

Redes Convolucionais Temporais para Previsão de Séries Epidemiológicas de COVID-19 no Período Pós-Pandêmico

Rafaella S. Ferreira¹, Wallace Casaca¹, Giovana A. Benvenuto¹

¹Instituto de Biociências, Letras e Ciências Exatas
Departamento de Ciências de Computação e Estatística
Universidade Estadual Paulista (UNESP) – São José do Rio Preto, SP – Brasil
{rafaella.ferreira, wallace.casaca, giovana.a.benvenuto}@unesp.br

Abstract. *Forecasting COVID-19 time series remains challenging in the post-pandemic period due to reduced testing, underreporting and regime shifts. This paper evaluates Temporal Convolutional Networks (TCN) for long-term forecasting of COVID-19 cases in New York City and Brazil under a unified protocol. The TCN is compared with LSTM, RNN, ARIMA and SARIMA using MAE, RMSE, MAPE and R^2 . Results show better performance for New York, while the Brazilian series remains more challenging due to higher irregularity and possible underreporting. The optimized TCN achieves the best overall performance and low inference cost, supporting its potential use in epidemiological monitoring.*

Resumo. *A previsão de séries temporais de COVID-19 permanece desafiadora no período pós-pandêmico devido à redução da testagem, subnotificação e quebras de regime. Este trabalho avalia Temporal Convolutional Networks (TCN) para previsão de longo prazo de casos em Nova York e no Brasil, sob um protocolo experimental unificado. A TCN é comparada com LSTM, RNN, ARIMA e SARIMA usando MAE, RMSE, MAPE e R^2 . Os resultados indicam melhor desempenho em Nova York, enquanto a série brasileira apresenta maior dificuldade devido à irregularidade e possível subnotificação. A TCN otimizada obteve o melhor desempenho geral e baixo custo de inferência, indicando potencial para monitoramento epidemiológico.*

1. Introdução

A COVID-19, causada pelo vírus SARS-CoV-2, emergiu no final de 2019 e rapidamente evoluiu para uma crise sanitária global, sendo declarada pandemia em março de 2020. Desde então, a modelagem matemática e computacional tem desempenhado papel central no entendimento da dinâmica epidêmica e no apoio à tomada de decisão, incluindo a avaliação de intervenções não farmacológicas e seus efeitos sobre a transmissão [Flaxman et al. 2020, Dehning et al. 2020, Chinazzi et al. 2020].

Em paralelo, abordagens baseadas em inteligência artificial, particularmente redes neurais profundas, foram amplamente exploradas para previsão de casos e óbitos e para extração de padrões em séries temporais [Arora et al. 2020, Shastri et al. 2021]. Nesse contexto, arquiteturas recorrentes como LSTM destacam-se por modelar dependências temporais de longo alcance [Hochreiter and Schmidhuber 1997]; entretanto, por realizarem processamento temporal de forma intrinsecamente sequencial, podem

apresentar custo de treinamento mais elevado e menor flexibilidade para re-treinamentos frequentes, aspecto relevante em cenários operacionais com restrições computacionais [Arora et al. 2020, Shastri et al. 2021].

LINHA DO TEMPO DA COVID-19



Figura 1. Linha do tempo da pandemia de COVID-19 com eventos-chave.

Fonte: Elaborado pelos autores.

A previsão de novas ondas da doença também é marcada por não-estacionaridade e quebras de regime, associadas, por exemplo, à emergência e substituição de variantes de preocupação, que alteram padrões de transmissão e o formato das curvas epidêmicas [Ferreira et al. 2025]. Esse desafio é agravado por alterações no processo de monitoramento do vírus a partir de 2022, com redução progressiva da testagem e da notificação, resultando em maior subnotificação, aumento do ruído estatístico e deterioração da qualidade informacional das séries temporais utilizadas para vigilância epidemiológica [Oliveira 2024, Mendes 2024, Capomaccio 2024]. Soma-se a isso a ocorrência recorrente de novas ondas de infecção associadas ao surgimento de novas variantes do vírus, o que demonstra que a dinâmica de transmissão ainda não se estabilizou em um padrão sazonal claramente definido. Diferentemente de doenças respiratórias como a gripe, cuja sazonalidade é relativamente previsível em diversos contextos geográficos, a COVID-19 tem apresentado comportamento irregular, com picos influenciados por fatores imunológicos e, sobretudo, pela competição viral [Suntronwong et al. 2025, Masoorian et al. 2025]. Esse quadro reforça a necessidade de manutenção da vigilância epidemiológica e genômica, especialmente diante da emergência de novas variantes, evidenciando a importância dos modelos preditivos na tarefa de operar sob alta incerteza, escassez de dados e troca recorrente de variantes. Para contextualizar a transição para a fase atual da doença, a Figura 1 apresenta uma linha do tempo com eventos-chave da pandemia.

Diante desse contexto, este trabalho investiga a viabilidade e o desempenho de *Temporal Convolutional Networks* (TCN) para previsão de séries temporais de COVID-19 no período pós-pandêmico, comparando seu desempenho com técnicas do estado-da-arte em dois cenários com perfis distintos de qualidade e estabilidade dos dados (Nova

York e Brasil). Adicionalmente, discute-se o custo computacional associado aos modelos TCN, com foco em requisitos práticos de implantação e re-treinamento em sistemas de monitoramento [Bai et al. 2018, Lea et al. 2017].

2. Trabalhos Relacionados

A previsão de séries epidemiológicas de COVID-19 tem sido abordada por modelos estatísticos e, de forma crescente, por arquiteturas de aprendizado profundo, com destaque para redes recorrentes e propostas híbridas que combinam decomposição/filtragem de sinal, modelos lineares e redes neurais para lidar com ruído, não-estacionaridade e mudanças de regime [Arora et al. 2020, Shastri et al. 2021, Jin et al. 2022, de Souza et al. 2023, Khan et al. 2022]. Em especial, abordagens híbridas têm sido exploradas para estabilizar o sinal e melhorar previsões de curto prazo por meio da integração entre decomposição empírica e modelos preditivos [Khan et al. 2022].

No que diz respeito especificamente às *Temporal Convolutional Networks* (TCNs), embora sejam reconhecidas como alternativas competitivas para modelagem de sequências em tarefas gerais de *sequence modeling* [Bai et al. 2018, Lea et al. 2017], a literatura aplicada à previsão epidemiológica, sobretudo da COVID-19, ainda é relativamente limitada e frequentemente recorre a pipelines compostos, dificultando isolar a contribuição da TCN no desempenho final [Jin et al. 2022, de Souza et al. 2023]. Jin et al. [Jin et al. 2022] investigam uma técnica *ensemble* que combina TCN com outras redes neurais e componentes de correção de erro, com validação em séries nacionais do Reino Unido, Índia e Estados Unidos. No contexto brasileiro, Souza et al. [de Souza et al. 2023] avaliam múltiplas arquiteturas profundas, incluindo a TCN, para a predição de casos e óbitos no estado do Pará, e empregam a técnica estatística ARIMA como pós-processamento para ajuste de resíduos. Complementarmente, Khan et al. [Khan et al. 2022] propõem um método híbrido que integra decomposição empírica e modelagem sazonal para previsão de curto prazo, embora sem empregar TCN.

Em síntese, os trabalhos reportados indicam resultados promissores, mas ainda carecem de avaliações sistemáticas, comparáveis e reprodutíveis de TCNs, particularmente no contexto pós-pandêmico, caracterizado por quebras de regime e heterogeneidade na qualidade dos dados, lacuna que fundamenta a investigação desenvolvida neste estudo [Jin et al. 2022, de Souza et al. 2023, Bai et al. 2018].

3. Materiais e Métodos

Esta seção apresenta as fontes de dados, o pré-processamento, a construção das sequências supervisionadas e a configuração experimental dos modelos.

3.1. Dados e preparação

Foram integradas séries temporais de três repositórios abertos: (i) Painel Coronavírus (Ministério da Saúde) para o Brasil (<https://covid.saude.gov.br>, acesso em 10/02/2026), (ii) GISAID para sinais associados à circulação de variantes (<https://gisaid.org>, acesso em 10/02/2026) e (iii) NYC DOHMH para dados oficiais de COVID-19 em Nova York (<https://www.nyc.gov/site/doh/covid/covid-19-data-totals.page>, acesso em 10/02/2026). Após a coleta, foram aplicados procedimentos de limpeza e alinhamento temporal (tratamento de ausências, duplicidades e lacunas), seguidos de suavização por média móvel para atenuar ruído de alta

frequência e estabilizar o sinal, especialmente no caso brasileiro, caracterizado por maior irregularidade e ocorrência de valores anômalos nos registros. A normalização/reescala foi ajustada apenas no conjunto de treinamento para evitar *data leakage*. As Figuras 2 e 3 mostram o efeito da suavização, e as Figuras 4 e 5 as variáveis de entrada do modelo.




Figura 2. Casos em Nova York antes e após a aplicação da média móvel.




Figura 3. Casos no Brasil antes e após a aplicação da média móvel.

Visualmente, as séries apresentam comportamento não estacionário, com mudanças de nível, picos epidêmicos e redução gradual da magnitude dos casos ao longo do período. A série de Nova York apresenta maior regularidade e granularidade diária, enquanto a série brasileira exibe maior ruído, agregação semanal e oscilações abruptas, indicando diferenças estruturais relevantes para o desempenho dos modelos.




Figura 4. Variáveis de entrada (variantes da COVID-19), caso Brasil.




Figura 5. Variáveis de entrada (variantes da COVID-19), caso Nova York.

As séries foram convertidas para o formato supervisionado por janelas deslizantes: para cada instante t , a entrada consiste em um histórico de tamanho W de variantes da doença, e o alvo ao número de casos sob um horizonte de previsão H . Esse procedimento padroniza as entradas e viabiliza o uso de redes neurais como regressores temporais.

A escolha do período 2022–2025 deve-se ao interesse em avaliar a previsão no cenário pós-pandêmico, caracterizado por redução da testagem, maior subnotificação e mudanças nos padrões de circulação viral. Embora os anos iniciais da pandemia apresentem dinâmicas abruptas relevantes, eles refletem um regime epidemiológico distinto, fortemente influenciado por intervenções emergenciais, ausência inicial de vacinação e mudanças intensas de políticas públicas.

3.2. Modelo e protocolo experimental

A arquitetura principal avaliada neste trabalho é a *Temporal Convolutional Network* (TCN), implementada com convoluções 1D causais e dilatadas, e regularizada

via *dropout*, permitindo ampliar o campo receptivo e capturar dependências temporais em múltiplas escalas com custo computacional controlado [Bai et al. 2018, Lea et al. 2017]. Como baselines de comparação, foram consideradas arquiteturas recorrentes clássicas, como RNN e LSTM [Hochreiter and Schmidhuber 1997, Lu et al. 2025, Krichen and Mihoub 2025, Hall and Rasheed 2025], bem como modelos estatísticos tradicionais de séries temporais, como ARIMA e SARIMA.

O treinamento e a seleção de hiperparâmetros seguiram o protocolo de [Ferreira et al. 2024, Ferreira et al. 2025], com otimização bayesiana para busca eficiente [Snoek et al. 2012, Snoek et al. 2015] e *early stopping* (*patience*=5) para reduzir custo computacional e prevenir sobreajuste [Keras Team 2026]. O conjunto de treinamento correspondeu a 80% dos dados, respeitando a ordem temporal, dos quais os 10% finais foram reservados para validação. Os 20% restantes foram mantidos isolados para teste, garantindo avaliação final em dados inéditos e posteriores ao período de treino.

O desempenho no teste dos modelos foi avaliado pelas métricas MAE, RMSE, MAPE e R^2 , capturando erros em escala absoluta e relativa, capacidade explicativa e desempenho em relação a outros modelos e técnicas de referência [Amaral et al. 2021]. As definições formais dessas métricas seguem as Equações (1) e (2).

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_i - \hat{Y}_i|, \quad RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2}, \quad (1)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{Y_i - \hat{Y}_i}{Y_i} \right| \times 100, \quad R^2 = 1 - \frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{\sum_{i=1}^n (Y_i - \bar{Y})^2}, \quad (2)$$

em que Y_i é o valor observado, $\hat{Y}_i$ o predito, $\bar{Y}$ a média observada e n o número de observações. Considerando que o MAPE pode superestimar o erro para valores próximos de zero, este deve ser analisado de forma conjunta com o MAE e RMSE.

4. Resultados e Discussão

Esta seção apresenta os principais resultados obtidos, organizados em análises qualitativas e quantitativas do desempenho dos modelos nos dois cenários considerados.

4.1. Resultados Qualitativos

A rede TCN foi avaliada nos cenários de Nova York e Brasil, considerando um horizonte de predição de termo prolongado. A Figura 6 apresenta os resultados para Nova York no período de 21/06/2024 a 22/03/2025, evidenciando que o modelo captura de forma consistente a tendência global da curva epidemiológica, mantendo alinhamento com os padrões de crescimento e declínio dos casos ao longo do tempo.

Já para o Brasil, conforme ilustrado na Figura 7, observa-se que o modelo acompanha parcialmente as flutuações da série temporal, reproduzindo de forma consistente a tendência geral de casos, embora com maior dispersão dos erros. A arquitetura TCN é capaz de capturar os padrões predominantes ao longo do tempo, refletindo variações semanais e mantendo a coerência das previsões em relação à dinâmica observada, mesmo frente à maior complexidade inerente à série brasileira.




Figura 6. Predição de casos para Nova York utilizando a rede TCN.




Figura 7. Predição de casos para o Brasil utilizando a rede TCN.

4.2. Resultados Quantitativos

A Tabela 1 apresenta as métricas de avaliação obtidas para ambos os cenários. Os resultados indicam desempenho substancialmente superior no dataset de Nova York, com $R^2 = 0,9421$, MAE de cerca de 30 casos e MAPE de 15,84%. Esse desempenho expressivo pode ser atribuído à granularidade diária dos dados, à cobertura ampla de testagem e à consistência do registro de casos, permitindo que o modelo capture com precisão as flutuações temporais presente nos dados. No caso brasileiro, o R^2 próximo de zero evidencia maior instabilidade da série, associada não apenas à agregação semanal dos dados, mas também à um menor nível de testagem, subnotificação e maior variabilidade regional nos registros divulgados. Apesar disso, ressalta-se que o MAPE de 27,75% sugere que o modelo ainda consegue identificar de forma satisfatória a tendência geral da evolução da doença, destacando a robustez da TCN frente a séries temporais ruidosas e incompletas.

No caso brasileiro, a agregação nacional pode mascarar padrões locais de transmissão, diferenças regionais de testagem e defasagens de notificação, dificultando a aprendizagem de padrões temporais consistentes. Assim, parte da diferença de desempenho pode estar associada não apenas ao modelo, mas também à granularidade e heterogeneidade estrutural dos dados.

Tabela 1. Métricas de avaliação para a rede TCN, casos Nova York e Brasil.

Métrica	Nova York	Brasil
MAE	30,40	752,82
RMSE	36,78	942,54
R^2	0,9421	0,0117
MAPE (%)	15,84	27,75

Ao comparar o modelo TCN contra técnicas do estado-da-arte, como LSTM, RNN, ARIMA e SARIMA (Tabela 2), observa-se um ganho de desempenho consistente da abordagem convolucional. No contexto de Nova York, a TCN otimizada (TCN-t) apresentou MAE de 30,40, enquanto versões recorrentes com configuração padrão registraram erros substancialmente maiores. Mesmo os modelos recorrentes com ajuste de hiperparâmetros não alcançaram o desempenho da TCN, cujo R^2 (0,9421) supera de forma expressiva os valores obtidos por LSTM e RNN. Já os modelos estatísticos ARIMA e SARIMA apresentaram desempenho significativamente inferior, com erros mais elevados e coeficientes de determinação próximos ou abaixo de zero, indicando baixa capacidade de capturar a dinâmica da série.

No cenário brasileiro, embora o desempenho absoluto seja mais modesto, a TCN mantém vantagem relativa. O MAE é reduzido em aproximadamente 60% em comparação às versões recorrentes padrão, e o R^2 ligeiramente positivo (0,0117) contrasta com os valores negativos observados para LSTM, RNN e modelos estatísticos, que se mostram inferiores a um preditor médio simples. Adicionalmente, a comparação entre versões padrão (-d), treinadas com configurações *default*, e as versões *tuned* (-t), resultantes da otimização bayesiana de hiperparâmetros, evidencia ganhos consistentes de desempenho, embora não seja suficiente para compensar integralmente as limitações impostas pela maior instabilidade da série brasileira.

Tabela 2. Comparação das métricas de avaliação dos modelos LSTM, RNN, TCN, ARIMA e SARIMA nos cenários de Nova York e Brasil.

Modelo	Nova York				Brasil			
	MAE	RMSE	R^2	MAPE (%)	MAE	RMSE	R^2	MAPE (%)
LSTM-d	83,79	95,97	0,5823	51,09	1877,53	2103,33	-3,9217	58,33
LSTM-t	51,98	58,90	0,8426	23,81	1009,85	1298,94	-0,8771	37,86
RNN-d	71,85	76,47	0,7348	33,86	2031,91	2242,22	-4,5931	64,04
RNN-t	77,84	97,14	0,5720	26,28	1183,51	1502,48	-1,5114	37,92
TCN-d	68,35	87,46	0,6725	47,96	2870,16	3014,12	-9,1069	95,33
TCN-t	30,40	36,78	0,9421	15,84	752,82	942,54	0,0117	27,75
ARIMA	114,80	145,76	-0,0018	57,84	9346,20	9828,07	-6,1208	295,73
SARIMA	861,83	892,50	-36,5578	446,98	25804,03	28857,16	-60,3905	873,75

4.3. Custo computacional da TCN

Além do ganho em acurácia observado, avaliou-se o custo computacional da TCN nos referidos cenários de estudo considerando a configuração final selecionada por otimização de hiperparâmetros, o número de parâmetros treináveis (como proxy de memória do modelo) e o tempo de inferência no conjunto de teste. Os experimentos foram executados em ambiente CPU, com uma máquina Intel Xeon 2,20 GHz, 12,67 GB de RAM.

Para Nova York, a melhor configuração empregou duas camadas convolucionais 1D com 128 filtros e *kernel* 2, *dropout* de 0,1 em ambas, seguida de uma camada densa com 32 unidades e taxa de aprendizado de $1,56 \times 10^{-4}$, totalizando 90.945 parâmetros treináveis (aproximadamente 355 KB). Nesse cenário, o tempo total de inferência no teste foi de 0,298 s, com média de 1,085 ms por amostra.

Para o Brasil, manteve-se a mesma largura convolucional (128 filtros; *kernel* 2), porém com regularização mais intensa na segunda camada (*dropout* 0,5) e camada densa maior (64 unidades), com taxa de aprendizado de $9,02 \times 10^{-3}$, resultando em 151.681 parâmetros treináveis (aprox. 592 KB). O tempo total de inferência no teste foi de 0,154 s, com 9,603 ms por amostra.

Esses resultados são compatíveis com o que é discutido na literatura sobre TCNs: o uso de convoluções causais e dilatadas permite ampliar o campo receptivo e capturar dependências temporais em múltiplas escalas sem crescimento proporcional do custo, favorecendo eficiência e estabilidade [Bai et al. 2018, Lea et al. 2017]. Assim, além de desempenho preditivo satisfatório, a TCN apresentou tamanho de modelo compacto ($\sim 10^5$ parâmetros) e inferência em milissegundos por amostra, sustentando sua aplicabilidade em cenários epidemiológicos pós-2022 com requisitos de retreinamento periódico e infraestrutura limitada.

5. Considerações Finais e Trabalhos Futuros

Este trabalho avaliou a viabilidade e o desempenho preditivo e computacional da arquitetura *Temporal Convolutional Networks* (TCN) para previsão de séries epidemiológicas de COVID-19 em dois cenários com perfis distintos de granularidade, qualidade e estabilidade de dados (Nova York e Brasil), no período pós-pandêmico marcado por redução da testagem e notificação de casos. A TCN foi comparada tanto com arquiteturas recorrentes já bem estabelecidas, como LSTM e RNN, bem como com técnicas estatísticas, incluindo o ARIMA e o SARIMA, sob mesmo protocolo experimental, incluindo otimização bayesiana de hiperparâmetros e avaliação em conjunto de teste independente.

Os resultados indicaram que a TCN otimizada apresentou melhor desempenho em ambos os cenários, com menores erros absolutos e maior capacidade de capturar tendências em comparação aos demais modelos. No cenário de Nova York, caracterizado por maior estabilidade da série, a TCN alcançou $R^2 = 0.9421$ e MAPE de 15,84%, enquanto a LSTM e RNN obtiveram R^2 de 0,5823 e 0,7348, respectivamente. Os modelos estatísticos ARIMA e SARIMA apresentaram coeficientes de determinação próximos ou inferiores a zero, com erros percentuais substancialmente mais elevados.

Cabe destacar que as predições realizadas correspondem a um horizonte de longo prazo (*long-term forecasting*), especialmente no caso de Nova York, que envolve um período temporal extenso. Na literatura, reconhece-se que previsões multi-

step tendem a apresentar maior acúmulo de erro, particularmente em arquiteturas recorrentes como RNN e LSTM, enquanto modelos convolucionais causais e dilatados, como a TCN, mostram maior estabilidade na captura de dependências de longo alcance [Zeng et al. 2023, Kong et al. 2025].

No cenário brasileiro, marcado por maior irregularidade, a TCN manteve vantagem relativa, com MAPE de 27,75% e menores erros percentuais, ao passo que os modelos LSTM, RNN, ARIMA e SARIMA exibiram erros relativos mais elevados, evidenciando menor capacidade de generalização frente à TCN.

Esses achados sugerem que arquiteturas baseadas em convoluções temporais resultam em desempenho potencialmente mais estável e generalizável em séries epidemiológicas heterogêneas. A menor dependência de estados ocultos recorrentes e o uso de convoluções causais e dilatadas parecem contribuir para maior estabilidade numérica e melhor captura de padrões multiescala, especialmente em cenários com ruído estrutural elevado e mudanças de regime. Além disso, a análise de custo computacional revelou que a TCN opera com modelos compactos (ordem de 10^5 parâmetros) e inferência em milissegundos por amostra, viabilizando retreinamentos frequentes e execução em infraestrutura limitada, requisitos relevantes para uso em monitoramento automatizado.

Como trabalhos futuros, sugere-se: (i) investigar mecanismos de atenção temporal integrados à TCN para melhorar a interpretabilidade e a captura de eventos abruptos; (ii) expandir a avaliação para outras regiões e doenças com perfis epidemiológicos distintos, fortalecendo as evidências de generalização; e (iii) implementar estratégias de *ensemble*, combinando a TCN com modelos compartimentais e explorando a complementaridade entre abordagens orientadas a dados e aquelas baseadas em conhecimento de domínio. Além disso, pretende-se incluir validação *cross-site*, experimentos repetidos com diferentes sementes, intervalos de confiança e baselines simples, como persistência e média móvel, a fim de avaliar de forma mais robusta a generalização dos modelos.

Agradecimentos

Este trabalho foi financiado pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) – Código de Financiamento 001, Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq – grant 305206/2024–9), e Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP – grants 2023/14427-8 e 2024/04492-0).

Referências

- Amaral, F., Casaca, W., Oishi, C. M., and Cuminato, J. A. (2021). Simulating immunization campaigns and vaccine protection against COVID-19 pandemic in Brazil. *IEEE Access*, 9:126011–126022.
- Arora, P., Kumar, D., and Bhatia, M. S. (2020). Forecasting of covid-19 spread using lstm and gru models. *Chaos, Solitons & Fractals*, 139:110030.
- Bai, S., Kolter, J. Z., and Koltun, V. (2018). An empirical evaluation of generic convolutional and recurrent networks for sequence modeling. *arXiv preprint arXiv:1803.01271*. Acesso em: 01 mar. 2026.
- Capomaccio, S. (2024). Casos de covid-19 registram aumento e vacinação ainda é importante. *Jornal da USP*.

- Chinazzi, M., Davis, J. T., Ajelli, M., et al. (2020). The effect of travel restrictions on the spread of the 2019 novel coronavirus (covid-19) outbreak. *Science*, 368(6489):395–400.
- de Souza, G. N., Mendes, A. G. B., Costa, J. d. S., Oliveira, M. d. S., Lima, P. V. C., et al. (2023). Deep learning framework for epidemiological forecasting: A study on covid-19 cases and deaths in the amazon state of par , brazil. *PLOS ONE*. Acesso em: 01 mar. 2026.
- Dehning, J., Zierenberg, J., Spitzner, F. P., et al. (2020). Inferring change points in the spread of covid-19 reveals the effectiveness of interventions. *Science*, 369(6500):eabb9789.
- Ferreira, R. S., Casaca, W., and Colnago, M. (2024). Aplica  o de redes de deep learning recurrent neural network, long short-term memory e gated recurrent unit na predi   o da covid-19 no cen  rio p s-vacina  o. In *Semin rio Integrado de Software e Hardware (SEMISH)*, pages 145–156. SBC.
- Ferreira, R. S., Colnago, M., and Casaca, W. (2025). Predictive and interpretable machine learning for covid-19 resurgences: the role of sars-cov-2 variants in the post-pandemic era. *BMC Infectious Diseases*.
- Flaxman, S., Mishra, S., Gandy, A., et al. (2020). Estimating the effects of non-pharmaceutical interventions on covid-19 in europe. *Nature*, 584(7820):257–261.
- Hall, T. and Rasheed, K. (2025). A survey of machine learning methods for time series prediction. *Applied Sciences*.
- Hochreiter, S. and Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8):1735–1780.
- Jin, W., Dong, S., Yu, C., and Luo, Q.-q. (2022). A data-driven hybrid ensemble ai model for covid-19 infection forecast using multiple neural networks and reinforced learning. *Computers in Biology and Medicine*. Acesso em: 01 mar. 2026.
- Keras Team (2026). Earlystopping. https://keras.io/api/callbacks/early_stopping/. Acesso em: 01 mar. 2026.
- Khan, D. M., Ali, M., Iqbal, N., Khalil, U., Aljohani, H. M., Alharthi, A. S., and Afify, A. Z. (2022). Short-term prediction of covid-19 using novel hybrid ensemble empirical mode decomposition and error trend seasonal model. *Frontiers in Public Health*. Acesso em: 01 mar. 2026.
- Kong, X., Chen, Z., Liu, W., Ning, K., Zhang, L., Muhammad Marier, S., Liu, Y., Chen, Y., and Xia, F. (2025). Deep learning for time series forecasting: a survey. *International Journal of Machine Learning and Cybernetics*, 16(7):5079–5112.
- Krichen, M. and Mihoub, A. (2025). Long short-term memory networks: A comprehensive survey. *AI*.
- Lea, C., Flynn, M. D., Vidal, R., Reiter, A., and Hager, G. D. (2017). Temporal convolutional networks for action segmentation and detection. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*. Acesso em: 01 mar. 2026.

- Lu, G., Ou, Y., Wang, Z., Qu, Y., Xia, Y., Tang, D., Kotenko, I., and Li, W. (2025). A survey of deep learning for time series forecasting: Theories, datasets, and state-of-the-art techniques. *Computers, Materials and Continua*, 85(2):2403–2441.
- Masoorian, E., Teimoori, A., Bakhtiari, S., Jalilian, F. A., Vosough, R. N., and Ansari, N. (2025). Post-covid-19 seasonality of influenza, respiratory syncytial virus, and sars-cov-2 among hospitalized children in western iran: A molecular surveillance study (2023–2024). *Journal of Epidemiology and Global Health*.
- Mendes, V. (2024). Por que covid-19 ainda mata tanta gente no brasil. BBC News Brasil.
- Oliveira, C. (2024). Controle sobre a covid-19 ainda é instável no país após quatro anos do 1º caso. Brasil de Fato.
- Shastri, S., Singh, K., Kumar, R., et al. (2021). Time series forecasting of covid-19 using deep learning models: India-usa comparative case study. *Chaos, Solitons & Fractals*, 140:110227.
- Snoek, J., Larochelle, H., and Adams, R. P. (2012). Practical bayesian optimization of machine learning algorithms. In *Advances in Neural Information Processing Systems*, volume 25. Curran Associates, Inc.
- Snoek, J., Rippel, O., Swersky, K., Kiros, R., Satish, N., Sundaram, N., Patwary, M., Prabhat, M., and Adams, R. (2015). Scalable bayesian optimization using deep neural networks. In *International conference on machine learning*, pages 2171–2180. PMLR.
- Suntronwong, N., Vichaiwattana, P., Puenpa, J., Pasittungkul, S., Aeemjinda, R., Wongsrisang, L., and Poovorawan, Y. (2025). Seasonal pattern and age-specific detection of eight respiratory viruses causing acute respiratory infection in 2024, bangkok, thailand. *Tropical Medicine and Infectious Disease*, 10(12):339.
- Zeng, A., Chen, M., Zhang, L., and Xu, Q. (2023). Are transformers effective for time series forecasting? In *Proceedings of the AAAI Conference on Artificial Intelligence*.