

Modelagem de Séries Temporais Biomédicas: Um Estudo Comparativo entre PSTA-TCN e TCN Vanilla para Previsão de Dados de Glicose de Pessoas Diabéticas

Miguel A. Santos¹, Áurea H. da S. Melo¹, J. S. dos Santos¹, I. C. M. Gonçalves¹, Waldeyde O. M. Santos¹, Luís Cuevas R.¹

¹Escola Superior de Tecnologia – Universidade do Estado do Amazonas (UEA)
Manaus – AM – Brasil

{maods.eng21, asmelo, jssantos, igoncalves,
wmagalhaes, lrodriguez}@uea.edu.br

Abstract. This study compares the performance of one-dimensional convolutional layer-based models, PSTA-TCN and Vanilla TCN (keras-tcn) in one-step-ahead prediction of glucose levels in diabetic participants. Continuous glucose and heart rate measurements were used as predictor variables, and the models were evaluated using metrics such as MAE, RMSE, and training time. Continuous heart rate and glucose data were collected from 20 diabetic volunteers over a period of 3 months. The results show that Vanilla TCN achieves lower predictive error, while PSTA-TCN presents higher computational efficiency.

Resumo. Este estudo compara o desempenho de modelos baseados em camadas convolucionais unidimensionais, PSTA-TCN e Vanilla TCN (keras-tcn) na previsão one-step-ahead dos níveis de glicose nos participantes diabéticos. Foram utilizadas medições contínuas de glicose e batimento cardíaco como variáveis preditoras, avaliando os modelos com métricas como MAE, RMSE e medindo o tempo de treinamento. Foram coletados dados contínuos de batimentos cardíacos e glicose de 20 voluntários diabéticos em um período de 3 meses. Os resultados mostram que o Vanilla TCN alcança menor erro preditivo, enquanto o PSTA-TCN apresenta maior eficiência computacional.

1. Introdução

Redes neurais convolucionais em uma dimensão têm ganhado espaço em previsão de séries temporais como uma alternativa mais leve às *recurrent neural networks* (RNNs) e às *Long-Short Term Memory* (LSTMs) apresentando um desempenho muito similar [Impedovo et al. 2024].

A PSTA-TCN (*Predictive Spatio-Temporal Attention Temporal Convolutional Network*) é uma arquitetura de rede neural projetada para capturar padrões complexos em dados espaço-temporais. Essa abordagem combina a robustez das *Time Convolutional Networks* (TCNs) na modelagem de dependências temporais de longo alcance com um mecanismo de atenção espaço-temporal preditivo, capaz de identificar automaticamente as regiões mais relevantes tanto no espaço quanto no tempo. Dessa forma, a PSTA-TCN otimiza a extração de características essenciais, tornando-se particularmente adequada para aplicações em cenários dinâmicos e multidimensionais.

O diferencial da PSTA-TCN reside no uso de um mecanismo de atenção preditivo que atribui pesos adaptativos às características mais importantes ao longo das dimensões

espaciais e temporais. Esse mecanismo permite que a rede priorize informações críticas, melhorando a capacidade de generalização em tarefas de previsão, trazendo precisão juntamente com eficiência [Fan et al. 2023].

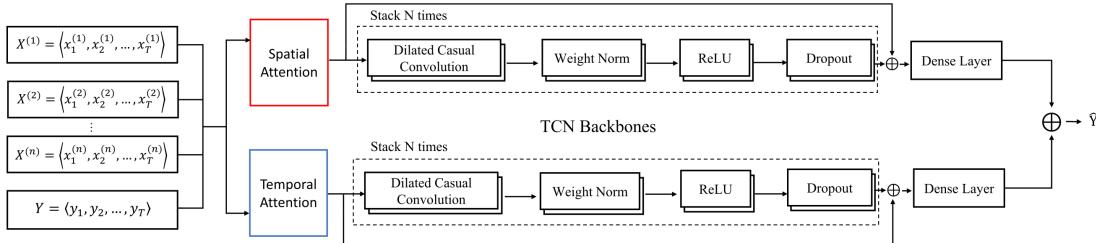


Figura 1. Arquitetura geral do modelo escolhido. Fonte: [Fan et al. 2023]

2. Trabalhos relacionados

Redes TCN têm sido utilizadas na modelagem de séries temporais em várias aplicações biomédicas, como a previsão de sinais fisiológicos, a detecção de anomalias cardíacas e o monitoramento contínuo de pessoas com diabetes. Elas são conhecidas por sua capacidade de capturar padrões temporais de longo alcance através da dilatação convolucional, tornando-as uma alternativa promissora às RNNs e LSTMs.

Um estudo conduzido por [Bai et al. 2018] analisou empiricamente a eficácia das redes convolucionais e recorrentes na modelagem de séries temporais. O estudo concluiu que TCNs são comparáveis a GRU *Gated Recurrent Unit* e LSTMs em diversas tarefas de previsão incluídas em benchmarks usadas para avaliar esses mesmos modelos de previsão, principalmente em problemas que exigem modelagem de longo prazo e treinamento eficiente. Apresenta também memória substancialmente mais longa, sendo útil em contextos onde a memória é mais requerida [Bai et al. 2018]. A pesquisa também reforçou a importância do uso de atenção e arquiteturas híbridas, alinhando-se com as melhorias propostas por [Fan et al. 2023]. [Bai et al. 2018].

O trabalho de [Fan et al. 2023] se destaca ao propor uma abordagem inovadora que combina atenção espaciotemporal com TCNs paralelas representada na Figura 1. Essa integração oferece um equilíbrio entre desempenho e eficiência, resolvendo desafios importantes e ampliando as possibilidades de aplicação de modelos preditivos em cenários complexos e de grande escala.

Essas descobertas reforçam a adoção das TCNs e suas variantes avançadas na análise de séries temporais biomédicas, demonstrando sua viabilidade como alternativa mais eficiente às arquiteturas tradicionais baseadas em recorrência.

3. Metodologia

O estudo foi conduzido por uma equipe composta por pesquisadores da área de saúde e de tecnologia. E foi realizado em conformidade com os princípios éticos estabelecidos para pesquisas com seres humanos e foi aprovado pelo Comitê de Ética em Pesquisa da Universidade do Estado do Amazonas. Todos os participantes foram informados sobre os objetivos da pesquisa, os procedimentos envolvidos e os possíveis riscos e benefícios, tendo assinado o Termo de Consentimento Livre e Esclarecido (TCLE) antes do início

da coleta de dados. Os dados foram obtidos a partir de um grupo de 20 voluntários diagnosticados com Diabetes Mellitus, acompanhados ao longo de um período de dois meses. Cada participante utilizou dispositivos de monitoramento contínuo de glicose e sensores de frequência cardíaca, possibilitando a captura de séries temporais de ambos os sinais fisiológicos. O estudo garantiu a privacidade e o anonimato dos participantes, seguindo as diretrizes da Lei Geral de Proteção de Dados (LGPD).

No estudo, foi realizada uma comparação entre dois modelos TCN para a previsão de níveis de glicose usando a série de glicose e batimentos cardíacos medidos continuamente. Foram escolhidos da literatura: TCN vanilla, obtido a partir da implementação de código aberto disponível na biblioteca *keras-tcn* [Bai et al. 2018], e o PSTA-TCN [Fan et al. 2023], que precisou ser implementado manualmente utilizando *TensorFlow* e *Keras*, uma vez que seu código-fonte não estava disponível publicamente.

3.1. Conjunto de Dados e Pré-processamento

Os dados utilizados consistem em medições contínuas de glicose e batimentos cardíacos dos 20 participantes. Esses sinais foram coletados com diferentes resoluções temporais:

- Glicose: medidas espaçadas de 15 minutos;
- Batimentos cardíacos: medidas espaçadas de 10 minutos.

Durante a análise inicial, foi identificado que os dados possuíam *janelas temporais faltantes*. Para o tratamento dessas lacunas, foram adotadas as seguintes estratégias:

1. Preenchimento do primeiro valor ausente dentro de cada janela com o *último valor disponível (forward fill)*, utilizando a função `fillna(method='ffill', limit=1)` da biblioteca *pandas*. [Xie and Wang 2020]
2. Imputação dos valores subsequentes utilizando um *filtro de Kalman*, trazendo uma reconstrução coerente da série temporal e suavizando possíveis ruídos nos dados. [Xie and Wang 2020]

Após a imputação, os dados foram *alinhados temporalmente* para garantir que cada amostra de batimento cardíaco correspondesse à amostra de glicose mais próxima. Para isso, foi aplicada reamostragem de timestamps, ajustando os valores para um intervalo regular:

- Glicose: timestamps aproximados para sequências espaçadas de exatos 15 minutos, por exemplo, 0, 15, 30 e 45 minutos;
- Batimentos cardíacos: timestamps arredondados para sequências espaçadas de exatos 10 minutos, por exemplo, 10, 20, 30, 40 e 50 minutos.
- Em ambos os casos, cada valor em minutos era aproximado para o múltiplo de 5 mais próximo (por exemplo 17 min se torna 15 min, 1 min se torna 0 min etc), isso ajudou a tratar a incerteza natural causada pelo arredondamento dos segundos a que os dados foram submetidos e evitou desalinhamento dos timestamps de suas posições originais ao longo do tempo.

Dado que a frequência das medições diferia entre as duas séries temporais, foi necessário um ajuste adicional para garantir o alinhamento entre elas. Observou-se que, para cada duas amostras de glicose, uma delas não correspondia diretamente a um valor presente na série de batimentos cardíacos. Para solucionar isso, os valores de glicose não diretamente observados foram substituídos pela média aritmética dos dois valores

de batimentos cardíacos mais próximos (um anterior e um posterior). Dessa forma, foi possível garantir que a série final de batimentos cardíacos estivesse perfeitamente alinhada com a série de glicose, ainda que com uma ligeira redução na quantidade de amostras disponíveis.

3.2. Modelos Utilizados

Foram implementadas e comparadas duas abordagens baseadas em Redes Temporais Convolucionais (TCN):

- TCN Vanilla: Implementado diretamente a partir da biblioteca keras-tcn, sem modificações estruturais.
- PSTA-TCN (*Parallel Spatiotemporal Attention TCN*): Implementado do zero em *TensorFlow* e *Keras*, combinando *atenção espaço-temporal* com convoluções temporais para melhorar a captura de padrões em séries temporais biomédicas.

3.3. Procedimento de Treinamento e Avaliação

Os modelos foram treinados para realizar previsões one-step-ahead e multi-step forecasting em um horizonte de seis valores futuros. Para avaliar a precisão das previsões, foram utilizadas as seguintes métricas:

- Erro Médio Absoluto (MAE): Mede a média dos erros absolutos entre valores previstos e reais.
- Raiz do Erro Quadrático Médio (RMSE): Penaliza erros maiores, fornecendo uma métrica mais sensível a variações.
- Erro Máximo (max_error): Mede a maior discrepância entre um valor previsto e seu valor real correspondente.

Para ambos os modelos, foram passadas séries temporais de comprimentos de 192 amostras (aproximadamente 2 dias seguidos amostrando glicose e batimento cardíaco) e era retornado um vetor de comprimento 1 (para one step ahead) ou 6 (para forecasting), que representam, respectivamente, previsões para 15 minutos à frente e 1 h e 30 min à frente.

4. Resultados

Nesta seção, apresentamos os resultados obtidos na comparação entre os modelos PSTA-TCN e TCN Vanilla, avaliando seu desempenho em tarefas de previsão de séries temporais de glicose, tendo como feature adicional o batimento cardíaco. A análise é baseada em métricas de erro, desempenho computacional e qualidade das previsões.

4.1. Comparação entre Modelos

A Tabela 1 apresenta os resultados da previsão *one-step-ahead* (*Output Forecast Size = 1*) para os dois modelos analisados. Os valores de erro indicam que o modelo TCN Vanilla obteve melhores métricas de erro (MAE, RMSE e Erro Máximo) em comparação ao modelo PSTA-TCN. Porém, o modelo PSTA-TCN apresentou um tempo de treinamento significativamente menor, sugerindo maior eficiência computacional.

Já a Tabela 2 apresenta os resultados da previsão *multi-step-ahead* (*Output Forecast Size = 6*). Nota-se que, para esse cenário, ambos os modelos apresentaram um

aumento significativo nos erros, o que é de se esperar considerando a maior dificuldade em prever valores mais distantes. O modelo PSTA-TCN teve um MAE superior ao TCN Vanilla, mas novamente apresentou um tempo de treinamento substancialmente menor. O modelo TCN Vanilla, embora tenha apresentado melhores métricas de erro, teve um tempo de treinamento cerca de 29 vezes maior, o que pode ser um fator limitante para aplicações em tempo real.

4.2. Discussão dos Resultados

Os experimentos realizados demonstram que, embora o TCN Vanilla apresente métricas de erro ligeiramente melhores, o PSTA-TCN se destaca pela eficiência computacional, com um tempo de treinamento significativamente menor. No cenário *multi-step-ahead*, a diferença de tempo de treinamento entre os modelos é ainda mais expressiva, tornando o PSTA-TCN uma opção viável para aplicações que exigem processamento em tempo real.

No geral, os resultados evidenciam que o PSTA-TCN pode ser uma alternativa competitiva ao TCN Vanilla, especialmente em cenários onde a eficiência computacional é um fator crítico. No entanto, melhorias podem ser implementadas para aprimorar sua capacidade preditiva, especialmente em previsões de longo prazo.

Métrica	PSTA-TCN	Vanilla TCN
MAE (mg/dl)	6,5667	4,9117
RMSE (mg/dl)	10,0408	8,4397
Max Error (mg/dl)	34,3676	31,4393
Epochs	378	415
Patience	80	80
Best Model in Epoch	298	335
Window Size	192	192
Convolutional Layers	4	4
Batch Size	128	128
Features	2	2
Output Forecast Size	1	1
Train Time (s)	1707,43	4431,42

Tabela 1. Comparação dos modelos PSTA-TCN e TCN Vanilla

Métrica	PSTA-TCN	Vanilla TCN
MAE (mg/dl)	16,9460	13,8379
RMSE (mg/dl)	25,4260	22,9376
Max Error (mg/dl)	105,7341	99,7839
Epochs	388	5000
Patience	120	500
Best Model in Epoch	268	4500
Window Size	192	192
Convolutional Layers	4	4
Batch Size	128	128
Features	2	2
Output Forecast Size	6	6
Train Time (s)	1838,30	53076,94

Tabela 2. Comparação dos modelos PSTA-TCN e Vanilla TCN

5. Conclusão

Este estudo realizou uma análise comparativa entre os modelos PSTA-TCN e TCN Vanilla na modelagem de séries temporais de glicose e batimento cardíaco, com foco na previsão de glicose usando essas duas características. A partir dos experimentos conduzidos, foi possível avaliar o desempenho dos modelos com diferentes configurações, analisando métricas de erro, eficiência computacional e impacto de hiperparâmetros na previsão.

Percebe-se que, no cenário one-step-ahead, o TCN Vanilla apresentou um erro médio absoluto inferior ao PSTA-TCN, sugerindo melhor precisão preditiva. No entanto, o PSTA-TCN demonstrou uma vantagem significativa no tempo de treinamento, sendo substancialmente mais eficiente computacionalmente. Essa diferença foi ainda mais evidente no cenário multi-step-ahead onde o tempo de treinamento do TCN Vanilla foi cerca de 29 vezes maior, tornando o PSTA-TCN uma alternativa viável para aplicações em tempo real.

A partir disso, pode-se concluir que a escolha do modelo ideal deve considerar um equilíbrio entre precisão preditiva e eficiência computacional. O PSTA-TCN se mostrou uma opção competitiva para aplicações que exigem previsão rápida, enquanto o TCN Vanilla pode ser mais adequado para contextos onde a exatidão preditiva é priorizada e o tempo de processamento não é uma restrição crítica.

Apesar disso, é uma meta para o futuro fazer um estudo com uma nova amostra de participantes, buscando um número maior de dados. Também se mostra interessante comparar os modelos usados neste estudo com outros altamente presentes na literatura, como arquiteturas baseadas em LSTM e GRU para atestar as vantagens e desvantagens de cada abordagem em diversas métricas.

6. Agradecimentos

Os autores agradecem o apoio financeiro e técnico do projeto DiaLog, patrocinado pela Samsung Eletrônica da Amazônia Ltda., com apoio da SUFRAMA (Lei nº 8.387/1991), e à Universidade do Estado do Amazonas, que viabilizaram este trabalho.

Referências

- 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*.
- Fan, J., Zhang, K., Huang, Y., Zhu, Y., and Chen, B. (2023). Parallel spatio-temporal attention-based tcn for multivariate time series prediction. *Neural Computing and Applications*, 35(18):13109–13118.
- Impedovo, D., Gattulli, V., Sarcinella, L., Veneto, D., Satalino, G., Balenzano, A., Longevigne, F., Albertini, C., Palmisano, D., Mattia, F., et al. (2024). A novel multi-speed dilated convolutional deep neural network architecture for meteorological forecasting. In *2024 IEEE International Humanitarian Technologies Conference (IHTC)*, pages 1–7. IEEE.
- Xie, J. and Wang, Q. (2020). Benchmarking machine learning algorithms on blood glucose prediction for type i diabetes in comparison with classical time-series models. *IEEE Transactions on Biomedical Engineering*, 67(11):3101–3124.