

12º Congresso de Inovação, Ciência e Tecnologia do IFSP - 2021

PREVISÃO DE CARGA EM SISTEMAS ELÉTRICOS DE POTÊNCIA UTILIZANDO REDE NEURAL LSTM

MATEUS A. GUELFÍ¹, JOSÉ G. M. S. DECANINI²

¹Graduando em Engenharia Elétrica, Bolsista FAPESP, IFSP, Campus Presidente Epitácio, mateus.guelfi@aluno.ifsp.edu.br.

²Professor Doutor em Engenharia Elétrica, IFSP, Campus Presidente Epitácio, guilhermedecanini@ifsp.edu.br.

Área de conhecimento (Tabela CNPq): 3.04.04.00-2 Sistemas Elétricos de Potência.

RESUMO: A previsão de carga elétrica consiste em um estudo fundamental para a operação e o planejamento dos sistemas elétricos de potência. Tendo em vista a desregulamentação do setor de energia elétrica, a maior competitividade e as transformações tecnológicas e filosóficas advindas da concepção e construção de redes inteligentes, o conhecimento do comportamento futuro das cargas dos sistemas de energia elétrica torna-se essencial para a adequada tomada de decisão. Dentro deste contexto, as pesquisas abordando a previsão de carga dar-se-ão nos horizontes de longo, médio, curto e curtíssimo prazo. Ademais, os pesquisadores e empresas do setor têm investido na aplicação de técnicas de inteligência artificial para concepção de modelos robustos e flexíveis que propiciem uma solução confiável, com alta acuracidade e de alta performance computacional. Por conseguinte, este presente trabalho visa desenvolver um sistema inteligente para previsão de carga de curto prazo em sistemas de energia elétrica. Mais especificamente um sistema que utiliza redes neurais LSTM (do inglês *Long Short Term Memory*) foi concebido para realizar a previsão de carga do sistema Sudeste/Centro-Oeste do Sistema Interligado Nacional (SIN). Os resultados preliminares obtidos são promissores, e denotam eficiência e viabilidade da aplicação de redes neurais LSTM para previsão de carga.

PALAVRAS-CHAVE: previsão de carga; curto prazo; redes neurais; LSTM; sistema inteligente.

LOAD FORECAST IN ELECTRICAL POWER SYSTEMS USING LSTM NEURAL NETWORK

ABSTRACT: The electric load forecast consists of a fundamental study for the operation and planning of electrical power systems. Considering the deregulation of the electricity sector, greater competitiveness and technological and philosophical transformations resulting from the design and construction of smart grids, knowledge of the future behavior of electric power system loads becomes essential for proper decision making. Within this context, the researches addressing the forecast of load will take place in the long, medium, short and very short term horizons. Furthermore, researchers and companies in the sector have invested in the application of artificial intelligence techniques to design robust and flexible models that provide a reliable solution, with high accuracy and high computational performance. Therefore, this work aims to develop an intelligent system for short-term load forecasting

in electric power systems. More specifically, a system that uses Long Short-Term Memory (LSTM) neural networks was designed to perform load forecasting for the Southeast/Central-West system of the National Interconnected System (NIS). The preliminary results obtained are promising, and denote efficiency and feasibility of applying LSTM neural networks for load forecasting.

KEYWORDS: load forecast; short term; neural networks; LSTM; intelligent system.

INTRODUÇÃO

Ao longo dos últimos anos, os sistemas elétricos de potência vêm passando por reestruturações técnicas e filosóficas que demandam um aporte maior das concessionárias de energia elétrica e dos pesquisadores para o desenvolvimento de sistemas inteligentes e modulares, que possam ser facilmente modificados para atender as constantes evoluções do setor. Redes ativas, sistemas automatizados, equipamentos eletrônicos inteligentes correspondem ao novo contexto da operação e planejamento do sistema. Neste sentido, destacam-se sistemas inteligentes para previsão de carga ((FIGUEIREDO, 2009), (FILHO, 2011), (SILVA; SPATTI; FLAUZINO, 2010), (ANDRADE, 2010), (LOPES, 2005), (FIGUEIREDO, 2009), (FERREIRA, 2020), (SHAN et al., 2017)). Estas ferramentas de apoio à tomada de decisão propiciam maior segurança, confiabilidade e lucratividade às empresas do setor.

A indústria voltada para o fornecimento de energia elétrica requer previsões com prazos que vão desde curto prazo (alguns minutos ou horas) a longos prazos (anos à frente). Previsões imprecisas podem resultar em custos operacionais desnecessários, em contrapartida a superestimação na demanda futura resulta em uma reserva girante excessiva (ANDRADE, 2010).

As previsões a curto prazo em particular, tem se tornado cada vez mais importantes desde a ascensão do mercado energético, sendo que muitos países privatizaram e desregulamentaram os sistemas de energia, tornando a energia elétrica uma mercadoria a ser comprada e vendida a preços de mercado, fazendo então com que as previsões de carga desempenham um papel crucial na composição destes preços, contribuindo diretamente para a indústria do abastecimento (HIPPERT; PEDREIRA; SOUZA, 2001).

MATERIAL E MÉTODOS

Para o desenvolvimento do presente trabalho foram adquiridos os dados relativos a carga horária, do site do ONS (Operador Nacional do Sistema Elétrico). Os dados extraídos correspondem ao período de 01/01/2019 até 31/12/2020 totalizando um intervalo de dois anos, compondo um *dataset* de mais de dezessete mil informações de carga. Os dados referem-se ao subsistema Sudeste/Centro-Oeste do SIN (Sistema Interligado Nacional).

Dentro deste contexto, desenvolveu-se um sistema inteligente para realizar a previsão de carga horária. Empregou-se a linguagem *Python* para implementação computacional do sistema predictor inteligente, sendo que recorreu-se ao uso da biblioteca (ABADI et al., 2015) conhecida como *TensorFlow*. Nesta perspectiva, foi concebido um sistema predictor utilizando a rede neural do tipo LSTM (*Long Short Term Memory*), que possui características fundamentais para composição de ferramentas para operação e planejamento de sistemas elétricos de potência.

No que tange o processamento do modelo supracitado foram adotadas as métricas arroladas abaixo:

- Número de épocas: 400;

- batch size: 256;
- Passo inicial: 1 hora;
- Quantidade de camadas escondidas: 1;
- Número de neurônios na camada escondida: 100;
- 80% dos dados para treinamento;
- 20% dos dados para teste.

Para o aperfeiçoamento da rede utilizada empregou-se três ferramentas fundamentais para o desempenho da rede, a primeira ferramenta denominada *Early Stopping* (“Parada Antecipada”) também da biblioteca (ABADI et al., 2015), na qual é utilizada para que não ocorra *overfitting* (“Sobretreinamento”) e *underfitting* (“Subtreinamento”). O *overfitting* consiste em um sobre ajuste da rede no processo de treinamento, em que a mesma ao invés de extrair o conhecimento do processo para possibilitar uma generalização adequada na etapa de teste, ela apenas os “decora”; já *underfitting* corresponde a um treinamento aquém do necessário para extração das informações, tendo como consequência erros consideráveis tanto no processo de treinamento como no de teste. A fim de evitar esses dois problemas que podem ocorrer no treinamento estabeleceu-se um mínimo de 100 épocas sem melhoria para a interrupção do processo e uma taxa de aprendizagem de 0,001, para que não ocorra principalmente o *overfitting*.

A segunda ferramenta utilizada no presente trabalho também faz parte da biblioteca (ABADI et al., 2015) e é denominada de *optimizers* usando a variação “adam”, que é um método de otimização que utiliza da descida do gradiente estocástico na estimativa adaptativa de momentos de primeira e segunda ordem. E por fim como terceira ferramenta se fez uso do *validation split* com uma taxa de 20%, que utiliza uma fração dos dados de treinamento a ser usada como dados de validação.

Em seguida faz-se o uso de índices de desempenho, que são baseados em medidas de erro, ou seja, os desvios entre os valores previstos e os efetivamente observados, dentre elas podemos destacar o MAE (do inglês *Mean Absolute Error*), RMSE (do inglês *Root Mean Square Error*) e um dos mais utilizados intitulado MAPE (do inglês *Mean Absolute Error*), é uma medida de acurácia da previsão e, para calculá-lo considera-se os desvios relativos ou percentuais do erro (SENNA; TANSCHIEIT; GOMES, 2015). Sendo expresso pela Equação 1.

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{C^{Real}(t) - C^{Previsto}(t)}{C^{Real}(t)} \right| * 100\% \quad (1)$$

em que,

C^{Real} - valor da carga real;

$C^{Previsto}$ - valor da carga prevista;

n - número de amostras previstas.

RESULTADOS E DISCUSSÃO

Os resultados preliminares apresentados são correspondentes à performance do sistema inteligente concebido via linguagem *Python* considerando os parâmetros previamente especificados. Dentro desta abordagem, implementou-se o sistema, a priori, tendo como variável de entrada os três valores de carga anteriores à previsão, e posteriormente analisar-se-á a viabilidade da inclusão de dados exógenos. A

rede neural LSTM consiste no cerne do módulo predictor, busca-se empregar técnicas com alto índice de eficácia capazes de prover subsídios adequados para a tomada de decisão. Assim, os resultados da previsão para as 48 horas posteriores são apresentados na Figura 1, que possibilita uma análise pontual mais refinada, e os resultados da previsão de 500 horas a frente encontra-se na Figura 2.

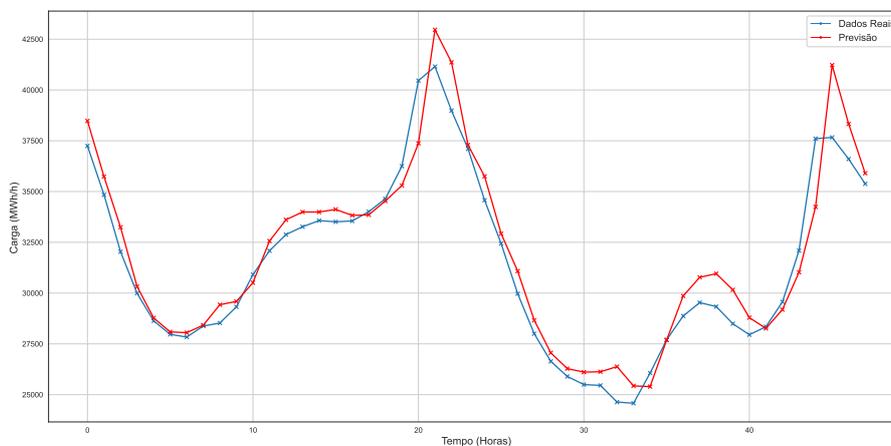


Figura 1: Resultados obtidos pelo sistema predictor usando a rede LSTM no horizonte de 48 horas.

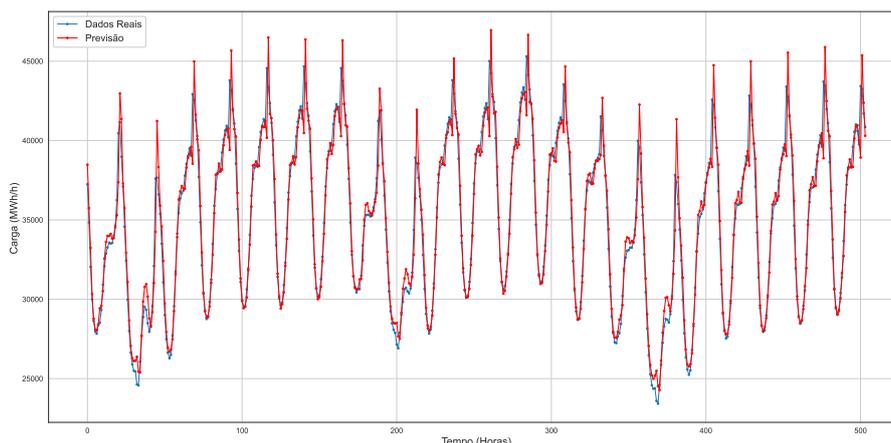


Figura 2: Resultados obtidos pelo sistema predictor usando a rede LSTM no horizonte de 500 horas.

Os índices de desempenhos que mostram a acurácia do sistema predictor para todo o conjunto de teste são apresentados na Tabela 1.

Tabela 1: Índices de desempenho da rede LSTM.

	MAE	RMSE	MAPE
Treino	755,4203	1073,8580	2,0540
Teste	718,2587	1028,5545	1,8525

CONCLUSÕES

Desenvolveu-se neste trabalho um sistema inteligente para a previsão de carga horária com o passo de uma hora a frente utilizando redes neurais LSTM, a qual possui uma vantagem sobre diversas redes RNNs (do inglês *Recurrent Neural Networks*) de conseguir "relembrar" dos valores em intervalos

arbitrários, sendo então muito utilizada em problemas de previsão de séries temporais. Os resultados obtidos foram promissores (MAPE < 2%), evidenciando a capacidade do módulo predictor concebido por meio de técnica de inteligência artificial realizar previsões de carga com alta acurácia, o que propicia confiabilidade e segurança para a operação e planejamento dos sistemas elétricos de potência, provendo maior simplicidade à rotina diária dos operadores.

A continuidade do trabalho dar-se-á provendo análise e inserção de variáveis exógenas no módulo predictor, assim como a ampliação do horizonte de previsão, a fim de fornecer aos operadores informações precípuas para uma correta tomada de decisão.

AGRADECIMENTOS

Os autores agradecem ao IFSP - Câmpus Presidente Epitácio e a Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP)(Processo 2020/15621-4), pelo apoio e suporte fornecidos para realização deste trabalho.

REFERÊNCIAS

- ABADI, M. et al. *TensorFlow: Large-Scale Machine Learning on Heterogeneous Systems*. 2015. Software available from tensorflow.org. Disponível em: <<https://www.tensorflow.org/>>.
- ANDRADE, L. C. M. D. *Abordagem neurofuzzy para previsão de demanda de energia elétrica no curtíssimo prazo*. 109 p. Dissertação (Mestrado) — Universidade de São Paulo (USP), Escola de Engenharia de São Carlos, São Carlos-SP, 2010.
- FERREIRA, A. B. A. *Previsão de carga multinodal utilizando Rede Neural ARTMAP Euclidiana*. 76 p. Dissertação (Mestrado) — Universidade Estadual Paulista (UNESP), 2020. Disponível em: <<http://hdl.handle.net/11449/193357>>.
- FIGUEIREDO, R. M. d. *Um sistema computacional para previsão de carga em sistemas de energia elétrica baseado em redes neurais artificiais*. 109 p. Dissertação (Mestrado) — Universidade do Vale do Rio do Sinos, Programa de Pós Graduação em Computação Aplicada, São Leopoldo, 2009.
- FILHO, K. N. *Previsão de carga multinodal utilizando redes neurais de regressão generalizada*. 90 p. Dissertação (Mestrado) — Universidade Estadual Paulista (UNESP), Faculdade de Engenharia de Ilha Solteira, 2011. Disponível em: <<http://hdl.handle.net/11449/87097>>.
- HIPPERT, H. S.; PEDREIRA, C. E.; SOUZA, R. C. Neural networks for short-term load forecasting: a review and evaluation. *IEEE Transactions on Power Systems*, v. 16, n. 1, p. 44–55, Feb 2001. Doi:10.1109/59.910780.
- LOPES, M. L. M. *Desenvolvimento de redes neurais para previsão de cargas elétricas de sistemas de energia elétrica*. 149 p. Tese (Doutorado) — Universidade Estadual Paulista (UNESP), Faculdade de Engenharia de Ilha Solteira, Ilha Solteira-SP, 2005.
- SENNA, P.; TANSCHKEIT, R.; GOMES, A. M. Demand forecast process planning with fuzzy logic support. *Revista Produção e Desenvolvimento*, v. 1, n. 2, p. 90–103, Aug. 2015. Disponível em: <<https://revistas.cefet-rj.br/index.php/producaoedesenvolvimento/article/view/e89>>.
- SHAN, B. et al. Analysis of energy demand forecasting model in the context of electric power alteration. In: *IEEE. 2017 8th IEEE International Conference on Software Engineering and Service Science (ICSESS)*. [S.l.], 2017. p. 798–801.
- SILVA, I. d.; SPATTI, D. H.; FLAUZINO, R. A. Redes neurais artificiais para engenharia e ciências aplicadas. *São Paulo: Artliber*, v. 23, n. 5, p. 33–111, 2010.