dados e facilitar a compreensão dos padrões identificados, utilizamos gráficos de barras para representar a média de internações por mês para cada hospital. Essas visualizações permitiram uma comparação direta entre a capacidade máxima de internações e as internações reais, facilitando a identificação de padrões sazonais e tendências emergentes.

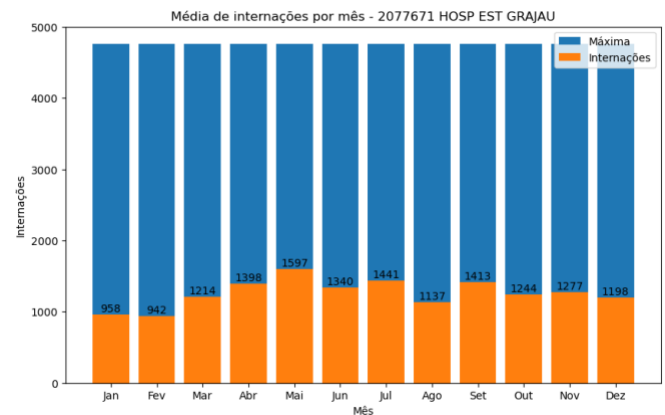


Figura 1: Média mensal da quantidade de internações comparado a capacidade máxima do Hospital Estadual do Grajaú.

A Figura 1 ilustra a média de internações mensais no Hospital Estadual do Grajaú, com a cor laranja representando a média mensal de internações e a cor azul indicando o pico histórico de internações. Observa-se que os meses de maio e julho registram as maiores médias de internações, enquanto janeiro e fevereiro apresentam as menores médias, evidenciando a sazonalidade das internações de 2008 a 2023.

3.3 Modelagem e Previsão

Na etapa de modelagem e previsão, aplicamos duas abordagens diferentes: SARIMAX e Prophet. O SARIMAX é um modelo estatístico que incorpora elementos de autocorrelação, sazonalidade e regressão em séries temporais. Utilizamos a técnica de `auto_arima` para determinar os melhores parâmetros do modelo SARIMAX, automatizando o processo de seleção de hiper-parâmetros. Os dados de séries temporais foram então preparados para cada hospital e ajustados aos modelos SARIMAX.

Por outro lado, o Prophet é um modelo de previsão de séries temporais desenvolvido pelo Facebook, projetado para lidar

com dados sazonais com tendências não lineares e feriados irregulares. Baseado em um modelo de decomposição aditiva, o Prophet permite a inclusão de efeitos sazonais e feriados, tornando-o adequado para prever padrões complexos em séries temporais. Da mesma forma que com o SARIMAX, os dados de séries temporais foram preparados para cada hospital e ajustados aos modelos Prophet.

Finalmente, para avaliar a precisão dos modelos de previsão, utilizamos o Erro Quadrático Médio (RMSE) como métrica de avaliação. O RMSE calcula a raiz quadrada da média dos quadrados dos erros entre as previsões do modelo e os valores reais. Com base nos resultados do RMSE, identificamos o modelo mais preciso para cada hospital, permitindo uma previsão mais confiável da demanda por internações hospitalares.

4. MAPA INTERATIVO DE LEITOS

4.1 Aspectos Computacionais

Começamos importando as bibliotecas necessárias para o processo, incluindo Selenium, Pandas, Openpyxl e Folium, entre outras, essenciais para a automação, manipulação de dados e visualização de mapas. Para automatizar a extração de informações sobre cada hospital, utilizamos uma função que emprega o Selenium para realizar buscas no Google para cada hospital na lista, extraindo dados como endereço, telefone, horário de funcionamento e link para mais informações.

Após a obtenção das informações, organizamos os dados em um DataFrame do Pandas para facilitar a manipulação e análise dos dados. Este DataFrame inclui campos como nome do hospital, endereço, telefone, horário de funcionamento e link para mais informações. Utilizamos a API do OpenCage Geocoding para obter as coordenadas geográficas de cada hospital, permitindo a criação de um mapa interativo com a biblioteca Folium.

Marcadores foram adicionados ao mapa para representar cada hospital, permitindo uma visualização geoespacial das informações. Dessa forma, é possível explorar a localização dos hospitais e acessar rapidamente os dados coletados, oferecendo uma ferramenta útil para análise e tomada de decisões com base na distribuição geográfica dos hospitais.

4.2 Sistema de Recomendação

Para fornecer uma experiência personalizada, permitimos que o usuário defina sua própria localização dentro do código. Isso é feito especificando um endereço na variável `seu_endereco` no código-fonte. O usuário pode modificar essa variável para indicar sua localização atual.

Ao definir sua localização, o usuário pode receber informações sobre os hospitais mais próximos a ele e as rotas possíveis da sua localização até esses hospitais. Isso permite uma tomada de decisão mais informada em caso de necessidade de assistência médica urgente, proporcionando acesso rápido e fácil a informações sobre os hospitais em sua área.

Utilizando a localização definida pelo usuário, calculamos a distância entre essa localização e os hospitais obtidos na pesquisa. Identificamos os cinco mais próximos com base nessa distância, onde são exibidos em um mapa separado, juntamente com suas possíveis rotas, permitindo aos usuários visualizarem facilmente os hospitais mais próximos e os trajetos disponíveis, facilitando assim a tomada de decisões em emergências médicas.

5. RESULTADOS

5.1 Previsões de Demanda Hospitalar

A Figura 2 apresenta as previsões de demanda hospitalar para o Hospital Estadual do Grajaú, utilizando dois modelos de séries temporais: SARIMAX e Prophet. As linhas contínuas representam as previsões realizadas por cada modelo, enquanto as áreas sombreadas indicam os intervalos de confiança associados a essas previsões.

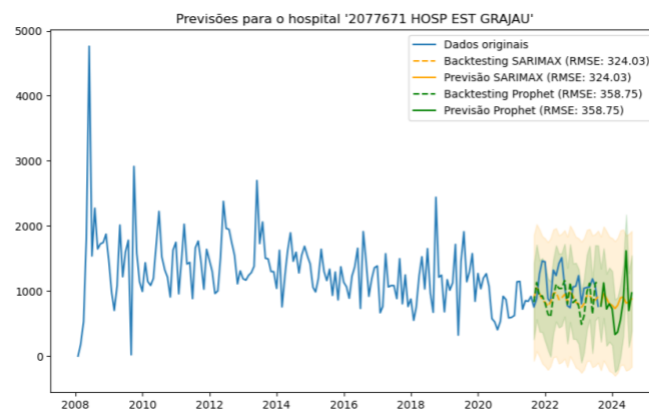


Figura 2: Previsões de demanda hospitalar para o Hospital Estadual do Grajaú.

Para avaliar a precisão dos modelos, utilizamos a métrica RMSE (Root Mean Square Error), que mede a diferença entre os valores previstos e os valores reais. Os valores de RMSE são:

- Backtesting SARIMAX: 324.03
- Previsão SARIMAX: 324.03
- Backtesting Prophet: 358.75
- Previsão Prophet: 358.75

Na Figura 2, podemos observar a série temporal dos dados originais de demanda hospitalar de 2008 até 2024, representada pela linha azul. Os modelos SARIMAX e Prophet foram utilizados para realizar previsões, sendo que as previsões de SARIMAX estão representadas pela linha laranja e as previsões de Prophet pela linha verde. As áreas sombreadas ao redor das linhas de previsão (verde e amarelo) mostram os intervalos de confiança, indicando a incerteza das

previsões. Para ambos os modelos, foi utilizado o intervalo de confiança padrão de 95%.

Ambos os modelos foram avaliados por meio de backtesting, que consiste em testar o modelo com dados históricos para verificar sua precisão. Os resultados mostram que o modelo SARIMAX tem um RMSE de 324.03, enquanto o modelo Prophet apresenta um RMSE de 358.75. Esses valores indicam que o modelo SARIMAX teve um desempenho ligeiramente melhor em termos de precisão de previsão.

A análise mostra que, embora ambos os modelos sejam capazes de capturar a tendência geral e padrões sazonais da série temporal, o modelo SARIMAX oferece previsões mais precisas em comparação com o Prophet, conforme indicado pelas métricas de RMSE. As previsões futuras indicam que a demanda hospitalar continuará a variar, mas os intervalos de confiança fornecem uma faixa de possíveis valores que ajudam a entender a incerteza associada a essas previsões.

5.2 Mapa Interativo de Leitos com Pop-Ups para cada Hospital



Figura 3: Mapa interativo de leitos com a localização do usuário e os cinco hospitais mais próximos.

A Figura 3 mostra um mapa interativo com a localização da Pontifícia Universidade Católica de São Paulo (PUC-SP) e os cinco hospitais mais próximos, indicados com marcadores coloridos que representam a quantidade de leitos disponíveis em cada hospital. O marcador cinza com símbolo de uma pessoa indica sua localização, enquanto os marcadores coloridos com símbolo de hospital representam os hospitais mais próximos dela, com a cor do marcador indicando a quantidade de leitos disponíveis. As linhas pretas conectam a localização escolhida aos cinco hospitais mais próximos, indicando a distância entre eles.

A coloração dos marcadores representa a previsão da taxa de ocupação dos leitos e foi determinada com base na seguinte lógica:

- Se o valor previsto para o último dia, dividido pela quantidade máxima histórica de cada hospital, for menor que 0.4, o ícone é verde, indicando que o hospital tem uma boa disponibilidade de leitos e está em uma situação confortável para admitir novos pacientes.
- Se o valor estiver entre 0.4 e 0.8, inclusive, o ícone é amarelo, indicando uma disponibilidade moderada de leitos, sugerindo que o hospital está mais próximo da capacidade máxima, mas ainda tem espaço para novos pacientes.
- Se o valor previsto for maior que 0.8, o ícone é vermelho, indicando baixa disponibilidade ou falta de leitos, sugerindo que o hospital está quase cheio ou completamente cheio, com capacidade limitada para novos pacientes.

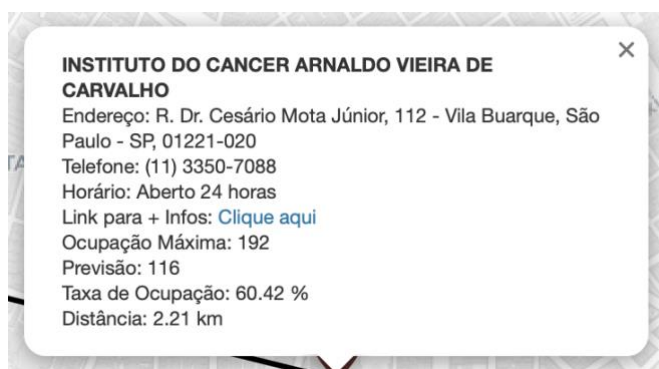


Figura 4: Pop-up ilustrativo do Instituto do Câncer Arnaldo Vieira de Carvalho

Ao clicar em um dos marcadores de hospitais exibido na Figura 3, aparece um pop-up informativo contendo diversas informações essenciais sobre o hospital selecionado, como mostra a Figura 4. Por exemplo, o pop-up fornece o nome do hospital, que neste caso é o Instituto do Câncer Arnaldo Vieira de Carvalho, juntamente com o endereço completo: Rua Dr. Cesário Mota Júnior, 112 - Vila Buarque, São Paulo - SP, 01221-020. Além disso, o telefone de contato do hospital é disponibilizado: (11) 3350-7088.

O horário de funcionamento informado é 24 horas, garantindo que os usuários saibam que podem acessar os serviços a qualquer momento do dia ou da noite. Para aqueles que precisam de informações adicionais, há um link no pop-up marcado como "Clique aqui" que direciona para mais detalhes sobre o hospital.

Informações cruciais sobre a capacidade do hospital também são incluídas, como a ocupação máxima, que é de 192 leitos, e a previsão atual de pacientes, que é de 116. A taxa de ocupação é apresentada em termos percentuais, sendo 60.42% neste caso, o que ajuda a avaliar a disponibilidade de vagas no hospital. Por fim, a distância do usuário até o hospital é especificada, sendo de 2.21 km. Este conjunto de informações é extremamente útil para auxiliar as unidades de saúde, pois permite uma avaliação rápida e precisa da capacidade e da disponibilidade do hospital, além de facilitar o contato e o acesso ao local.

6. CONCLUSÃO

A pesquisa realizada proporciona uma análise detalhada e precisa da demanda por leitos hospitalares para doenças respiratórias em São Paulo, utilizando modelos preditivos avançados como SARIMAX e Prophet. Ao longo do estudo, identificamos que ambos os modelos possuem alta capacidade de prever a demanda, com SARIMAX apresentando um desempenho ligeiramente superior em termos de precisão. A criação de um mapa interativo de leitos, que visualiza a disponibilidade e localização dos leitos hospitalares, demonstrou ser uma ferramenta valiosa para a gestão eficiente dos recursos hospitalares, permitindo uma alocação mais estratégica e ágil dos mesmos. Além disso, a análise exploratória dos dados revelou padrões sazonais e tendências que são cruciais para a elaboração de políticas de saúde pública mais eficazes.

Concluimos que a integração de técnicas de previsão de demanda com ferramentas interativas de visualização pode significativamente melhorar a capacidade de resposta do sistema de saúde, tornando-o mais proativo e preparado para lidar com flutuações na demanda por leitos hospitalares. Esse estudo não apenas contribui para a literatura existente, mas também oferece uma abordagem prática que pode ser implementada em outras regiões para otimizar a gestão de recursos hospitalares. Em última análise, a aplicação dessas metodologias pode levar a melhorias substanciais na qualidade do atendimento ao paciente e na eficiência operacional dos hospitais, promovendo uma resposta mais rápida e eficaz às necessidades emergentes de saúde respiratória.

7. REFERÊNCIAS

- São Paulo (Cidade). Prefeitura Municipal. Secretaria da Saúde. Dados de internação hospitalar. Disponível em: <http://tabnet.saude.prefeitura.sp.gov.br/cgi/deftohtm3.exe?secretarias/saude/TABNET/AIHRD08/AIHRDNET08.def>. Acessado em: setembro de 2023
- Organização Mundial da Saúde (OMS). (2019). Poluição do ar ambiente (ao ar livre). Disponível em: <https://www.who.int/news-room/fact-sheets/detail/ambient-%28outdoor%29-air-quality-and-health>. Acessado em: fevereiro de 2024
- Colaboradores do GBD 2019 Diseases and Injuries. (2020). Carga global de 369 doenças e lesões em 204 países e territórios, 1990–2019: uma análise sistemática para o Estudo Global da Carga de Doença 2019. *The Lancet*, 396(10258), 1204-1222. Disponível em: <https://www.thelancet.com/pdfs/journals/lancet/PIIS0140-6736%2820%2930925-9.pdf>. Acessado em: fevereiro de 2024
- Chen, Q., Li, P., Wang, J., & Schuurmans, D. (2020). Previsão da admissão hospitalar de pacientes com doenças respiratórias usando métodos de conjunto. Em *Proceedings of the 2020 IEEE International Conference on Bioinformatics and Biomedicine (BIBM)* (pp. 2796-2803). IEEE. Disponível em: <https://link.springer.com/article/10.1007/s11704-024-40231-1>. Acessado em: fevereiro de 2024
- Sami, A., & Yasar, A. (2021). Previsão de surtos de doenças respiratórias em áreas urbanas usando SARIMAX: um estudo de caso de Karachi. *International Journal of Computer Applications*, 182(6), 6-10. Disponível em: <https://www.taylorfrancis.com/chapters/edit/10.1201/9781003185246-7/prediction-epidemic-disease-outbreaks-using-machine-learning-vaishali-gupta-sanjeev-prasad>. Acessado em: fevereiro de 2024
- Lethan, Benjamin; Taylor, Ean J. *Forecasting at scale*. Menlo Park, California: Facebook, 2017. Disponível em: https://www.researchgate.net/publication/344989540_Forecasting_at_scale. Acessado em: fevereiro de 2024
- Brockwell, Peter J; Davis, Richard A. *Introduction to Time Series and Forecasting*. 3. ed. Cham: Springer, 2016. Disponível em: fevereiro de 2024 https://www.academia.edu/42933730/Introduction_to_Time_Series_and_Forecasting_Third_Edition. Acessado em:
- Shumway, Robert H.; Stoffer, David S. *Time series analysis and its applications: with R examples*. 4. ed. Cham: Springer, 2017. Disponível em <http://www.stat.ucla.edu/~frederic/221/W21/tsa4.pdf>. Acessado em: fevereiro de 2024