

Uso de Redes Neurais Recorrentes Para Predição de Doenças Isquêmicas do Coração Usando Séries Temporais

Davi Matos de Carvalho¹, Omar Andres Carmona Cortes²

¹Bacharelado em Sistemas de Informação – Instituto Federal do Maranhão (IFMA)
Av. Getúlio Vargas, 04, Monte Castelo – São Luis, MA, Brasil

davimatosc@hotmail.com

²Departamento de Computação (DComp) – Instituto Federal do Maranhão (IFMA)
Av. Getúlio Vargas, 04, Monte Castelo – São Luis, MA, Brasil

omar@ifma.edu.br

Abstract. *The present investigation aims to evaluate the efficiency of using recurrent neural networks to analyze a time series of deaths due to ischemic heart disease in the city of São Luís, Maranhão. It employs two models, LSTM, BiLSTM, and GRU, seeking to identify the combination of parameters that yields the best results. These RNNs are compared with the traditional ARIMA model in an experiment using k-fold. Results indicate that LSTM achieves an RMSE of 0.70, the BiLSTM of 0.45, and the GRU of 0.46, while ARIMA reaches a higher RMSE of 7.5.*

Resumo. *O presente trabalho tem como objetivo avaliar a eficiência do uso de redes neurais recorrentes para análise de séries temporais de óbitos por doenças isquêmicas do coração na cidade de São Luís do Maranhão, por meio de três modelos: LSTM, BiLSTM e GRU, buscando identificar a combinação de parâmetros que proporcione melhores resultados. As referidas RNNs são comparadas com o modelo tradicional ARIMA em um experimento usando k-fold. Resultados indica que a LSTM chega a um RMSE de 0,70, o BiLSTM de 0,45 e a GRU de 0.46, enquanto que ARIMA alcança um RSME de 7,5.*

1. Introdução

As doenças isquêmicas do coração são a principal causa de morte no mundo, segundo a Organização Mundial da Saúde, ocupando essa posição no ranking global de mortalidade desde 2000 até 2021 [World Health Organization 2024]. A previsão de eventos relacionados à saúde, como taxas de mortalidade e prevalência de doenças crônicas, é essencial para identificar ameaças à saúde pública, orientar políticas e otimizar o uso de recursos [Soyiri and Reidpath 2013].

Modelos preditivos têm sido amplamente aplicados na saúde para antecipar eventos e apoiar a tomada de decisão. No caso das doenças isquêmicas do coração, prever ocorrências como infarto e angina pode viabilizar medidas preventivas, reduzindo impactos e melhorando o atendimento. No entanto, a escolha do modelo preditivo adequado continua sendo um desafio.

Nesse contexto, este trabalho é um estudo compara o desempenho de três modelos preditivos: dois baseados em Redes Neurais Recorrentes (LSTM, BiLSTM e GRU) e

um modelo estatístico tradicional (ARIMA). A avaliação considera a capacidade de cada abordagem em modelar séries temporais e fornecer previsões acuradas, permitindo uma análise comparativa de suas vantagens e limitações.

2. Trabalhos Correlatos

A aplicação de modelos baseados em redes neurais recorrentes vem sendo empregado com intuito de solucionar problemas de sequências temporais, por meio da demonstração de seus resultados promissores comparando com modelos tradicionais de estatística e Aprendizagem de Máquina. Possuindo uma gama de estudos empregando modelos de séries temporais com Aprendizagem Profunda para investigar problemas de saúde pública em diferentes contextos e regiões [HYNDMAN and ATHANASOPOULOS 2018].

Um trabalho focado na avaliação de modelos de predição de séries temporais com base em dados da COVID-19 de dez países, analisando três variáveis: casos confirmados, casos recuperados e óbitos. A abordagem adotada dividiu os modelos em três categorias: estatística, utilizando o ARIMA; aprendizado de máquina, com o Support Vector Machine baseado em kernels polinomiais e Radial Basis Function (RBF); e aprendizagem profunda, focando nos modelos LSTM, GRU e Bidirectional Long Short-Term Memory (Bi-LSTM). Os resultados obtidos mostraram que, apesar de cada modelo apresentar vantagens e limitações, as Redes Neurais Recorrentes (RNNs), especialmente os modelos LSTM e GRU, demonstraram um desempenho superior em relação aos métodos tradicionais, como o ARIMA [SHAHID et al. 2020].

O estudo aborda uma solução baseada em aprendizagem profunda para predição de malária, uma doença que, apesar de seu atual status de risco de vida ser curável e evitável, em 2018 possuiu um grau não ignorável de incidência de óbitos no Brasil. Os modelos utilizados foram a LSTM e GRU, tendo resultados promissores durante a fase de teste, tendo melhor desempenho o modelo GRU na métrica RMSE. Concluindo que modelos de Aprendizagem Profunda possuem potencial para auxiliar governos e organizações de saúde para no planejamento e implementação de estratégias de controle de doenças [BARBOZA 2021].

Um estudo comparativo com Redes Neurais Recorrentes e modelos estatísticos tradicionais na predição de séries temporais com intuito de investigar a efetividade dos modelos em aproximar os resultados obtidos na computação de índices de variabilidade de frequência cardíaca e na previsão do volume de chamadas de emergência recebidas por um serviço de atendimento ao consumidor. O estudo também utilizou o uso de ajustes nos hiper parâmetros com intuito de identificar melhores combinações por meio de validação cruzada. Os resultados apontaram o melhor desempenho para modelos de Redes Neurais Profundas, por meio dos seguintes hiper parâmetros: otimizador, Adam; função de ativação, *sigmoid*; 15 épocas; número de neurônios, 32; e 2 camadas [CARVALHO 2023].

A revisão destes estudos permitiu uma visualização geral da aplicação de modelos de séries temporais para análise na área da saúde pública. No entanto, é válido ressaltar que poucos estudos desenvolveram modelos apropriados e precisos, questões importantes para assegurar previsões coerentes e imparciais de resultados na área de saúde.

3. Redes Neurais Recorrentes

As redes neurais recorrentes foram criadas para processar sequência de dados, como por exemplo, séries temporais, texto, áudio, entre outras, onde a ordem dos elementos é importante. Sua principal característica é possuir conexões recorrentes que permitem que informações sejam mantidas e reutilizadas ao longo do tempo. A equação básica de uma RNN é $h_t = \sigma(W_h \cdot h_{t-1} + W_x \cdot x_t + b)$, na qual σ é uma função de ativação, h_t é um estado oculto no tempo t , W_h são os pesos associados ao estado oculto anterior, W_x são os pesos associados à entrada atual e b é o bias. Em cada passo de tempo a RNN produz uma saída com base no estado oculto de acordo com $y_t = \sigma(W_y \cdot h_t + b_y)$. Assim, pode-se observar que as RNN possuem memória de curto prazo que podem ser usadas para tomar decisões. Por outro lado, não conseguem capturar dependências de longo prazo devido ou a explosão ou desaparecimento do gradiente.

Para resolver o problema de memória de longo prazo foram criadas as *Long Short-Term Memory* (LSTM), que usando três tipos de gates consegue decidir o que esquecer (*forget gate*), o que armazenar (*input gate*) e o que expor como saída (*output gate*). Adicionalmente, as LSTM possuem uma célula de memória que armazenam informações a longo prazo. A *Gated Recurrent Unit* (GRU) é uma simplificação das LSTM, possuindo um *reset gate* que controla a informação passada que deve ser esquecida e o *update gate* que decide quanto do estado anterior deve ser mantido. Uma variação das LSTM é a Bidirectional LSTM (BiLSTM), que processa os dados tanto na direção temporal direta quanto na reversa, permitindo à rede capturar dependências passadas e futuras da sequência. Esse mecanismo é especialmente útil para tarefas que exigem uma compreensão mais profunda do contexto temporal. Detalhes sobre essas redes podem ser vistos em [GOODFELLOW et al. 2016] e [Siarni-Namini et al. 2019].

4. Experimentos

4.1. Setup

Os experimentos foram realizados no Google Colab, utilizadas as bibliotecas NumPy, para operações numéricas, Pandas, para manipulação de dados, Scikit-learn, que oferece algoritmos de aprendizado de máquina; Matplotlib, para visualização gráfica; Statsmodels, para estimativas estatísticas; e Keras, para experimentação das RNN. No caso do ARIMA, foram ajustados os parâmetros p , d e q dentro de um intervalo limitado. Para as Redes Neurais Recorrentes (LSTM, BiLSTM e GRU), testaram-se diferentes quantidades de neurônios, funções de ativação e épocas. O otimizador RMSprop foi escolhido por apresentar o melhor desempenho nos experimentos conduzidos na monografia que serviu de base para este estudo. Adicionalmente, foram ajustados os seguintes hiper parâmetros via tentativa-e-erro: função de ativação = Softplus, 16 neurônios, time-step = 3 e épocas = 150.

4.2. Base de Dados e Pré-Processamento

O conjunto de dados utilizado refere-se à mortalidade por doenças isquêmicas do coração em São Luís do Maranhão, disponibilizado pelo Ministério da Saúde por meio do Sistema de Informação de Mortalidade (SIM), vinculado ao Departamento de Vigilância de Doenças Não Transmissíveis (DAENT). Os dados foram obtidos no seguinte endereço eletrônico: <https://svs.aids.gov>.

br/daent/centrais-de-conteudos/paineis-de-monitoramento/mortalidade/cid10/. Para a obtenção dos registros de janeiro de 2005 a dezembro de 2021, totalizando 204 entradas, foi necessária a aplicação de filtragem manual. Dado o foco na análise direta de séries temporais, o presente trabalho demandou uma etapa essencial de pré-processamento dos dados. Inicialmente, foram selecionadas as colunas de interesse: Mês, Ano e Casos de Óbitos, garantindo a extração das informações relevantes sem introduzir ruídos nos dados.

Em seguida, os dados foram divididos seguindo a abordagem tradicional de 80% para treinamento (164 registros) e 20% para teste (40 registros). Em uma etapa posterior, adotou-se a validação cruzada K-Fold para os modelos baseados em Redes Neurais Recorrentes, permitindo uma avaliação mais robusta ao testar diferentes subconjuntos de treinamento e teste como no trabalho de Carvalho (2023). O ARIMA, entretanto, permaneceu com a divisão fixa, pois o embaralhamento do K-Fold comprometeria a ordem temporal dos dados. Além disso, embora a normalização dos dados tenha sido aplicada na monografia, observou-se que sua remoção resultou em um desempenho superior. Por esse motivo, optou-se por não utilizá-la na versão final deste estudo.

4.3. Resultados

Os resultados são baseado na raiz do erro quadrático médio (RMSE) conforme Equação 1 que mede a diferença média entre os valores previstos e os reais, sendo uma métrica bastante aplicada em séries temporais. Além disso, utilizou-se o erro percentual absoluto médio (MAPE) como mostra a Equação 2, que expressa o erro da previsão em termos percentuais.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (1)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \times 100 \quad (2)$$

Os resultados apresentados nas Figuras 1, 2a, 2b e 2c demonstraram que os modelos de RRNs (LSTM, BiLSTM e GRU) apresentaram desempenho significativamente superior ao modelo estatístico ARIMA. O BiLSTM obteve o menor erro quadrático médio (RMSE = 0,45) e erro percentual absoluto médio (MAPE = 0,011), superando os demais modelos. O GRU ficou em segundo lugar (RMSE = 0,46, MAPE = 0,010), seguido pela LSTM (RMSE = 0,70, MAPE = 0,016), enquanto o ARIMA teve um desempenho consideravelmente inferior (RMSE = 7,5, MAPE = 0,11).

A análise das previsões mostrou que o ARIMA produziu estimativas suavizadas, sem capturar adequadamente as variações da série temporal, um problema comum em modelos estatísticos quando aplicados a dados complexos e com alta variabilidade. Em contrapartida, os modelos baseados em RRNs foram capazes de aprender padrões temporais mais complexos, refletindo melhor os picos e flutuações dos óbitos por doenças isquêmicas do coração. Dentre eles, o BiLSTM obteve o menor erro, indicando que a consideração de dependências bidirecionais permitiu uma modelagem mais precisa da série. O GRU apresentou um desempenho semelhante, enquanto a LSTM teve um erro

ligeiramente maior. Esses resultados reforçam a eficácia das RRNs na previsão de séries temporais médicas.




Figura 1. Resultado do Modelo ARIMA na Previsão de Doenças Isquêmicas

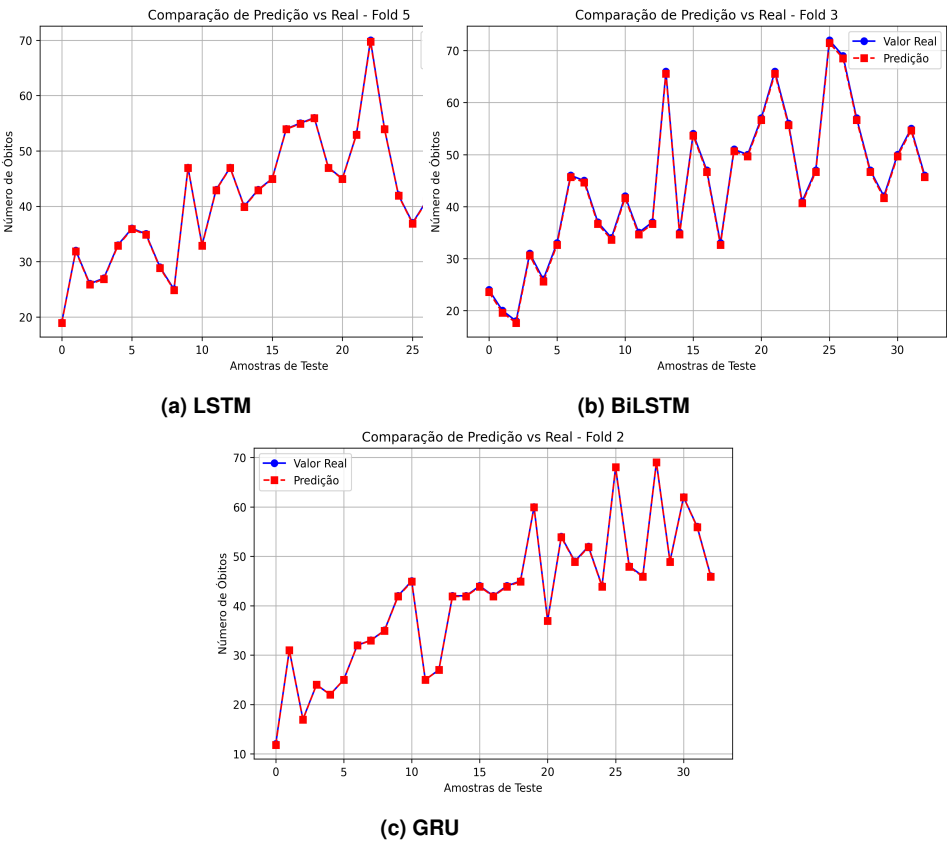


Figura 2. Comparação de Previsão dos Modelos LSTM, BiLSTM e GRU com $k = 5$

A superioridade do BiLSTM sobre os demais modelos pode estar relacionada à sua capacidade de processar informações em ambas as direções da sequência temporal, permitindo uma melhor captação de padrões e tendências nos dados. Além disso, a validação cruzada (k -fold) evidenciou que o BiLSTM obteve resultados mais consistentes nos diferentes subconjuntos de dados, destacando sua robustez em relação ao GRU e a LSTM. Esses achados reforçam a viabilidade de redes neurais recorrentes para aplicações em previsões epidemiológicas, podendo ser utilizadas para otimizar estratégias de alocação de recursos na saúde pública.

5. Conclusões

Este estudo comparou modelos de RNNs com um modelo estatístico convencional para a predição da mortalidade mensal causada por doenças isquêmicas do coração, utilizando dados de 2005 a 2021. Os resultados indicaram que o modelo BiLSTM apresentou o melhor desempenho em relação aos demais, como evidenciado nas Figuras 2a, 2b e 2c. Além disso, observou-se uma similaridade nos hiperparâmetros que proporcionaram bons resultados para os modelos de RNN, sendo utilizados os mesmos valores de ajuste para todos.

Embora o BiLSTM tenha apresentado a melhor performance, sua vantagem foi sutil em relação ao GRU e à LSTM, o que sugere que a bidirecionalidade pode não ter sido um fator determinante. Considerando a simplicidade do problema e a semelhança nos resultados entre os modelos, o uso do BiLSTM pode ser desnecessário devido ao seu maior custo computacional, tornando o GRU ou a LSTM opções eficientes para a predição. Adicionalmente, o estudo reforça a importância do uso de modelos de predição na saúde pública, pois fornecem evidências baseadas em séries temporais que podem auxiliar na otimização da assistência hospitalar na formulação de políticas públicas mais eficazes e na gestão de recursos. Não obstante, embora os resultados sejam promissores, dado o caráter crítico da previsão de mortalidade, diretamente relacionado à preservação de vidas humanas, é essencial aprimorar a acurácia e a capacidade adaptativa desses modelos. Assim, sugere-se para pesquisas futuras a incorporação de variáveis relacionadas a fatores de risco, como tabagismo, colesterol, diabetes, hipertensão arterial, má alimentação e sedentarismo, pois esses elementos influenciam diretamente a incidência de doenças isquêmicas do coração.

Referências

- BARBOZA, M. F. X. (2021). Análise e predição de incidência de casos de malária no tempo e no espaço utilizando modelos deep learning resumo estendido. CTDSI/CTCCSI.
- CARVALHO, D. L. d. (2023). *Aplicação de Redes Neurais Recorrentes para Previsão de Séries Temporais*. Tese (doutorado), Universidade Estadual da Paraíba, Campina Grande, PB.
- GOODFELLOW, I., BENGIO, Y., and COURVILLE, A. (2016). *Deep Learning*. MIT Press.
- HYNDMAN, R. J. and ATHANASOPOULOS, G. (2018). *Forecasting: Principles and Practice*. OTexts.
- SHAHID, F., KHAN, M., AHMED, M., ALI, M., REHMAN, M., and KHAN, M. (2020). Predictions for covid-19 with deep learning models of lstm, gru and bi-lstm. *Chaos, Solitons and Fractals*, 140:111178.
- Siarni-Namini, S., Tavakoli, N., and Namin, A. S. (2019). The performance of lstm and bilstm in forecasting time series. In *2019 IEEE International Conference on Big Data (Big Data)*, pages 3285–3292.
- Soyiri, I. N. and Reidpath, D. D. (2013). An overview of health forecasting. *Environmental Health and Preventive Medicine*, 18(1):1–9.
- World Health Organization (2024). The top 10 causes of death. Acesso em: 18 fev. 2025.