



Análise de Séries Temporais Usando Aprendizado Profundo e Dinâmica Não-Linear

Palavras-Chave: REDES NEURAIS, SÉRIES TEMPORAIS, ELETROCARDIOGRAMA

Autores/as:

PEDRO FRANCISCO GODOY BERNARDINELLI – IMECC, UNICAMP
Prof. Dr. JOÃO BATISTA FLORINDO (orientador(a)) – IMECC, UNICAMP

INTRODUÇÃO:

O aprendizado de máquinas e a inteligência artificial estão gradativamente se tornando cada vez mais preponderantes no contexto tecnológico atual. Ano após ano, são descobertas novas aplicações, modelos e técnicas que melhoram o desempenho de tais ferramentas. Uma dessas áreas é a classificação de séries temporais: ou seja, dada uma série temporal (uma sequência de valores que variam com o tempo) classificá-la em algumas categorias pré-determinadas.

Uma situação médica onde há um interesse em tal capacidade é a identificação de anomalias cardíacas a partir de um eletrocardiograma. Assim, uma melhoria no desempenho dos modelos atuais permitiria uma identificação mais rápida e precisa de anomalias cardíacas em pacientes, melhorando as possibilidades de tratamento para tais.

Para esse fim, o presente projeto propõe o estudo do desempenho de um novo modelo de *deep learning*, o qual junta três elementos: um modelo do estado-da-arte, N-BEATS; um mecanismo de auto-atenção e uma medida estatística da dependência de longo-prazo da série temporal, o expoente generalizado de Hurst (GHE).

METODOLOGIA:

EXPOENTE GENERALIZADO DE HURST: Medida derivada de estudos em dinâmica não linear que indica se há dependência estatística de longo prazo presente em uma série temporal. A dependência de longo prazo ocorre se o decaimento da autocorrelação de dois pontos da série temporal separados por intervalos de tempo cada vez maiores é mais lento do que uma exponencial. Em outras palavras, essa medida indica se os valores de uma série temporal são influenciados por valores que ocorreram em um passado mais remoto.

O cálculo desse expoente é feito por meio de mínimos quadrados, onde são passados um valor q , o qual indica com qual momento da distribuição dos incrementos da série temporal o expoente está relacionado e uma série temporal sobre a qual será calculado o valor do expoente.

MOMENTOS AMOSTRAIS: Medida estatística extremamente simples para realizar a comparação com o GHE. Trata-se, simplesmente, da média aritmética dos valores da série temporal elevados à potência q .

MECANISMO DE AUTO-ATENÇÃO: Intuitivamente, o mecanismo de auto-atenção é responsável por determinar quais partes dos dados o modelo deve prestar mais atenção para melhorar a predição do horizonte desejado. Assim, o mecanismo de atenção é responsável por definir pesos para cada parte da série temporal (ou outro conjunto de dados, como o GHE dos eletrocardiogramas), de acordo com a fórmula abaixo:

$$\text{Attention} = \text{softmax}\left(\frac{(AW_q)(AW_k)^T}{\sqrt{d_k}}\right)(AW_v).$$

Equação 1: Fórmula de uma head do mecanismo de auto-atenção. Cada W é uma matriz de pesos aprendidos diferentes e A é a matriz com os dados.

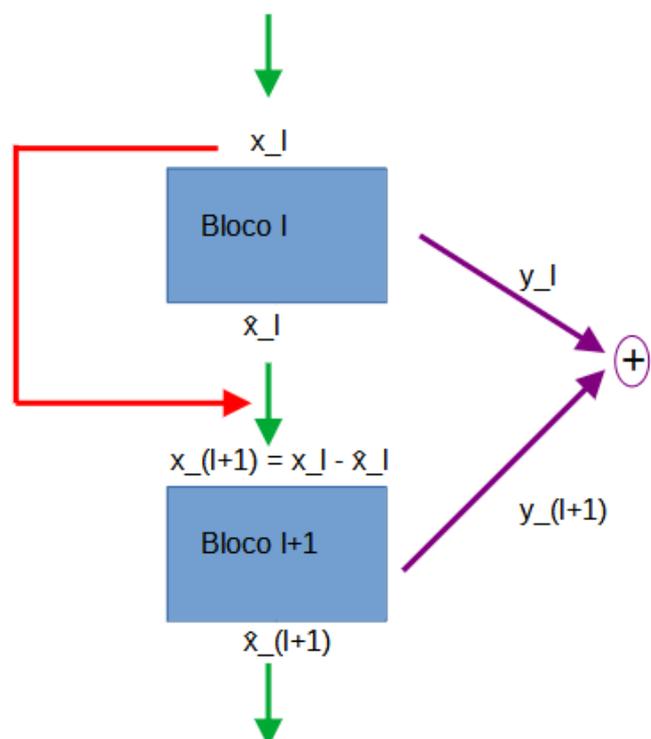
Na fórmula acima, A é a matriz dos dados passada como entrada para o mecanismo de atenção, W_q , W_k e W_v são matrizes com pesos a serem aprendidos durante o processo de treinamento e d_k é a dimensão de AW_k , softmax é uma função para transformar todos os valores em números entre 0 e 1.

N-BEATS (Neural Basis Expansion Analysis for Interpretable Time Series): Modelo do estado-da-arte criado para realizar a previsão de séries temporais, o qual foi adaptado para realizar a classificação de um eletrocardiograma, com base nele e no resultado do mecanismo de auto-atenção baseado no GHE.

A ideia básica do modelo N-BEATS pode ser visualizada no próximo diagrama:

O modelo consiste no empilhamento de diversos blocos residuais (blocos cuja entrada depende da entrada e da saída do bloco anterior).

Cada bloco é um mapeamento não-linear com camadas totalmente conectadas que devolve duas saídas distintas: uma saída que fará parte da predição final, y_l , e uma saída que será usada para compor a entrada do próximo bloco, \hat{x}_l .



Modelo proposto: Todos os elementos apresentados acima são as diversas partes que compõem o modelo proposto: inicialmente, é feito um pequeno tratamento dos dados: todas as *leads* de um eletrocardiograma são concatenadas e então é feito um *downsample* de 25 de cada um deles. Após isso, é calculado o GHE (ou o momento empírico ou qualquer outra medida estatística desejada) para cada *lead* para todos os exemplos e estes são armazenados em uma matriz. Essa matriz é utilizada como a entrada para um mecanismo de auto-atenção.

A saída do mecanismo de auto-atenção é concatenada com o eletrocardiograma concatenado e os dois juntos compõem a entrada de um modelo N-BEATS. Em todos os blocos do N-BEATS, a saída do mecanismo de auto-atenção é concatenada com a entrada de tal bloco.

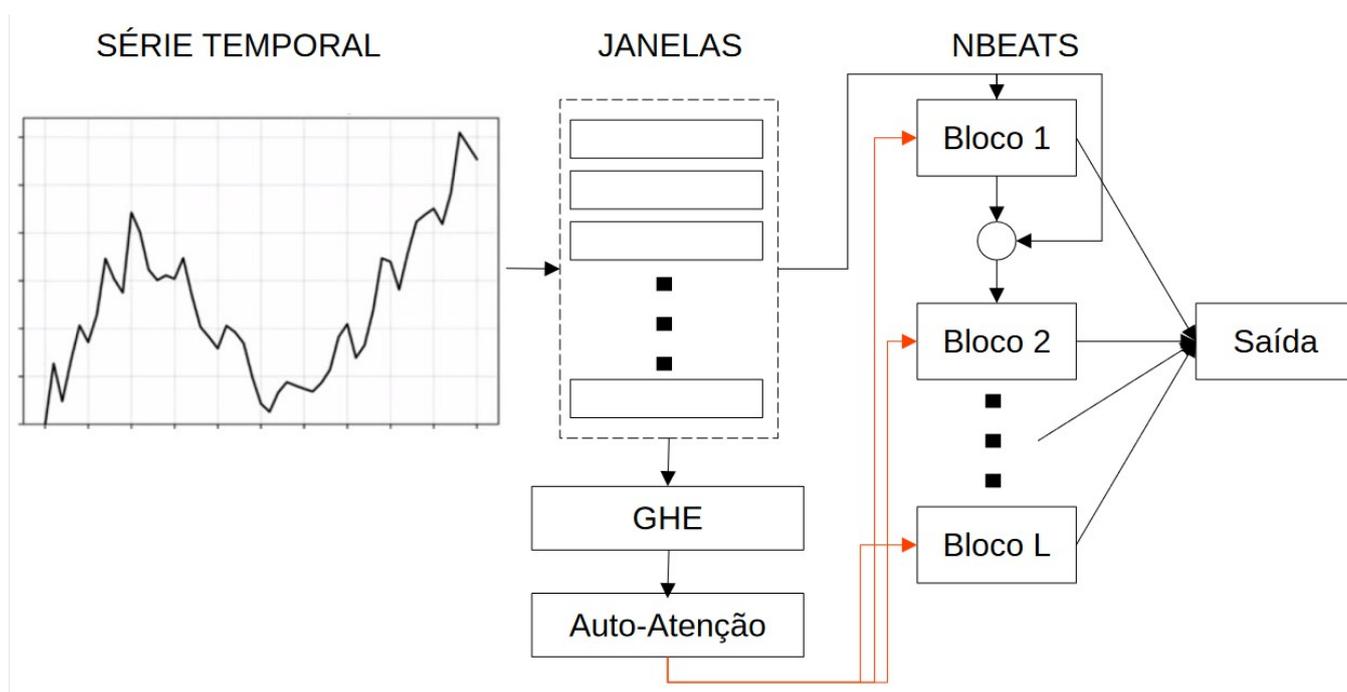


Figura 2: Representação gráfica do modelo proposto.

RESULTADOS E DISCUSSÃO:

O conjunto de dados utilizado para o treinamento e teste do modelo foi utilizado no Desafio de Computação na Cardiologia de 2021 (Computing in Cardiology Challenge 2021). Entretanto, não foram utilizados a totalidade dos exemplos disponíveis: apenas aqueles cujas séries temporais possuem tamanho 60000, o que, corresponde a um eletrocardiograma com 12 *leads*, cada uma com 10 segundos de duração e 500 Hz de frequência. Isso corresponde à maioria dos dados disponíveis, totalizando 74.374 exemplos correspondentes às seguintes bases de dados: Chapman-Shaoxing (Chapman University e Shaoxing People's Hospital); Ningbo (Ningbo First Hospital); Physikalisch-Technische Bundesanstalt (PTB) (no caso foi usado somente a PTB-XL); e uma base de dados do estado da Geórgia, Estados Unidos. Cada eletrocardiograma poderia ser classificado em 112 classes, sendo que um mesmo eletrocardiograma poderia estar classificado em qualquer quantidade de

classes. As classes não são balanceadas, havendo certas anomalias cardíacas raras com apenas 1 exemplo no conjunto de dados. Isso quer dizer que há classes em que não se espera que o modelo seja capaz de prever corretamente.

Todas essas bases de dados foram juntadas e misturadas, sendo, por fim, divididas em 5 *folds* diferentes, sendo que para cada treinamento e teste do modelo um *fold* diferente era separado para teste e todos os outros eram os exemplos de treinamento. Desse modo, todos os exemplos disponíveis foram usados tanto para teste quanto para treino (em momentos separados). No final, é calculada a média dos resultados dos 5 experimentos.

Além disso, foram feitos diversos testes com os modelos para encontrar a melhor combinação de hiperparâmetros.

Para conseguir uma identificação melhor do quão impactante foram as inovações propostas neste projeto, foi elaborado um experimento comparando o desempenho de 3 modelos: o modelo proposto, o modelo proposto com a troca do GHE pelos momentos amostrais e o N-BEATS puro, sem o mecanismo de auto-atenção. O objetivo deste experimento é identificar qual o impacto de cada adição ao modelo: o GHE e o mecanismo de auto-atenção.

Para tal, foram implementados os dois outros modelos e o mesmo experimento apresentado foi conduzido para ambos. Os resultados deste experimento podem ser vistos na Tabela 1:

| | | Modelo | | |
|---------|-----------|---------------|---------------|---------|
| Métrica | | GHE | Moments | N-BEATS |
| TREINO | Precision | 0.5165 | 0.4988 | 0.4726 |
| | Recall | 0.3241 | 0.2791 | 0.3242 |
| | Accuracy | 0.2510 | 0.1897 | 0.2199 |
| | F1-score | 0.3977 | 0.3532 | 0.3839 |
| TESTE | Precision | 0.4418 | 0.4809 | 0.4067 |
| | Recall | 0.2806 | 0.2663 | 0.2759 |
| | Accuracy | 0.2299 | 0.1828 | 0.1991 |
| | F1-score | 0.3430 | 0.3385 | 0.3286 |

Tabela 1: Comparação dos modelos propostos

Em verde estão os melhores resultados em cada uma das métricas. Como pode ser visto, o modelo proposto neste projeto é superior em praticamente todas as métricas, o que demonstra que a adição de um mecanismo de auto-atenção baseado no expoente generalizado de Hurst melhora de modo significativo a performance do modelo N-BEATS padrão. Não obstante, ao longo dos diversos experimentos conduzidos, foi notado que uma precisão maior geralmente estava associada a desempenhos piores dos modelos nas outras métricas. Há uma razão razoável para tal comportamento aparentemente contraditório: a base de dados possui classes altamente

desbalanceadas, com algumas anomalias cardíacas tendo até mesmo um ou dois exemplos no total. Assim, é muito mais simples para o modelo identificar quando não existem anomalias do que quando existem, o que implica em valores maiores para a precisão em detrimento das outras métricas.

Por fim, as métricas apresentam valores relativamente baixos em decorrência da dificuldade da tarefa proposta, já que, como mencionado, há anomalias raras com poucos exemplos e se optou por manter todas as classes, em vez de usar apenas 30 como se faz na maioria dos modelos que usam essa base, o que reduz drasticamente a dificuldade da tarefa.

CONCLUSÕES:

O modelo proposto demonstrou ser uma melhora em relação ao modelo padrão. Não obstante, os resultados da Tabela 1 mostram que utilizar apenas o mecanismo de auto-atenção sem alguma medida estatística mais elaborada não gera um desempenho melhor, sendo necessária a combinação de ambos os elementos. Assim, este projeto mostrou que há potencial para a combinação de modelos do estado-da-arte, em especial o N-BEATS, com mecanismos de auto-atenção baseados em medidas estatísticas, como o expoente generalizado de Hurst, para a classificação de eletrocardiogramas ou tarefas similares de classificação de séries temporais. Além disso, os resultados do experimento ilustram que há espaço para melhorias no desempenho do modelo proposto.

BIBLIOGRAFIA

- PUSZARSKI, Bartosz; HRYNIÓW, Krzysztof; SARWAS, Grzegorz. **Comparison of neural basis expansion analysis for interpretable time series (N-BEATS) and recurrent neural networks for heart dysfunction classification.** *Physiological Measurement*, 2022.
- ZENG, Sebastian et al. **Topological Attention for Time Series Forecasting.** 35th Conference on Neural Information Processing Systems (NIPS), 2021.
- ORESHKIN, Boris et al. **N-BEATS: Neural Basis expansion analysis for interpretable time series forecasting.** International Conference on Learning Representations (ICLR), 2020.
- REYNA, Matthew et al. **Will Two Do? Varying Dimensions in Electrocardiography: The PhysioNet/Computing in Cardiology Challenge 2021.** *Computing in Cardiology*, 2021.
- LAHMIRI, Salim. **Generalized Hurst exponent estimates differentiate EEG signals of healthy and epileptic patients.** *Physica A*, 2018.
- VASWANI, Ashish et al. **Attention Is All You Need.** 31st Conference on Neural Information Processing Systems (NIPS), 2017.