

Análise de predições de atendimentos na saúde em Florianópolis

Analysis of healthcare predictions in Florianópolis

Análisis de las predicciones sanitarias en Florianópolis

Luciano Weber¹, Luís Antonio Lourenço², Martina Klippel Brehm³, Pedro Matiucci Pereira⁴,
Vinicius Faria Culmant Ramos⁵

1 Mestrando no Programa de Pós-graduação em Engenharia do Conhecimento, da Universidade Federal de Santa Catarina (UFSC) Florianópolis - Santa Catarina - Brasil.

2 Pós-Doutorando no Programa de Pós-graduação em Engenharia do Conhecimento, da Universidade Federal de Santa Catarina (UFSC) Florianópolis - Santa Catarina - Brasil

3 Bacharelada em Sistemas de Informação, na Universidade Federal de Santa Catarina (UFSC) Florianópolis - Santa Catarina - Brasil.

4 Bacharelado em Sistemas de Informação, na Universidade Federal de Santa Catarina (UFSC) Florianópolis - Santa Catarina - Brasil

5 Professor Doutor no Programa de Pós-graduação em Engenharia do Conhecimento, da Universidade Federal de Santa Catarina (UFSC) Florianópolis - Santa Catarina - Brasil.

Autor correspondente: Luciano Weber


E-mail: luciano.weber@ufsc.br

Link: <https://github.com/LucWeb80/Artigo-Atendimentos>

Florianópolis – Santa Catarina – Brasil

Resumo

Objetivo: Comparar modelos de séries temporais na predição de atendimentos individuais mensais em Florianópolis em 2024. **Métodos:** Usando dados públicos de atendimentos de 2019 a 2023 do Ministério da Saúde do Brasil, aplicados nos modelos ARIMA, SARIMA, Stacking e Holt-Winters. A comparação foi baseada em métricas de erro. **Resultados:** SARIMA apresentou maior precisão, enquanto ARIMA gerou predição constante para todos os meses, embora suas métricas de erro serem semelhantes às de SARIMA. **Conclusões:** A aplicação de modelos de séries temporais é útil para o planejamento em saúde pública, embora as diferenças entre modelos indiquem limitações. Essas técnicas podem otimizar recursos e melhorar a qualidade do



atendimento, mas estudos adicionais são necessários para aprofundar as análises e aprimorar as previsões.

Descritores: Atendimento médico; atenção primária à saúde; previsão; séries temporais


Abstract

Objective: To compare time series models in predicting monthly individual visits in Florianópolis in 2024. **Methods:** Using public data on visits from 2019 to 2023 from the Brazilian Ministry of Health, applied in the ARIMA, SARIMA, Stacking and Holt-Winters models. The comparison was based on error metrics. **Results:** SARIMA showed greater accuracy, while ARIMA generated constant prediction for all months, although its error metrics were similar to SARIMA. **Conclusions:** The application of time series models is useful for public health planning, although differences between models indicate limitations. These techniques can optimize resources and improve the quality of care, but additional studies are needed to deepen the analyzes and improve predictions.

Keywords: Medical care; primary health care; prediction; time series

Resumen

Objetivo: Comparar modelos de series de tiempo en la predicción de visitas individuales mensuales en Florianópolis en 2024. **Métodos:** Utilizando datos públicos de visitas de 2019 a 2023 del Ministerio de Salud de Brasil, aplicados en los modelos ARIMA, SARIMA, Stacking y Holt-Winters. La comparación se basó en métricas de error. **Resultados:** SARIMA mostró mayor precisión, mientras que ARIMA generó predicción constante para todos los meses, aunque sus métricas de error fueron similares a SARIMA. **Conclusiones:** La aplicación de modelos de series temporales es útil para la planificación de la salud pública, aunque las diferencias entre modelos indican



limitaciones. Estas técnicas pueden optimizar recursos y mejorar la calidad de la atención, pero se necesitan estudios adicionales para profundizar los análisis y mejorar las predicciones.


Descriptorios: Atención médica; atención primaria de salud; predicción; series de tiempo

Introdução

Nos últimos anos, a aplicação de técnicas estatísticas e de aprendizado de máquina tem revolucionado diversos campos, incluindo o setor de saúde pública (Thomasian, Carstel e Adashi, 2021). Por tratar-se de um estudo ecológico de séries temporais (Bolsoni, Garcia e Calderon, 2022), este artigo se concentra na exploração de tais técnicas para aprimorar a predição e gestão de serviços de saúde na atenção primária, especificamente em Florianópolis, Brasil, para o ano de 2024. O objetivo é analisar comparativamente os resultados de 4 modelos de séries temporais usados na predição do volume de atendimentos médicos individuais, item crítico no planejamento e alocação de recursos em saúde, uma temática sensível à gestão e uso de conhecimento, dados e informação em saúde digital.

A motivação deste estudo surge da crescente demanda por serviços de saúde eficientes e da necessidade de otimizar a distribuição de recursos (Mendes, *et al.*, 2012), especialmente em cenários de restrições orçamentárias e desafios logísticos. A predição correta do volume de serviços de saúde necessários é fundamental para garantir a disponibilidade e a qualidade do atendimento ao paciente (Mendes, *et al.*, 2012).

Neste contexto, a pesquisa utilizou modelos de séries temporais (Box, *et al.*, 2015), como ARIMA e SARIMA (Soyiri, 2012), para analisar dados históricos e prever tendências futuras em atendimentos de saúde. O estudo fornece *insights* aos formuladores de políticas e profissionais de saúde em Florianópolis, servindo de referência que pode ser adaptada e aplicada em outras regiões, contribuindo para a melhoria contínua dos sistemas de saúde pública.




Métodos

A metodologia seguiu etapas previstas no *Cross Industry Standard Process for Data Mining* (CRISP-DM) que inclui obtenção, análise exploratória dos dados, modelagem e avaliação dos resultados. Os dados mensais sobre o número de atendimentos individuais na atenção primária à saúde de 2019 a 2023, foram obtidos do Sistema de Informação em Saúde para a Atenção Básica (SISAB), do Ministério da Saúde do Brasil. Estes dados são públicos e não exigiram aprovação pelo Comitê de Ética em Pesquisa (CEP). Apesar de registros no SISAB desde 2013, não há dados disponíveis para Florianópolis para outubro, novembro e dezembro de 2023. Para evitar erros preditivos devido a essas ausências, optou-se por realizar uma predição de 15 meses, englobando os 3 meses faltantes de 2023 e os 12 meses do ano de 2024.

Foram usados quatro algoritmos de séries temporais: ARIMA, SARIMA, Stacking e Holt-Winters. A implementação foi realizada em Python (<https://github.com/LucWeb80/Artigo-Atendimentos>). Os modelos ARIMA e SARIMA foram ajustados utilizando a função *auto.arima*. No método Holt-Winters, houve testes de adição e multiplicação para a tendência e para a sazonalidade. No método Stacking (Paula, 2022), utilizou-se o método de hiperparametrização *Grid Search* com os seguintes parâmetros: *Random Forest Estimators* (50, 100, 150), *Gradient Boosting Estimators* (50, 100, 150) e *Ridge Alpha* (0,1; 0,2; 0,3).

Para avaliar a performance dos modelos, foram utilizadas as seguintes métricas: *Mean Squared Error* (MSE), *Root Mean Squared Error* (RMSE), *Mean Absolute Percentage Error* (MAPE) e *Theil's U* (TU), conforme o Guia sobre Métricas de Erro de Regressão (Sefidian e Daneshpour, 2020). O período de teste considerado foi dos últimos 15 meses da série histórica (julho de 2022 a setembro de 2023).

Resultados e Discussão



Os ajustes dos modelos paramétricos utilizando a função *auto.arima* resultaram na seleção dos modelos ARIMA (1,1,0) e SARIMA (0,1,0) (0,1,1) para a análise. Para o algoritmo Holt-Winters, o modelo com 12 períodos sazonais apresentou maior precisão. No método Stacking, a hiperparametrização com *Grid Search* identificou os melhores parâmetros como *Random Forest* =100, *Gradient Boosting* = 150, *Ridge* = 0, 1.


A Tabela 1 apresenta as métricas de performance dos modelos ajustados, demonstrando diferenças significativas na capacidade preditiva de cada algoritmo. O SARIMA obteve a melhor performance geral com menor *Mean Squared Error* (MSE) e *Root Mean Squared Error* (RMSE), sugerindo maior precisão nas previsões. Embora o ARIMA tenha apresentado métricas de erro semelhantes ao SARIMA, sua predição constante ao longo dos meses pode indicar limitações na captura de padrões sazonais. O modelo Stacking, apesar de possuir maior complexidade, apresentou métricas de erro superiores aos demais modelos, possivelmente devido à combinação dos estimadores. Por fim, o modelo Holt-Winters apresentou um desempenho intermediário, com métricas de erro mais altas em comparação com SARIMA e ARIMA, mas ainda dentro de um intervalo aceitável.:

Tabela 1 – Métricas de performance dos modelos de séries temporais ajustados para a predição do número de internações na atenção básica no município de Florianópolis

Algoritmo	MSE	RMSE	MAPE	TU
ARIMA	145338324,974	12055.634	0.100	0.743
SARIMA	132540646,351	11512.629	0.103	0.657
Stacking	501097275,394	22385.202	0.203	0.885
Holt-Winters	296115558,451	17208.008	0.142	1.052

Fonte: dos Autores

Esses resultados indicam que, embora o uso de modelos de séries temporais forneça suporte valioso para o planejamento em saúde pública, a escolha do modelo




apropriado é crucial. O modelo SARIMA, em particular, mostrou-se eficaz em capturar padrões sazonais e tendências, tornando-o mais adequado para previsões na saúde pública de Florianópolis. No entanto, as limitações observadas, como as diferenças nos resultados dos modelos, ressaltam a necessidade de estudos adicionais para melhorar a precisão das previsões e a utilização otimizada de recursos.

As métricas MSE, RMSE e MAPE são amplamente utilizadas para avaliar a precisão de modelos preditivos (Patil, *et al.*, 2023). Em geral, quanto menores esses valores, melhor a performance do modelo. A métrica TU (Theil's U) também é relevante para a comparação de desempenho. Valores de TU próximos de 1 indicam que o modelo tem uma performance similar ao modelo trivial (que simplesmente assume que o valor futuro é igual ao último valor observado). Valores de TU maiores que 1 indicam que o modelo tem uma performance pior do que o trivial, enquanto valores menores que 1 indicam uma performance melhor que o trivial (Arumugam e Natarajan, 2023).

Os resultados demonstram que o modelo SARIMA apresentou o melhor desempenho geral, com métricas menores em comparação aos outros modelos, incluindo um TU significativamente menor que 1, sugerindo uma performance superior ao modelo trivial. O modelo ARIMA também teve um bom desempenho, com métricas ligeiramente superiores às do SARIMA, mas ainda assim apresentando um TU inferior a 1. O modelo Holt-Winters, apesar de ter um TU ligeiramente superior a 1, apresentou métricas que indicam uma precisão moderada. O modelo Stacking, embora sofisticado, apresentou as maiores métricas de erro e um TU abaixo de 1, mas superior aos modelos ARIMA e SARIMA, indicando uma performance menor.


Na literatura, há diversas análises dos algoritmos. Observou-se que ARIMA e SARIMA tendem a ser mais utilizados na captura de padrões lineares e sazonais (Dubey, *et al.*, 2021). São modelos clássicos e amplamente utilizados em previsões de séries temporais. Para o poder público, a eficácia destes modelos pode ser medida pela precisão das previsões em relação aos padrões sazonais dos atendimentos. Eles podem



ser relativamente eficientes em termos de custo, uma vez que são modelos bem estabelecidos e amplamente suportados.



Da análise para a predição do número de atendimentos na atenção básica em Florianópolis (Figura 1), percebeu-se que o modelo ARIMA tende a uma predição linear. Já a predição com o modelo SARIMA (0,1,0) (0,1,1) demonstrou as melhores métricas de erro (Figura 2).

Figura 1 – Predição do número de atendimentos na atenção primária para o município de Florianópolis utilizando o modelo ARIMA (1, 1, 0)



Fonte: dos autores

Figura 2 – Predição do número de atendimentos na atenção primária para o municípios de Florianópolis utilizando o modelo SARIMA (0,1,0) (0,1,1)





Fonte: dos autores

O modelo Holt-Winters é usado para capturar tendências e padrões sazonais, especialmente se os dados mostram uma sazonalidade clara (Feroni e Andreão, 2017). Este modelo pode ser mais simples e rápido de aplicar em comparação com os modelos paramétricos ARIMA e SARIMA, o que tende a ser benéfico para o poder público em termos de economia de tempo e recursos.


Verificou-se que o modelo Holt-Winters (Figura 3) segue as previsões de SARIMA, com valores variáveis a respeito do número previsto de atendimentos individuais de Florianópolis em 2024. Entretanto, é importante destacar que diferentemente do modelo SARIMA, as previsões realizadas pelo modelo Holt-Winters apresentam tendência de queda no número de atendimentos na atenção básica. Da mesma forma, pode-se observar que o método Stacking realizou previsões similares ao modelo SARIMA, conforme pode ser observado na Figura 4.

Figura 3 – Predição do número de atendimentos na atenção primária para o município de Florianópolis utilizando o modelo Holt-Winters




Fonte: dos autores

Figura 4 – Previsão do número de atendimentos na atenção primária para o município de Florianópolis utilizando o modelo Stacking



Fonte: dos autores

As tecnologias que mostram consistentemente previsões mais altas podem indicar uma expectativa de aumento na demanda por atendimentos, enquanto valores mais




baixos podem indicar uma expectativa de menor demanda. Para os usuários (pessoas atendidas), a melhor tecnologia seria aquela que alcança mais precisão as demandas reais, garantindo que haja recursos suficientes sem sobrecarregar o sistema de saúde. Para o poder público, a melhor tecnologia pode ser aquela que oferece um bom equilíbrio entre precisão e custo. Se a precisão adicional de um modelo mais complexo não se traduzir em melhor planejamento ou alocação de recursos, modelos mais simples e eficientes, como o modelo Holt-Winters, podem ser preferíveis.

Uma análise mais detalhada exigiria comparar essas previsões com os dados reais (que podem contribuir para estudos futuros sobre o tema) para avaliar qual modelo ofereceu maior assertividade. Além disso, o custo de implementação e a facilidade de uso também devem ser considerados antes de fazer uma escolha definitiva.

No caso do presente estudo, se as decisões políticas seguirem na direção de uma maior economia, o gestor público poderá optar pela previsão menor de atendimentos individuais. Um exemplo está no mês de dezembro, em que um algoritmo (SARIMA) prediz 123 mil atendimentos, enquanto em outro (Stacking) são 77 mil. A diferença de 43 mil atendimentos para mais ou para menos deve levar em conta, então, sazonalidades e os contextos locais, do contrário muitas pessoas poderão ficar sem atendimento nos postos de saúde, ou pode haver um excesso de profissionais e estrutura, dentro de uma capacidade que fique acima da procura, resultado em perdas de recursos para outras áreas, como Educação. “(...) as proteções em torno das respostas geradas (...) podem prevenir danos” (Ettman e Galea, 2023).

Com efeito, o uso inadequado dos algoritmos, especialmente no contexto de previsões de atendimentos individuais na atenção primária à saúde, pode ter várias implicações críticas. Uma delas diz respeito ao acesso não autorizado de informações, ou ao uso incorreto dessas informações, geralmente para dar golpes em pacientes e seus familiares. “Quanto mais pessoas utilizarem sistemas de informação clínica (CIS) para além dos seus limites intramuros tradicionais, mais promissores serão os benefícios e mais assustadores serão os riscos” (Hübner, Egbert e Schulte, 2020).




Entre outros problemas, está a generalização excessiva, pois algoritmos usados em predições de séries temporais são treinados com dados históricos. Se esses dados não são representativos de futuras condições ou se o modelo é excessivamente ajustado (*overfitting*) aos dados históricos, as predições podem ser enganosas (Braun e Hummel, 2022). No contexto da saúde, isso pode levar a uma alocação inadequada de recursos, como pessoal, medicamentos e equipamentos (Maschewski e Nosthoff, 2022).

É necessário também verificar questões de viés e equidade, pois os modelos são tão imparciais quanto os dados nos quais são treinados (Ghassemi e Nsoesie, 2021). Se os dados históricos contêm viés, os modelos podem perpetuar ou até exacerbar essas tendências (Lett e Cava, 2023). No contexto da saúde, isso pode levar a disparidades nos atendimentos, onde certos grupos demográficos podem ser sistematicamente sub ou superestimados nas previsões de necessidade de serviços de saúde (Wang, *et al.*, 2022).

Há ainda que se levar em conta a sensibilidade aos dados de treinamento, porque os algoritmos podem ser extremamente sensíveis a pequenas variações nos dados de treinamento (Smith, *et al.*, 2020). No contexto da saúde, isso pode significar que variações sazonais, surtos de doenças ou outras anomalias podem distorcer as predições de maneira inadequada, levando a planejamentos baseados em imprecisão.

Infere-se então que as tecnologias implementadas têm como finalidade principal fornecer suporte ao processo de tomada de decisão. A dependência excessiva em algoritmos pode, de fato, reduzir o julgamento humano e a expertise clínica no planejamento e prestação de serviços de saúde. Isso é especialmente relevante em situações complexas que requerem avaliação contextual e ética, algo que os modelos algorítmicos sozinhos não conseguem proporcionar. No entanto, a implementação dessas tecnologias deve sempre manter o humano no centro do processo decisório, garantindo que a expertise clínica continue a ser um componente fundamental no planejamento de políticas de saúde. Carter *et al.* (2023) destacam a importância de manter a responsabilidade humana, especialmente em contextos críticos como a leitura de



mamografias, ressaltando que os sistemas de IA devem complementar e não substituir o julgamento humano.


O custo e a acessibilidade (Owoyemi, *et al.*, 2020) são outros fatores importantes, pois o desenvolvimento, a implementação e a manutenção de soluções preditivas por algoritmos podem ser caros. No contexto da saúde pública, onde os recursos são frequentemente limitados, investir em tecnologias complexas pode não ser a abordagem mais custo-efetiva, especialmente se soluções mais simples puderem fornecer resultados semelhantes. Por fim, a responsabilidade é fator preponderante. Determinar a responsabilidade pelas decisões pode ser desafiador (d'Elia, *et al.*, 2022). No contexto da saúde, erros em previsões podem ter consequências graves. Se um modelo falhar, determinar quem é responsável – o desenvolvedor do algoritmo, o profissional de saúde que o utilizou, ou outra parte – pode ser complicado.

Então, algoritmos têm o potencial de transformar a prestação de serviços de saúde, garantir sua implementação de maneira ética, transparente e responsável é crucial, especialmente quando se trata de previsões que afetam a alocação de recursos de saúde e o bem-estar dos pacientes. Uma abordagem equilibrada, que combina a expertise humana com insights da computação, é geralmente a mais indicada.

Conclusão

Este artigo examinou o uso de algoritmos de séries temporais, especificamente modelos de previsão de séries temporais, no contexto da atenção primária à saúde, com foco em atendimentos individuais no município de Florianópolis. A análise comparativa de diferentes técnicas, incluindo ARIMA, SARIMA, Stacking e Holt-Winters, revelou *insights* sobre a eficácia e eficiência de cada abordagem na previsão de demandas de saúde.

Os resultados obtidos destacam o desempenho superior do modelo SARIMA, que apresentou as menores métricas de erro, indicando uma performance superior ao modelo trivial. O modelo ARIMA também demonstrou bom desempenho, com métricas ligeiramente superiores às do SARIMA, mas ainda assim apresentando um TU inferior a




1. O modelo Holt-Winters, embora tenha exibido um TU ligeiramente superior a 1, mostrou métricas que indicam uma precisão moderada. O método Stacking, apesar de sua sofisticação, apresentou as maiores métricas de erro e um TU inferior a 1, mas superior aos modelos ARIMA e SARIMA, sugerindo uma performance menos eficiente em comparação com os outros métodos avaliados.

A análise dos resultados é corroborada pela literatura, que aponta a eficácia dos modelos ARIMA e SARIMA na captura de padrões lineares e sazonais em séries temporais. Esses modelos clássicos são amplamente utilizados em previsões de séries temporais devido à sua capacidade de proporcionar previsões precisas com um custo relativamente baixo. Para o setor público, a utilização desses modelos pode ser vantajosa, uma vez que eles são eficientes na identificação e previsão de padrões sazonais nos atendimentos, auxiliando na gestão e planejamento de recursos.

A discussão destacou a importância de considerar fatores como precisão, transparência, custo e viabilidade operacional ao implementar soluções algorítmicas na saúde pública. Enquanto modelos mais complexos podem oferecer previsões mais precisas, seu custo pode não justificar a implementação em todos os cenários, especialmente sob as restrições orçamentárias típicas do setor público.

A análise sublinhou, ainda, a necessidade crítica de abordagens computacionais serem transparentes, explicáveis e livres de viés, garantindo que as decisões de saúde pública sejam justas e fundamentadas. A integração de julgamento humano e expertise clínica com insights derivados dos algoritmos foi identificada como uma estratégia chave para otimizar os resultados de saúde e garantir a confiança nas tecnologias implementadas.


Em conclusão, enquanto os algoritmos detêm um potencial considerável para melhorar a eficiência e eficácia dos serviços de saúde, sua adoção deve ser abordada com cautela. Os formuladores de políticas, profissionais de saúde e desenvolvedores de tecnologia devem colaborar estreitamente para garantir que as soluções sejam responsáveis, justas e alinhadas com os objetivos mais amplos da saúde pública. Assim,



o uso de algoritmos preditivos na atenção primária à saúde pode ser otimizado para melhorar o atendimento ao paciente, garantir a alocação eficiente de recursos e apoiar decisões informadas no nível do poder público.

Referências

1. Arumugam V, Natarajan V. Time series modeling and forecasting using Autoregressive Integrated Moving Average and Seasonal Autoregressive Integrated Moving Average models. *Instrum Measure Métrol.* 2023;22(4):161-8. doi:10.18280/i2m.220404
2. Bolsoni L, Garcia LP, Calderón DBL. Predição de visitas domiciliares na atenção primária: uma abordagem de séries temporais com o modelo Autoregressive Integrated Moving Average. *Rev Bras Med Fam Comunidade.* 2022;17(44):3012. doi:10.5712/rbmfc17(44)3012
3. Box GEP, Jenkins GM, Reinsel GC, Ljung GM. *Time series analysis: forecasting and control.* 5th ed. New Jersey: John Wiley & Sons; 2015
4. Braun M, Hummel P. Data justice and data solidarity. *Patterns.* 2022;3. doi:10.1016/j.patter.2021.100427
5. Carter SM, Carolan L, Saint James Aquino Y, et al. Australian women's judgements about using artificial intelligence to read mammograms in breast cancer screening. *Digit Health.* 2023;9. doi:10.1177/20552076231191057
6. Walsh CG, Chaudhry B, Dua P, et al. Stigma, biomarkers, and algorithmic bias: recommendations for precision behavioral health with artificial intelligence. *JAMIA Open.* 2020;3(1):9-15. doi:10.1093/jamiaopen/ooz054
7. d'Elia A, Gabbay M, Rodgers S, et al. Artificial intelligence and health inequities in primary care: a systematic scoping review and framework. *Fam Med Community Health.* 2022;10. doi:10.1136/fmch-2022-001670
8. Ettman CK, Galea S. The potential influence of AI on population mental health. *JMIR Ment Health.* 2023. doi:10.2196/49936
9. Feroni RC, Andreão WL. Análise do modelo de Holt-Winters aplicado a uma série histórica de dados com tendência e sazonalidade. *Blucher Physics Proceedings.* 2017;4(1):228-31.
10. Ghassemi M, Nsoesie EO. In medicine, how do we machine learn anything real? *Patterns.* 2022;3(1). doi:10.1016/j.patter.2021.100392
11. Hübner UH, Egbert N, Schulte G. Clinical information systems – seen through the ethics lens. *Yearb Med Inform.* 2020;29(1):104-14. doi:10.1055/s-0040-1701996



12. Lett E, La Cava WG. Translating intersectionality to fair machine learning in health sciences. *Nat Mach Intell.* 2023;5:476-9. doi:10.1038/s42256-023-00651-3
13. Maschewski F, Nosthoff AV. Überwachungskapitalistische Biopolitik: Big Tech und die Regierung der Körper. *Z Politikwiss.* 2022;32:429-55. doi:10.1007/s41358-021-00309-9
14. Mateus LF, Ourique F, Morales AS, Silva MN. Implementação de um modelo de previsão usando séries temporais para estimar excesso de óbitos no Brasil em 2020. *J Health Inform.* 2024;16(1). doi:10.59681/2175-4411.v16.2024.1003
15. Mendes ACG, Sá DA, Miranda GMD, Lyra TM, Tavares RAW. Assistência pública de saúde no contexto da transição demográfica brasileira: exigências atuais e futuras. *Cad Saúde Pública.* 2012;28(5):955-64. doi:10.1590/S0102-311X2012000500014
16. Owoyemi A, Owoyemi J, Osiyemi A, Boyd A. Artificial intelligence for healthcare in Africa. *Front Digit Health.* 2020;2. doi:10.3389/fdgth.2020.00006
17. Paula MG de. Aprendizagem cruzada para previsão de séries temporais univariadas [dissertation]. Brasília: Universidade de Brasília; 2022.
18. Patil H, Bolla BK, Sabeesh E, Bhumireddy DR. Comparative study of predicting stock index using deep learning models. In: *International Conference on Cognitive Computing and Cyber Physical Systems.* Cham: Springer Nature Switzerland; 2023.
19. Python Software Foundation. Python Language Site: Documentation. 2023. Available from: <https://www.python.org/doc/>. Accessed January 12, 2024.
20. Sefidian AM, Daneshpour N. Estimating missing data using novel correlation maximization-based methods. *Appl Soft Comput.* 2020;91:106249. doi:10.1016/j.asoc.2020.106249
21. Smith MJ, Axler R, Bean S, Rudzicz F, Shaw J. Four equity considerations for the use of artificial intelligence in public health. *Bull World Health Organ.* 2020;98:290-2. doi:10.2471/BLT.19.237503
22. Soyiri IN, Reidpath DD. Evolving forecasting classifications and applications in health forecasting. *Int J Gen Med.* 2012;5:381-9. doi:10.2147/IJGM.S31079
23. Wang HE, Landers M, Adams R, et al. A bias evaluation checklist for predictive models and its pilot application for 30-day hospital readmission models. *J Am Med Inform Assoc.* 2022;29(8):1323-33. doi:10.1093/jamia/ocac065