

UTILIZAÇÃO DE MODELOS DE APRENDIZADO DE MÁQUINA COMO FERRAMENTA PARA PREVISÃO DE CASOS DE COVID-19 NA CIDADE DE BOTUCATU – SÃO PAULO

USE OF MACHINE LEARNING MODELS TO PREDICT COVID-19 CASES IN THE CITY OF BOTUCATU – SÃO PAULO

Fábio Eduardo Severino¹ José Luiz Rybarczyk-Filho² Vivian Toledo Santos Gambarato³

RESUMO

A COVID-19, doença causada pelo vírus SARS-CoV-2, provavelmente teve sua origem na província de Hubei, na China, em 2019, tornando-se uma pandemia em questão de meses trazendo grandes prejuízos em várias esferas, afetando milhões de indivíduos. Até agosto de 2021, mais de 200 milhões de pessoas se contaminaram com o Coronavírus, e mais de 4 milhões de mortes foram relatadas ao redor do mundo. No Brasil, no mesmo período, havia mais de 20 milhões de casos confirmados e mais de 500 mil óbitos, com 100% dos municípios contaminados. O município de Botucatu, no Estado de São Paulo, apresenta milhares de pessoas que já foram contaminadas pelo vírus e centenas de óbitos. Durante a pandemia, houve uma notável evidência e aumento do uso de tecnologias nas mais diversas áreas, inclusive para monitoramento de casos e contágio. Os modelos de aprendizado de máquina são algoritmos matemáticos computacionais desenvolvidos com o objetivo de simular o modo de aprendizado humano, com o intuito de desenvolver ferramentas para resolver problemas complexos. Diante desses fatos, o objetivo deste trabalho envolveu a comparação entre dois modelos, *Long Short-Term Memory* (LSTM) e *Gated Recurrent Unit* (GRU), ambos redes neurais recorrentes de aprendizado profundo, para avaliar a capacidade de previsão em uma série de dados temporais de pessoas contaminadas ou mortas dentro do município de Botucatu, interior do Estado de SP. Os dois modelos testados demonstraram bons resultados, compatíveis com a literatura científica disponível sobre redes neurais na detecção da COVID-19, sendo que o modelo de GRU obteve a melhor performance, com o menor erro e menor tempo de treinamento. Em resumo, pode-se afirmar que o uso destes modelos poderiam ser ferramentas importantes para o estudo epidemiológico da doença enquanto auxiliariam o poder público local a traçar rotas efetivas para combater e minimizar os danos causados pela pandemia.

Palavras chaves: Aprendizado Profundo. Pandemia. Redes Neurais.

¹Discente do Curso de Análise e Desenvolvimento de Sistemas na Faculdade de Tecnologia de Botucatu, Av. José Ítalo Bacchi, s/nº; e-mail fabio.severino@fatec.sp.gov.br.

²Docente Doutor do Instituto de Biociências de Botucatu, Distrito de Rubião Júnior, s/n; e-mail jose.luiz@unesp.br.

³Docente Mestre na Faculdade de Tecnologia de Botucatu, Av. José Ítalo Bacchi, s/nº; e-mail vivian.gambarato@fatec.sp.gov.br.

ABSTRACT

COVID-19, caused by the SARS-CoV-2 virus, emerged in Hubei Province, China, in 2019, and rapidly evolved into a global pandemic, causing significant impacts across health, economic, and social systems worldwide. By August 2021, more than 200 million infections and over 4 million deaths had been reported globally. In Brazil, during the same period, more than 20 million confirmed cases and more than 500 thousand deaths were recorded, with 100% of cities reporting cases of infection. In the city of Botucatu, São Paulo state, thousands of cases and hundreds of deaths associated with COVID-19 were reported. During the pandemic, the use of technological tools for monitoring and predicting disease spread increased substantially. In this context, machine learning techniques have been widely applied to analyze epidemiological data and support decision-making processes. This study aimed to compare the performance of two deep learning models: Long Short-Term Memory (LSTM) and Gated Recurrent Unit (GRU), both based on recurrent neural network architectures for predicting COVID-19 cases and deaths using time-series data from the city. Both models demonstrated satisfactory predictive performance, consistent with the findings reported in the scientific literature on neural network applications for COVID-19 forecasting. However, the GRU model showed superior performance, presenting lower prediction error and the shorter training time. Results suggest machine learning approaches may represent valuable tools for epidemiological monitoring and forecasting, contributing to the development of more effective public health strategies and supporting local government decision-making during health emergencies.

Keywords: Deep Learning. Neural networks. Pandemic

.

¹Discente do Curso de Análise e Desenvolvimento de Sistemas na Faculdade de Tecnologia de Botucatu, Av. José Ítalo Bacchi, s/nº; e-mail fabio.severino@fatec.sp.gov.br.

²Docente Doutor do Instituto de Biociências de Botucatu, Distrito de Rubião Júnior, s/n; e-mail jose.luiz@unesp.br.

³Docente Mestre na Faculdade de Tecnologia de Botucatu, Av. José Ítalo Bacchi, s/nº; e-mail vivian.gambarato@fatec.sp.gov.br.

1 INTRODUÇÃO

A COVID-19, doença causada pelo vírus SARS-CoV-2, que imita o comportamento de uma pneumonia viral, provavelmente surgiu na província de Hubei, na China, em 2019, espalhando-se de forma global, causando grandes prejuízos de ordem econômica e de saúde para as pessoas (Aishwarya; KumaR, 2021). Mundialmente, até agosto de 2021, mais de 200 milhões de pessoas se contaminaram com o Coronavírus, e mais de 4 milhões de mortes foram relatadas, 2% dos casos positivos (Worldometers, 2021). No Brasil, no mesmo período, havia mais de 20 milhões de casos confirmados e mais de 560 mil óbitos (2,8% dos confirmados), com 100% dos municípios apresentando pessoas contaminadas e 99% deles com óbitos (Brasil.IO, 2021). Ainda segundo a mesma plataforma, o município de Botucatu apresenta milhares de pessoas que já foram contaminadas pelo vírus e mais de 300 óbitos acumulados.

Os modelos de aprendizado de máquina podem ser entendidos como a utilização de algoritmos estatísticos complexos executados em ambiente computacional, com o objetivo de simular o modo de aprendizado humano. Desse modo, é possível desenvolver ferramentas para resolver problemas de classificação, regressão, *clusterização*, entre outros (SOUZA FILHO *et al.*, 2020). De outro modo, pode-se dizer que hipóteses são geradas automaticamente pelos algoritmos de aprendizado de máquina a partir da ingestão de grandes volumes de dados (Ludermir, 2021).

As aplicações desses modelos são muito diversas e praticamente ilimitadas. Eles têm sido utilizados com sucesso na área da saúde há algum tempo, como exemplo pode-se citar diagnósticos médicos automáticos analisando imagens de tomografia, auxiliando o trabalho do médico (Ludermir, 2021). Também existem trabalhos com essa tecnologia aplicada no diagnóstico de diversos cânceres, diabetes tipo 2, doenças cardíacas e de pele, mal de Parkinson, entre tantas outras (Jayatilake; Ganegoda, 2020). Especificamente no caso da COVID-19, muitos modelos estão sendo utilizados para diagnóstico, tratamento e monitoramento de pacientes: para predição de mortalidade, recuperação e severidade dos sintomas (Tayarani, 2021).

Os algoritmos de redes neurais com aprendizado profundo (*Deep Learning*) demonstram grande importância na análise de dados e previsão de padrões a partir de grandes volumes de dados a respeito da infecção e adicionalmente eles apresentam potencial para interromper a taxa de propagação do coronavírus (Chimmula; Zhang, 2020). O uso dos dados de série temporal de COVID-19 mostrou-se viável para utilização em modelos de redes neurais de aprendizado

profundo como Unidade Recorrente com Portão (GRU) e memória de longo-curto prazo (LSTM) com o objetivo de predição do número de casos confirmados e mortos (Shahid; Zameer; Muneeb, 2020).

Adentrando na questão epidemiológica, segundo Tayarani (2021), prever a evolução da doença permitiria aos governos desenvolverem um planejamento estratégico no sistema público de saúde resultando na redução do número de óbitos. Ainda de acordo com o autor, entender o comportamento da doença e ter a capacidade de prever futuras ondas de infecção auxiliaria os governos a combater a pandemia de forma mais eficiente.

Diante desses fatos, o objetivo deste trabalho foi confrontar dois diferentes modelos de redes neurais de aprendizado profundo disponíveis, que teriam a capacidade de previsão do número de pessoas que poderão se contaminar com o SARS-CoV-2. Espera-se dessa maneira, que seja implementada de forma satisfatória uma ferramenta adicional de detecção precoce do número de pessoas que poderiam ser infectadas, a fim de auxiliar os pesquisadores a elucidar o processo de dispersão do vírus no município, ao mesmo tempo em que poderá auxiliar o poder público na elaboração de políticas e planejamentos mais eficientes para o enfrentamento da pandemia.

2 MATERIAL E MÉTODOS


As análises foram conduzidas no software de código aberto *Jupyter Notebook*, como interpretador da linguagem Python versão 3.9.7 e de suas bibliotecas, baseados no código, com adaptações, de Saldanha (2025). Os dados coletados permitiram, entre outras informações, as quantidades de casos confirmados acumulados (CCA) – total de pessoas que testaram positivo; casos novos diários (CND) – pessoas que testaram positivo por dia; casos de mortos acumulados (CMA) – total de pessoas cuja causa da morte foi atribuída a COVID-19 e casos de mortos diários (CMD) – pessoas que morreram devido à doença por dia. As variáveis analisadas foram: a variável independente data e uma das variáveis dependentes (alvos): CCA, CND, CMA e CMD, tomadas uma a uma.

Dados relativos à COVID-19 para o município de Botucatu/SP foram recolhidos do banco de dados da plataforma colaborativa Brasil.io, alimentado com dados oficiais advindos das secretarias estaduais de saúde, e abrange dados referentes ao período de 04/04/2020 a 30/09/2021 (Brasil.IO, 2021), totalizando 545 dias de coleta.

Inicialmente realizou-se um pré-processamento dos dados brutos do banco para avaliação e remoção de dados faltantes e atributos não utilizados neste artigo, foram utilizadas apenas variáveis quantitativas discretas. Os dados pré-processados, então, foram divididos em dois conjuntos, sendo um para casos confirmados acumulados e outro para casos novos diários de COVID-19, e analisados separadamente. Após essa divisão inicial, os conjuntos foram escalonados usando escala mín.-máx. dentro do intervalo [0, 1]. Na sequência, cada conjunto de dados foi dividido em duas partes: (80%) para realizar o treinamento do modelo e (20%) para o seu teste.

Durante o treinamento do modelo, foram realizados ajustes para otimização deste, enquanto o teste destinou-se a avaliação através de uma métrica adequada. A visualização do fluxo de trabalho proposto neste artigo encontra-se na Figura 1, abaixo.

Figura 1 – Diagrama do fluxo de trabalho e suas etapas para modelagem dos dados



Próprio Autor, 2025.

Os modelos apresentados neste trabalho foram comparados entre si utilizando-se a raiz quadrada média dos erros (RMSE) entre valores reais e os preditos (Figura 2), como principal métrica de avaliação.

Figura 2 – Fórmula matemática para cálculo do RMSE

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - \hat{y}_t)^2}$$

Fonte: Adaptado de ZEROUAL *et al.* (2020)

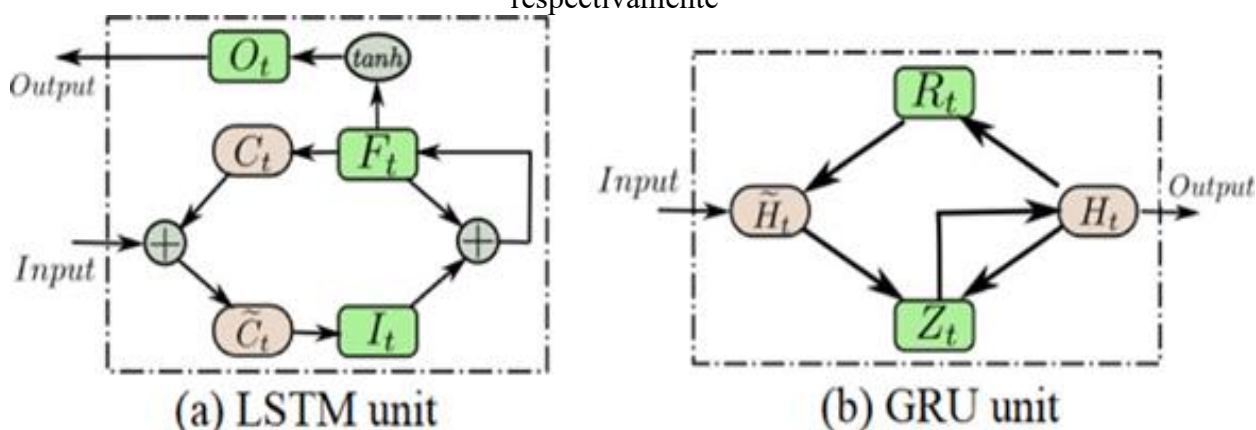
Após uma revisão na literatura disponível, optou-se pela escolha de dois modelos de redes neurais recorrentes com bons desempenhos para modelagem da série temporal dos dados de COVID-19 (Omran *et al.*, 2021; Elsheikh *et al.*, 2021).

Os modelos LSTM são formados por redes de unidades conectadas, sendo que cada uma dessas unidades são células de memória com portas (Hochreiter; Schmidhuber, 1997). O que a

diferencia de uma rede recorrente tradicional é que essas redes LSTM possuem a habilidade de reter informações por longos períodos no tempo. De acordo com Zeroual *et al.* (2020), cada unidade possui três portas (*Input*, *Forget* e *Output*) controladoras do fluxo de informações, essas portas representam funções logísticas de somas ponderadas; os pesos podem ser obtidos durante o treinamento. Segundo os mesmos autores, o estado da célula é gerenciado por meio das portas *Input* e *Forget*, a porta *Output* é responsável por fornecer a saída, ou seja, uma informação útil memorizada (FIGURA 3a). Desse modo, é possível que a rede seja capaz de memorização por um longo período, habilidade esta, muito oportuna quando se está trabalhando com séries temporais (Zeroual *et al.*, 2020).

Segundo Zeroual *et al.* (2020), o modelo GRU, embora com uma arquitetura mais simples que os modelos LSTM, apresenta um desempenho superior. Houve uma fusão entre as portas *Input* e *Forget* surgindo a porta *Update* (para cálculos de estado oculto) (FIGURA 3b), contando com mais uma porta, a *Reset*. Consoante, os mesmos autores afirmam que a porta *Update* é responsável por fornecer os dados memorizados enquanto a porta *Reset* pela combinação entre novas entradas e anteriores.

Figura 3 – Estrutura básica de uma unidade LSTM e GRU. **(a)** I_t , F_t , e O_t representam as três portas LSTM (*Input*, *Forget* e *Output* respectivamente), C e \tilde{C} representam as células de memória candidatas e o conteúdo da célula de memória. **(b)** R_t e Z_t são as portas *Reset* e *Update* respectivamente, H_t e \tilde{H}_t são o estado oculto candidato e o estado oculto, respectivamente



Fonte: Adaptado de ZEROUAL *et al.* (2020)

3 RESULTADOS E DISCUSSÃO

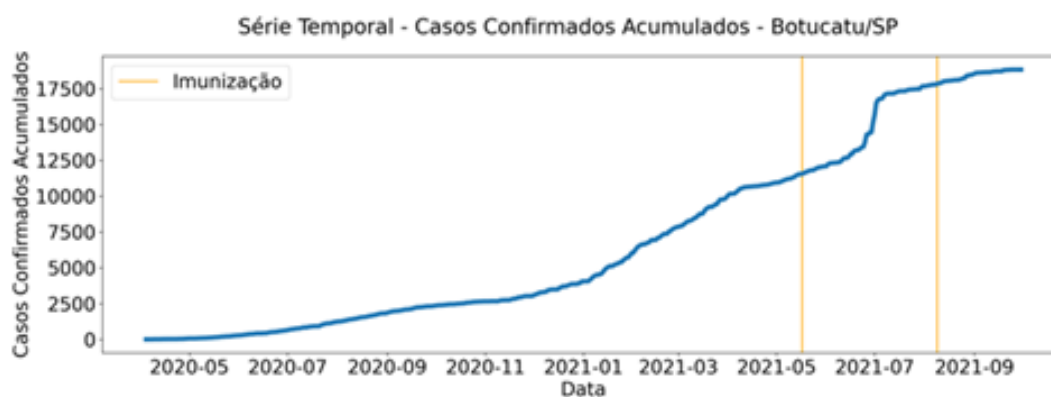
3.1 Descrição dos dados

Os dados coletados para o município de Botucatu-SP apontavam para uma população total de 18.828 pessoas infectadas e 324 mortas pela epidemia no período em estudo. Um aspecto que chama a atenção, observando-se a série histórica (FIGURA 4), é a elevação no número de casos de infectados após a primeira dose do projeto de vacinação em massa da pesquisa Universidade de Oxford, da farmacêutica AstraZeneca e do Ministério da Saúde entre outras entidades e órgãos públicos envolvidos. Uma possível explicação para o fato pode ser o relaxamento das medidas sanitárias de controle por parte da população devido à falsa sensação de segurança.

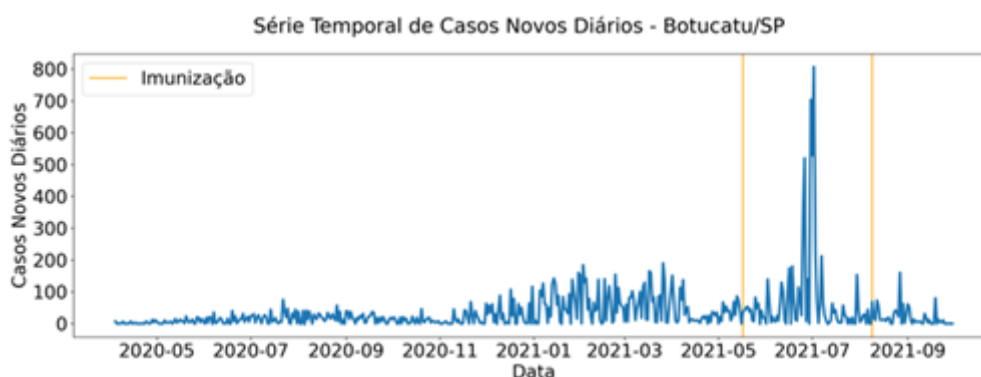
Observou-se pelos dados coletados que a infecção no município de Botucatu encontra-se em uma tendência de queda de acordo com as últimas dez médias móveis semanais para novos casos diários (15,00; 14,00; 14,57; 16,14; 16,14; 4,71; 4,71; 2,86; 2,14 e 1,57) e nenhuma pessoa testou positivo para contaminação nos últimos seis dias. Esses dados vêm demonstrando claramente o efeito da vacinação na população e corroborando a eficácia e segurança da vacina aplicada (Ghasemiyeh *et al.*, 2021).

Figura 4 – Gráficos para as séries temporais sobre a infecção de COVID-19 em Botucatu-SP. Em (a) casos confirmados acumulados e em (b) casos novos diários

a)



b)



Próprio Autor, 2025.

As linhas verticais amarelas representam as datas da imunização em massa do projeto de pesquisa sobre a eficácia da vacina COVID-19 da Astrazeneca/Oxford (Participantes da pesquisa: Ministério da Saúde, Fundação Oswaldo Cruz, Universidade de Oxford, Universidade Estadual Paulista, Universidade Federal de São Paulo, Fundação Bill e Melinda Gates e Prefeitura Municipal de Botucatu).

3.2 Modelos

Utilizou-se para os dois modelos, dentro deste estudo, a mesma configuração de hiperparâmetros: uma camada (*layer*) e taxa de aprendizado de 0,001 (*learning rate*), sendo que os demais melhores parâmetros ajustados para os modelos de redes neurais estão apresentados no Quadro 1 abaixo.

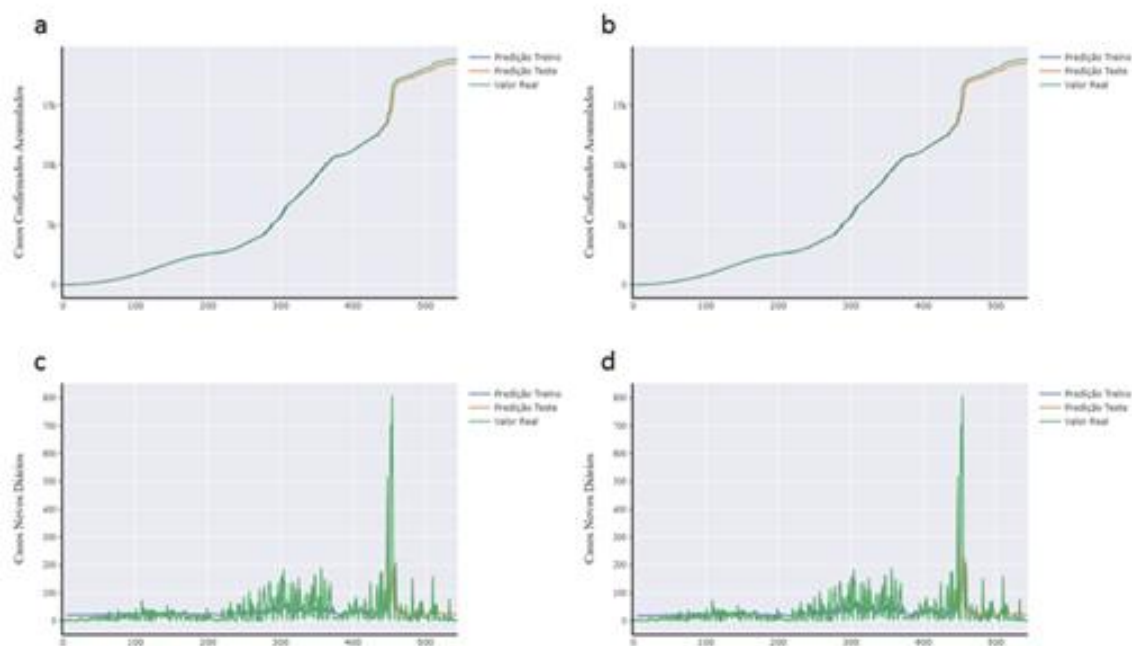
Quadro 1 – Melhores hiperparâmetros encontrados para os modelos

Alvos	Unidades na Dimensão Oculta	Número de Épocas
Casos Confirmados Acumulados	500	200
Casos Novos Diários	20	1.000
Casos de Mortos Acumulados	500	200
Casos de Mortos Diários	20	1.000

Próprio Autor, 2025.

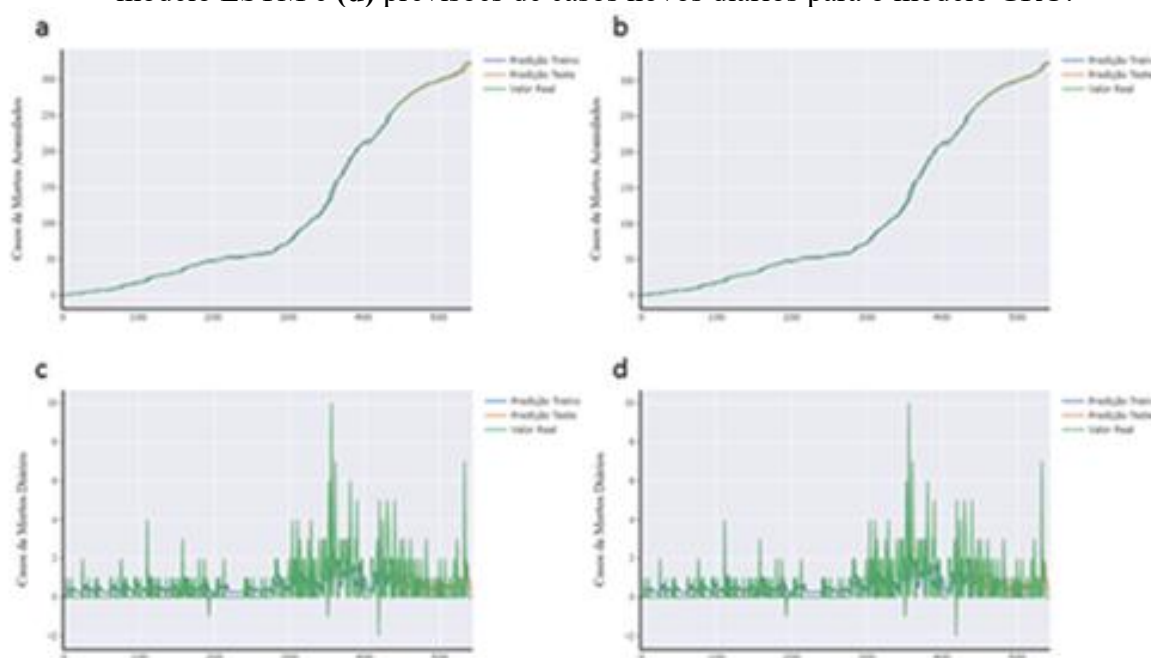
Os resultados apresentados por ambos os modelos podem ser considerados eficientes na previsão de casos para o conjunto de dados utilizados nos testes, como podem ser observados nas comparações das Figuras 5 e 6. Entre os dados preditos e os reais, nota-se claramente que os modelos são capazes de acompanhar a tendência da série temporal.

Figura 5 – Gráficos das previsões com o conjunto de dados sobre pessoas infectadas. Em **(a)** previsões de casos confirmados acumulados para o modelo LSTM, **(b)** previsões de casos confirmados acumulados para o modelo GRU, **(c)** previsões de casos novos diários para o modelo LSTM e **(d)** previsões de casos novos diários para o modelo GRU



Próprio Autor, 2025.

Figura 6 – Gráficos das previsões com o conjunto de dados sobre pessoas mortas. Em **(a)** previsões de casos confirmados acumulados para o modelo LSTM, **(b)** previsões de casos confirmados acumulados para o modelo GRU, **(c)** previsões de casos novos diários para o modelo LSTM e **(d)** previsões de casos novos diários para o modelo GRU.



Próprio Autor, 2025.

Avaliando-se o desempenho dos dois modelos, conclui-se que o modelo GRU tem um erro aproximadamente 33% menor que o modelo LSTM para o conjunto de dados de teste para os casos confirmados acumulados e um tempo de treino aproximadamente 17% menor. Para os casos de mortos acumulados, o modelo GRU apresenta um erro RMSE 35% menor que o modelo LSTM e um tempo de treino de aproximadamente 32% menor. Demonstra-se que para os cenários avaliados neste artigo, a maior variação no desempenho está relacionada ao uso de dados acumulados, quando se utiliza os dados diários, a variação na performance não é tão evidente em favor do modelo GRU.

Comparando os dois modelos pode-se afirmar que o melhor desempenho, neste conjunto de dados e para qualquer alvo, foi alcançado pela rede neural GRU, tanto em apresentar um erro RMSE menor quanto em realizar o treinamento do modelo em tempo reduzido, quando comparado ao modelo LSTM (Quadro 2), resultado que pode ser o inverso, a depender do conjunto de dados (tamanho, localização geográfica, tipo, etc.), da metodologia aplicada (divisão dos dados, configuração das redes neurais, etc.), entre outros fatores (Arunkumar, *et al.*, 2021; Ashutosh; Yash; Arpita, 2020; Zeroual *et al.*, 2020).

Quadro 2 – Comparativo entre os modelos LSTM e GRU

Alvos	LSTM		GRU	
	Erro de Teste (RMSE)	Tempo de Treino (s)	Erro de Teste (RMSE)	Tempo de Treino (s)
Casos Confirmados Acumulados	612,444232	117,944106	411,396004	97,956978
Casos Novos Diários	119,684567	13,948968	116,350062	12,257221
Casos de Mortos Acumulados	2,480595	154,526633	1,627742	105,480204
Casos de Mortos Diários	1,174530	15,630319	1,171349	13,531336

Próprio Autor, 2025.

4 CONCLUSÕES

Ao confrontar os resultados encontrados com a literatura recente sobre modelos de aprendizado de máquina aplicados a dados epidemiológicos de COVID-19, pode-se afirmar que ambos os modelos apresentaram bons resultados e poderiam ser utilizados para prever o número de pessoas contaminadas e/ou mortas pela infecção no conjunto de dados disponíveis para o município de Botucatu/SP. Deste modo, ajudando o poder público local a traçar medidas mais efetivas de combate à pandemia e fornecendo mais uma ferramenta capaz de auxiliar pesquisadores a entender o processo de disseminação do vírus.

REFERÊNCIAS

AISHWARYA, T.; KUMAR V. R. Machine Learning and Deep Learning Approaches to Analyze and Detect COVID-19: A Review. **SN Computer Science**, v. 2, n.3, p. 226 – 234, apr. 2021. Disponível em: <https://link.springer.com/article/10.1007/s42979-021-00605-9>. Acesso em: 27 ago. 2021.

ARUNKUMAR, K. E. *et al.* Forecasting of COVID-19 using deep layer Recurrent Neural Networks (RNNs) with Gated Recurrent Units (GRUs) and Long Short-Term Memory (LSTM) cells. **Chaos, solitons, and fractals**. v.146, p.110861, may 2021. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/33746373/>. Acesso em: 13 out. 2021.

ASHUTOSH, A.; YASH, L.; ARPITA, R. Forecasting COVID-19 Transmission in India Using Deep Learning Models. **Letters in Applied NanoBioScience**. v.10, n.2, p.2044 – 2055, oct. 2020. Disponível em: <https://nanobioletters.com/wp-content/uploads/2020/10/22846808102.20442055.pdf>. Acesso em: 13 out. 2021.

BRASIL.IO. **ESPECIAL COVID-19** - Dados por Município. Disponível em: <https://brasil.io/covid19/>. Acesso em: 13 ago. 2021.

CHIMMULA, V. K. R.; ZHANG, L. Time series forecasting of COVID-19 transmission in Canada using LSTM networks. **Chaos, Solitons, Fractals**, v.135, p.109864-109864, may 2020. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/32390691/>. Acesso em: 15 set. 2021.

ELSHEIKH, A. H. *et al.* Deep learning-based forecasting model for COVID-19 outbreak in Saudi Arabia. **Process Saf Environ Prot.** v. 49, p. 223–233, may 2021. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7604086/>. Acesso em: 29 set. 2021.

GHASEMIYEH, P. *et al.* A focused review on technologies, mechanisms, safety, and efficacy of available COVID-19 vaccines. **International immunopharmacology.** v. 100, p.108162. sep. 2021. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC8445802/>. Acesso em: 10 out. 2021.

HOCHREITER, S.; SCHMIDHUBER, J. Long Short-Term Memory. **Neural Comput.** v.9, n.8, p. 1735–1780, nov. 1997. Disponível em: <https://direct.mit.edu/neco/article/9/8/1735/6109/Long-Short-Term-Memory>. Acesso em: 27 set. 2021.

JAYATILAKE, S. M. D. A. C.; GANEGODA, G. U. Involvement of Machine Learning Tools in Healthcare Decision Making. **J. Healthc. Eng.**, v. 2021, p. 20, jan. 2021. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/33575021/>. Acesso em: 08 set. 2021.

LUDERMIR, T.B. Inteligência Artificial e Aprendizado de Máquina: estado atual e tendências. **Estudos Avançados**, v. 35(101), p. 85-94 2021, Jan-Apr 2021. Disponível em: <https://www.scielo.br/j/ea/a/wXBdv8yHBV9xHz8qG5RCgZd/>. Acesso em: 08 set. 2021.

OMRAN, N. F. *et al.* Applying Deep Learning Methods on Time-Series Data for Forecasting COVID-19 in Egypt, Kuwait, and Saudi Arabia. **Complexity.** v. 2021, p. 1-13, mar. 2021. Disponível em: <https://www.hindawi.com/journals/complexity/2021/6686745/>. Acesso em: 29 set. 2021.

SALDANHA, R. **GITHUB.** Disponível em: <https://github.com/RodolfoLSS/stock-prediction-pytorch/blob/master/stock-prediction-pytorch.ipynb>. Acesso em 26/08/2025.

SHAHID, F.; ZAMEER, A.; MUNEEB, M. Predictions for COVID-19 with deep learning models of LSTM, GRU and Bi-LSTM. **Chaos Solitons Fractals**, v. 140, p. 110212–110220, aug. 2020. Disponível em: https://www.researchgate.net/publication/343755747_Predictions_for_COVID-19_with_deep_learning_models_of_LSTM_GRU_and_Bi-LSTM. Acesso em: 27 ago. 2021.

SOUZA FILHO, E. M. *et al.* Inteligência Artificial em Cardiologia: Conceitos, Ferramentas e Desafios – “Quem Corre é o Cavalo, Você Precisa ser o Jôquei” **Arq. Bras. Cardiol.** v. 114 (4), p. 1-8, abr. 2020. Disponível em: <https://www.scielo.br/j/abc/a/NdvtBXhFLXJGpbZS6vgTzfS/?lang=pt>. Acesso em: 27 ago. 2021.

TAYARANI, N. M. H. Applications of artificial intelligence in battling against covid-19: A literature review. **Chaos Solitons Fractals.** v. 142, p. 31, jan. 2021. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7532790/>. Acesso em: 08 ago. 2021.

WORLDMETERS. **Worldometers-COVID-19 Coronavirus Pandemic**. Disponível em: <https://www.worldometers.info/coronavirus/>. Acesso em: 13 ago. 2021.

ZEROUAL, A. *et al.* Deep learning methods for forecasting COVID-19 time-Series data: A Comparative study. **Chaos Solitons Fractals**. v.140, p.110121, jul. 2020. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7362800/>. Acesso em: 27 set. 2021.