

Aplicação de modelos fundamentais de séries temporais no mercado de energia

RESUMO ESTENDIDO - Disciplina de TCC029009

Gustavo Paulo

Estudante do Curso de Engenharia de Telecomunicações

Arliones Stevert Hoeller Junior, Dr

Professor orientador

Mario de Noronha Neto, Dr

Professor coorientador

Semestre 2025.1

Resumo- Diante da evolução dos Time Series Foundation Models (TSFM) e de sua capacidade de capturar dependências temporais complexas sem ajustes específicos, esses modelos vêm transformando pipelines de previsão em diversos domínios. A predição zero shot dos TSFM elimina a etapa de coleta massiva de dados rotulados para treinamento, o que é especialmente vantajoso em aplicações onde os dados são escassos ou custosos de obter. Realiza-se um levantamento do estado da arte e uma avaliação experimental de TSFM de código aberto em séries históricas do mercado de energia, quantificando seu desempenho por métricas como erro médio quadrático (MSE) e erro médio absoluto (MAE). Este trabalho visa aplicar e comparar esses modelos na previsão de séries temporais do setor elétrico, avaliando sua viabilidade e potencial estratégico.

Palavras-chave: Time series foundation models. Aprendizado profundo. Séries temporais. Mercado de energia.

1 Introdução

A digitalização de processos e a automação em diversos setores criaram um ambiente altamente conectado, no qual dados são continuamente gerados em volumes massivos. Esse crescimento acelerado não apenas amplia os desafios de armazenamento e processamento, mas, sobretudo, impõe novas exigências analíticas para capturar padrões temporais em dados sequenciais,

fundamentais em áreas como finanças, saúde, clima e, de maneira particular, no setor energético (LIANG et al., 2024).

Diante dessa explosão de dados, os avanços do *deep learning* têm se mostrado revolucionários na modelagem de séries temporais. Arquiteturas como *transformers* emergiram como ferramentas potentes para lidar com dependências temporais complexas e variáveis exógenas, superando limitações dos métodos estatísticos tradicionais (CHEN et al., 2023).

Essa evolução culminou em uma nova fronteira de pesquisa: os *Time Series Foundation Models* (TSFM), inspirados nos modelos fundamentais que transformaram a visão computacional e o processamento de linguagem natural. Os TSFM representam uma mudança de paradigma ao permitir previsões *zero shot* e *few shot* a partir de pré-treinamento em larga escala, com notável generalização entre domínios e frequências temporais (LIANG et al., 2024).

A proposta deste projeto é aplicar e comparar TSFM de código aberto em séries históricas do mercado de energia elétrica, avaliando o desempenho dos principais modelos atuais por meio de métricas como MSE e MAE. Espera-se demonstrar que os TSFM podem ser modelos ágeis e eficientes em contextos onde os dados rotulados são escassos ou custosos de obter, apresentando resultados concretos e significativos.

1.1 Objetivo geral

Com base nesse contexto, o objetivo principal deste trabalho é aplicar diversos modelos de TSFM para a previsão de séries temporais no mercado de energia.

1.2 Objetivos específicos

Para atingir o objetivo geral, os seguintes objetivos específicos se fazem imprescindíveis:

- Realizar uma pesquisa do estado da arte sobre o tema de TSFM.
- Coletar dados abertos de séries temporais do setor de energia para constituir a base de dados do projeto.
- Limpar e pré-processar a base de dados coletada.
- Selecionar modelos de TSFM de código aberto para a realização de testes.
- Realizar testes de diversos modelos na base de dados pré-processada.

2 Metodologia

A pesquisa adota uma metodologia empírica dividida em etapas sucessivas, com foco na aplicação de *Time Series Foundation Models* (TSFM) em séries

temporais do setor elétrico. O primeiro passo consiste em uma revisão sistemática do estado da arte, com o objetivo de mapear os principais modelos de TSFM atualmente disponíveis na literatura e em repositórios de código aberto. Essa etapa é essencial para identificar quais arquiteturas se destacam em termos de desempenho, generalização entre domínios e suporte à incorporação de covariáveis futuras. A partir dessa análise crítica, serão selecionados os modelos mais promissores para aplicação no contexto energético.

Em seguida, realiza-se a coleta de séries temporais públicas por meio de fontes como o Operador Nacional do Sistema (ONS) e a Câmara de Comercialização de Energia Elétrica (CCEE). Entre essas séries temporais, destacam-se: curva de carga elétrica, geração de energia fotovoltaica, geração eólica, Energia Natural Afluente (ENA), Energia Armazenada (EAR) e preço horário. Os dados são submetidos a um processo de pré-processamento que envolve a limpeza de valores ausentes, padronização de frequência, normalização e segmentação temporal em janelas para previsão. A estruturação dos dados será feita considerando diferentes horizontes de previsão (curto, médio e longo prazo), de forma a testar a adaptabilidade dos modelos em múltiplos cenários.

Os modelos selecionados na etapa anterior serão implementados em ambiente *Python* com suporte a *GPU* e avaliados por métricas quantitativas, como o erro quadrático médio (MSE) e o erro médio absoluto (MAE).

Adicionalmente, serão realizados testes com a inclusão de covariáveis futuras simuladas, com o objetivo de explorar o potencial dos TSFM para incorporar informações prospectivas e aprimorar a acurácia preditiva em cenários energéticos complexos. Isso se justifica pelo fato de que previsões baseadas exclusivamente em dados históricos frequentemente não capturam toda a variabilidade presente em contextos como o do setor elétrico, onde fatores externos, como clima, calendário e indicadores econômicos, exercem forte influência. Dessa forma, serão conduzidos experimentos complementares utilizando covariáveis futuras simuladas, ou seja, variáveis previstas por modelos auxiliares simples, a fim de alimentar os modelos TSFM. A meta é verificar se a inclusão dessas variáveis adicionais contribui para um desempenho preditivo superior, destacando o potencial dos TSFM para apoiar decisões estratégicas fundamentadas em dados prospectivos.

3 Considerações parciais

É importante destacar que previsões baseadas exclusivamente em padrões históricos apresentam limitações intrínsecas, especialmente no mercado de energia, onde eventos externos e imprevistos são frequentes. Assim, os resultados obtidos devem ser interpretados com cautela, sabendo-se que previsões perfeitamente acuradas são improváveis. Uma abordagem promissora envolve a utilização de covariáveis futuras simuladas, permitindo capturar dinâmicas adicionais e mitigar parcialmente essas limitações.

4 Resultados esperados

Espera-se demonstrar que os TSFM são eficazes na previsão de séries temporais no mercado de energia, destacando-se por sua capacidade de generalização e rápida adaptação, especialmente em contextos com escassez de dados para treinamento. Prevê-se identificar claramente quais modelos apresentam melhor desempenho para cada horizonte temporal (curto, médio e longo prazo), além de avaliar a contribuição das covariáveis futuras simuladas para a melhoria da acurácia preditiva. Esses resultados poderão subsidiar decisões estratégicas mais informadas no setor energético.

Referências

CHEN, S.-A. et al. *TSMixer: An All-MLP Architecture for Time Series Forecasting*. 2023. Disponível em: <<https://arxiv.org/abs/2303.06053>>.

LIANG, Y. et al. Foundation models for time series analysis: A tutorial and survey. In: *Proceedings of the 30th ACM SIGKDD Conference on Knowledge Discovery and Data Mining*. ACM, 2024. (KDD '24), p. 6555–6565. Disponível em: <<http://dx.doi.org/10.1145/3637528.3671451>>.