

## Previsão do consumo de energia elétrica em uma agroindústria: um estudo de caso usando redes LSTM e CNN-LSTM

*Forecast of electric energy consumption in a agroindustry: a case study using LSTM and CNN-LSTM networks*

Eduarda Araujo Antonioli<sup>1</sup>, José Airton Azevedo dos Santos<sup>2</sup>, Alex Lemes Guedes<sup>3</sup>, Leandro Antonio Pasa<sup>4</sup>

### RESUMO

Este trabalho tem como objetivo desenvolver e comparar modelos, de Redes Neurais Artificiais (RNA), para previsão do consumo de energia elétrica de uma agroindústria. A base de dados, disponibilizada pela Câmara de Comercialização de Energia Elétrica (CCEE), apresenta uma série histórica, do consumo de energia elétrica, no período entre janeiro de 2020 e janeiro de 2021, representado 6816 observações horárias. Modelos, baseados nas arquiteturas LSTM e CNN-LSTM, foram implementados, na linguagem Python, utilizando o *framework* Keras. Resultados obtidos dos modelos foram comparados por meio das métricas MAPE (*Mean Absolute Percentage Error*), MAE (*Mean Absolute Error*) e RMSE (*Root Mean Squared Error*). Verificou-se, para um horizonte de 24 horas, que o modelo CNN-LSTM apresentou melhor desempenho.

**Palavras-chave:** Redes neurais artificiais; Energia elétrica; Agroindústria.

### ABSTRACT

This work aims to develop and compare models of Artificial Neural Networks (ANN) to predict the consumption of electricity in an agroindustry. The database, made available by the Electrical Energy Commercialization Chamber (CCEE), presents a historical series, of electricity consumption, in the period between January 2020 and January 2021, representing 6816 hourly observations. Models, based on the LSTM and CNN-LSTM architecture, were implemented, in Python language, using the Keras framework. Results obtained from the models were compared using the metrics MAPE (Mean Absolute Percentage Error), MAE (Mean Absolute Error) and RMSE (Root Mean Squared Error). We verified, for a horizon of 24 hours, that the CNN-LSTM model presented better performance.

**Keywords:** Artificial neural network; Electrical energy; Agroindustry.

<sup>1</sup> Discente do Programa de Pós-Graduação em Tecnologias Computacionais para o Agronegócio (PPGTCA). E-mail: [antonioli@alunos.utfpr.edu.br](mailto:antonioli@alunos.utfpr.edu.br). <https://orcid.org/0000-0003-3990-1757>

<sup>2</sup> Doutor em Engenharia Elétrica. Docente do Programa de Pós-Graduação em Tecnologias Computacionais para o Agronegócio (PPGTCA). Universidade Tecnológica Federal do Paraná (UTFPR). E-mail: [airton@utfpr.edu.br](mailto:airton@utfpr.edu.br). <https://orcid.org/0000-0002-2568-5734>

<sup>3</sup> Mestre em Engenharia Elétrica. Docente do Departamento de Engenharia Elétrica. Universidade Tecnológica Federal do Paraná (UTFPR). E-mail: [alexguedes@utfpr.edu.br](mailto:alexguedes@utfpr.edu.br). <https://orcid.org/0000-0002-4120-8436>

<sup>4</sup> Doutor em Engenharia Elétrica. Docente do Departamento de Engenharia Elétrica. Universidade Tecnológica Federal do Paraná (UTFPR). E-mail: [pasa@utfpr.edu.br](mailto:pasa@utfpr.edu.br). <https://orcid.org/0000-0002-0214-250X>

## 1. INTRODUÇÃO

A disponibilidade de energia elétrica, nas indústrias, é um fator muito importante para o desenvolvimento econômico das nações. O setor industrial, no Brasil, é o maior consumidor de energia, com alguns segmentos altamente dependentes de grande volume de eletricidade, para sua operação. Dentre estes segmentos podem-se citar: alimentos e bebidas, metalurgia (não ferrosos), papel e celulose e química (SOLIMAN; AL-KANDARI, 2010; CBIE, 2021).

A demanda crescente por energia, por parte das indústrias, motiva a necessidade do planejamento do consumo e de ferramentas de tomada de decisão. Modelos de séries temporais podem ser utilizados como ferramentas de tomada de decisão. Dentre estes modelos têm-se as Redes Neurais Artificiais. As redes neurais, ferramentas de grande importância em um sistema de planejamento, direcionam a melhor forma de aproveitar todos os recursos disponíveis pela empresa (PINHEIRO et al., 2020).

Redes Neurais Artificiais, por sua boa capacidade de aproximar funções não lineares, vêm sendo empregadas, com muito sucesso, na previsão de séries temporais. As RNAs, abstrações da rede neural biológica, são capazes de memorizar, analisar e processar um grande número de dados obtidos de um experimento. Podem ser consideradas como um esquema de processamento capaz de armazenar conhecimento e disponibilizá-lo para determinada aplicação. Seu objetivo é servir de modelo para o aprendizado e resoluções de problemas complexos (SEBASTIAN, 2016; PINHEIRO et al., 2020; BASTIANI et al., 2018; HAYKINS, 2001; SANTOS; CHAUCOSKI, 2020; LUCAS, 2019).

Vários trabalhos, de autores nacionais e estrangeiros, utilizaram modelos de previsão de séries temporais para prever o consumo de eletricidade. Dentre eles podem-se citar os trabalhos de: Wassesa et al. (2020) que utilizaram modelos, de Redes Neurais Artificiais, para previsão do consumo de eletricidade de um edifício educacional. Amaral (2020) que desenvolveu uma nova metodologia para previsão, do consumo de energia elétrica de curto prazo, utilizando Redes Neurais Artificiais e decomposição de séries temporais. Chadramitasari et al. (2019) que propuseram uma abordagem *deep learning* (LSTM-FFNN) para previsão do consumo de eletricidade em uma empresa de manufatura. Já Kim e Cho (2019) e Yan et al. (2019) usaram redes CNN-LSTM para prever o consumo de Energia elétrica em residências.

Segundo Witten et al. (2016), é importante, na indústria, a determinação da demanda futura o mais a frente possível. Estimativas acuradas significam economia pela otimização da operação, configuração e, até mesmo, manutenções.

Apesar da importância das previsões, no planejamento do consumo de energia elétrica, ainda são poucos os trabalhos, de previsão de consumo, no setor industrial. Além disso, ressalta-se a necessidade de encontrar modelos mais assertivos para previsão, do consumo de energia elétrica, no setor industrial.

Neste contexto, este trabalho tem como objetivo desenvolver e comparar modelos, de Redes Neurais Artificiais, para previsão do consumo de energia elétrica de uma agroindústria.

Este trabalho está organizado da seguinte maneira. Na Seção 2 são descritas as metodologias empregadas na previsão do consumo de energia elétrica da agroindústria. Na Seção 3 são apresentados os resultados obtidos da aplicação dos modelos, de Redes Neurais Artificiais, em observações horárias do consumo de energia elétrica. Comentários finais e conclusões finalizam o trabalho.

## 2. MATERIAIS E MÉTODOS

A empresa:

A empresa, foco deste estudo, é uma empresa de grande porte e atuação no ramo agroindustrial. Visando economia, migrou para mercado livre, para poder optar por diferentes fornecedores de energia elétrica. Ao optar pelo mercado livre, o consumidor deve adquirir a energia que pretende consumir de uma comercializadora ou diretamente de um gerador. Esta contratação é feita em um mercado de livre concorrência, com negociações bilaterais (BARROS et al., 2020).

Neste contexto, a Câmara de Comercialização de Energia Elétrica (CCEE) integra geradores, distribuidores, comercializadores e consumidores. Está presente em cada etapa do processo, garantindo as condições para que a energia elétrica seja negociada (CCEE, 2021).

Base de dados:

Para previsão, do consumo de energia elétrica da agroindústria, utilizou-se uma base de dados obtida da Câmara de Comercialização de Energia Elétrica. A base de dados é

composta por 6816 observações horárias obtidas entre janeiro de 2020 e janeiro de 2021 (CCEE, 2021).

Os dez primeiros registros do conjunto de dados são apresentados na Tabela 1.

**Tabela 1.** Dez primeiros registros do arquivo de dados.

Instância-Ano	Consumo (kWh)
1-2020	5065,2
2-2020	4989,6
3-2020	4643,1
4-2020	4586,4
5-2020	4491,9
6-2020	4491,9
7-2020	4466,7
8-2020	4422,6
9-2020	4271,4
10-2020	3647,7

Os dados, do consumo de energia da agroindústria, foram divididos em três conjuntos. O primeiro conjunto, Conjunto de Treinamento, foi formado pelos primeiros 5408 dados. O segundo conjunto, o Conjunto de Validação, foi constituído pelos seguintes 1334 dados. Finalmente, o Conjunto de Teste foi formado pelos 24 dados restantes.

Os dados, para evitar que o desempenho dos algoritmos fossem afetados, foram normalizados. O objetivo da normalização é alterar os valores das colunas numéricas, no conjunto de dados, para usar uma escala comum, sem distorcer a diferença nos intervalos de valores ou perder informações (BINOTI, 2010).

Neste trabalho, a normalização dos dados, para o intervalo [0,1], foi realizada por meio da função `MinMaxScaler()` da biblioteca `Scikit-learn`.

Etapas do trabalho:

Este trabalho foi dividido em três etapas (Figura 1):

Etapa 1: Inicialmente foi realizada, com o objetivo de extrair informações importantes do conjunto de dados, uma análise descritiva dos dados (Etapa de Análise dos Dados).

Etapa 2: Na segunda etapa, etapa de Treinamento e Validação, foram selecionados, por meio de métricas, os melhores hiperparâmetros das redes neurais.

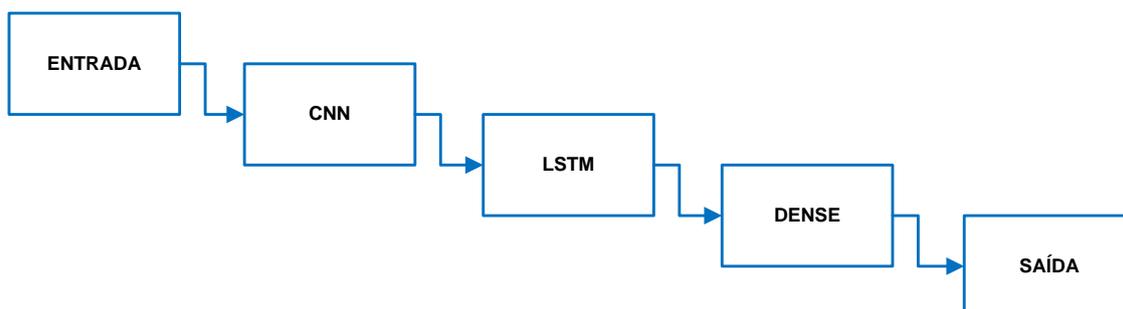
Etapa 3: Na última etapa, etapa de Teste, testaram-se os modelos para os dados que não participaram da etapa de Treinamento e Validação (Conjunto de Teste).



**Figura 1.** Etapas do trabalho

Algoritmos:

O modelo híbrido CNN-LSTM é uma arquitetura baseada na rede LSTM (*Long Short-Term Memory*), projetada para lidar com previsões de sequências. Envolve o uso da rede CNN (*Convolutional Neural Network*), como camada inicial, para a extração de características a partir dos dados de entrada. Os resultados da rede CNN são repassados a rede LSTM (Figura 2).



**Figura 2.** Arquitetura básica CNN-LSTM

O vetor FM, saída da rede CNN, é repassado para a rede LSTM (VINAYAKUMAR, 2017):

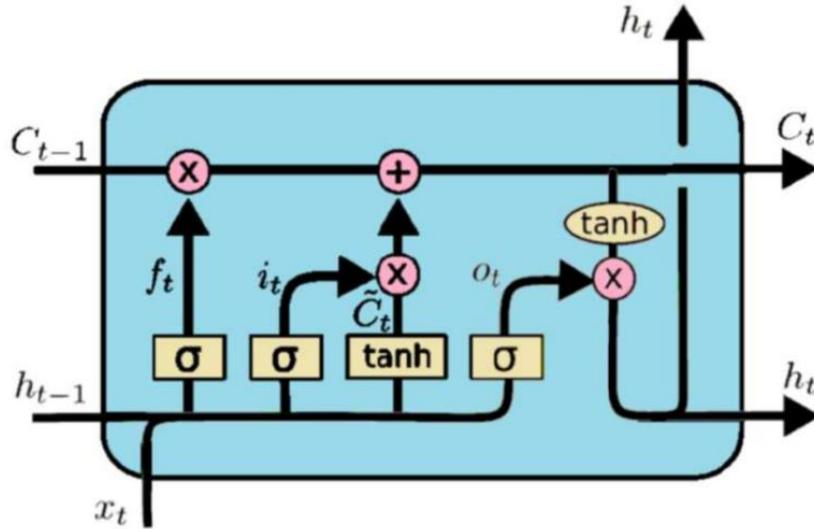
$$FM = CNN(x_t)$$

1

Onde  $x_t$  é o vetor de entrada.

CNN-LSTM: A rede LSTM, diferente das redes recorrentes convencionais, introduz células de memória. A capacidade de armazenar sequências recentes, na componente de memória da célula, a torna melhor que um neurônio clássico. Cada célula contém três portas

(Entrada ( $i_t$ ), Saída ( $O_t$ ) e Esquecimento ( $f_t$ )) as quais controlam o funcionamento da unidade (Figura 3) (GRAVES, 2014; SANTOS; CHAUCOSKI, 2020).



**Figura 3.** Célula LSTM  
 Fonte: Graves, 2014.

As equações da rede são definidas como (VINAYAKUMAR, 2017):

$$f_t = \sigma_g(W_{FMf}FM_t + W_{hf}h_{t-1} + W_{cf}c_{t-1} + b_f) \quad 2$$

$$i_t = \sigma_g(W_{FMi}FM_t + W_{hi}h_{t-1} + W_{ci}c_{t-1} + b_i) \quad 3$$

$$o_t = \sigma_g(W_{FMo}FM_t + W_{ho}h_{t-1} + W_{co}c_{t-1} + b_o) \quad 4$$

$$c_t = f_t \odot c_{t-1} + i_t \odot \tanh(W_{FMc}FM_t + W_{hc}h_{t-1} + b_c) \quad 5$$

$$h_t = o_t \odot \tanh(c_t) \quad 6$$

Onde  $b$  é o bias,  $W$  são as matrizes de peso,  $\sigma_g$  a função de ativação e  $FM$  é o vetor calculado a partir da rede CNN.

Métricas:

Neste trabalho, os modelos foram avaliados pelas seguintes métricas (CANKURT; SUBASI, 2015; PINHEIRO et al., 2020; BASTIANI et al., 2018):

Raiz Quadrada do Erro Médio Quadrático (RMSE): Raiz do erro médio quadrático da diferença entre a predição e o valor real. É muito usada, em séries temporais, porque dá um peso maior para desvios grandes (pois são elevados ao quadrado).

Erro Médio Absoluto (MAE): Como o RMSE, o MAE possui dimensão igual à dimensão dos valores observados e preditos. Seu valor representa o desvio médio entre observado e predito.

Erro Médio Absoluto Percentual (MAPE): O MAPE mede o tamanho do erro em termos percentuais.

As equações, das métricas RMSE, MAE e MAPE, são apresentadas na Tabela 2.

**Tabela 2.** Equações: RMSE, MAE e MAPE.

Métrica	RSME	MAE	MAPE
Equação	$\sqrt{\frac{1}{n} \sum_{i=1}^n ((y_i - \hat{y}_i)^2)}$	$\frac{1}{n} \sum_{i=1}^n  (y_i - \hat{y}_i) $	$\frac{1}{n} \sum_{i=1}^n  (y_i - \hat{y}_i)/y_i  \times 100$

Fonte: Santos, 2021.

Onde:  $y_i$  é o valor real do período  $i$ ,  $\hat{y}_i$  é a previsão para o período  $i$  e  $n$  é o número de observações.

### 3. RESULTADOS E DISCUSSÃO

Inicialmente, neste trabalho, realizou-se uma análise descritiva dos dados fornecidos pela agroindústria (Tabela 3).

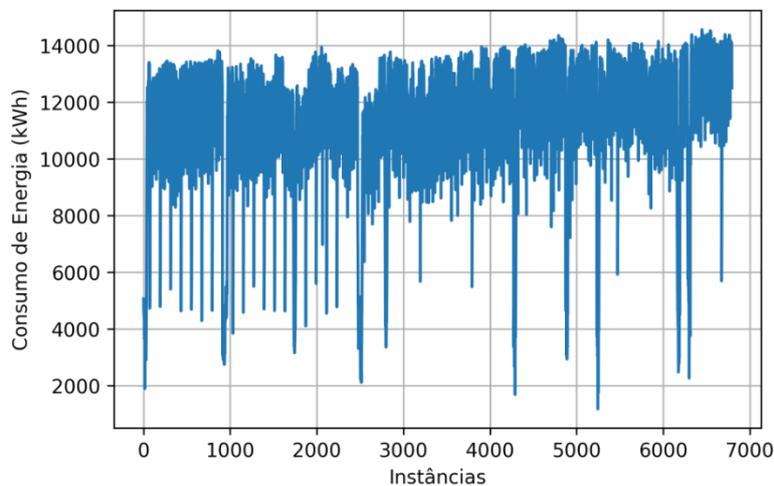
**Tabela 3.** Análise descritiva do consumo de energia elétrica

Resumo Descritivo	Consumo
Quantidade	6816
Média (kWh)	11846,41
Mínimo (kWh)	1171,8
Máximo (kWh)	14565,6
Desvio Padrão (kWh)	2294,03
Coeficiente de Variação (%)	19,4

Pode-se observar, dos dados apresentados na Tabela 3, que o consumo ficou, para o período em estudo, em média de 11846,41 kWh. Apresentando, neste período, consumos mínimo e máximo de 1171,8 kWh e 14565,6 kWh, respectivamente.

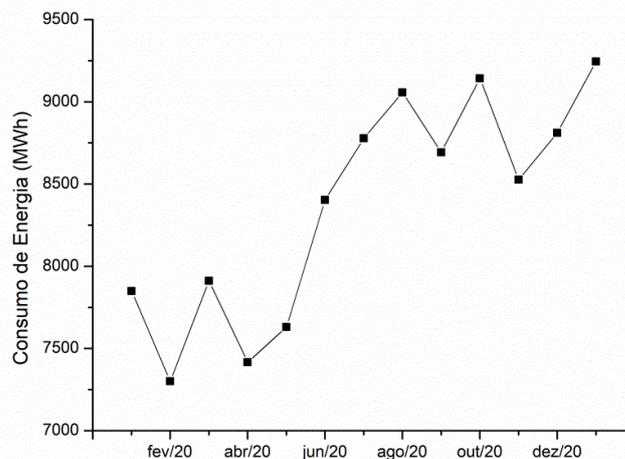
Quanto menor o Coeficiente de Variação maior será a representatividade da média. O valor do coeficiente de variação, para este conjunto de dados, é maior que 10%, sendo considerado médio, o que indica uma certa variabilidade dos dados (PIMENTEL, 2000).

O consumo horário de energia elétrica (kWh), para o período de janeiro de 2020 a janeiro de 2021, é apresentado na Figura 4.



**Figura 4.** Gráfico ilustrativo da série temporal do consumo de energia elétrica

Na Figura 5 apresenta-se o consumo de energia mensal de janeiro de 2020 a janeiro de 2021.



**Figura 5.** Consumo de energia por mês (MWh)

Pode-se notar, por meio da Figura 5, a tendência de crescimento do consumo de energia da agroindústria.

Treinamento e validação:

Neste trabalho, vários modelos de redes neurais, LSTM e CNN-LSTM, foram testados utilizando como indicadores de desempenho as métricas RMSE, MAE e MAPE. As redes neurais foram treinadas com 5408 amostras (80%) e validadas com 1334 amostras (20%). Os melhores modelos (Tabela 4) utilizam o algoritmo de otimização Adam com os seguintes hiperparâmetros: Rede LSTM: *cells*=32, *batch*=45, *learning rate*=0.0001 e *activate*= relu. Rede CNN: *kernel\_size*=3, *filters*=16 e *activate*= relu. Definiu-se, como critério de parada do treinamento, a função *EarlyStopping()* com o parâmetro *patience*=17. O parâmetro *patiente* indica o número de épocas, após a qual nenhuma melhoria foi observada. Observa-se que, neste trabalho, foi utilizado um *look-back*=24.

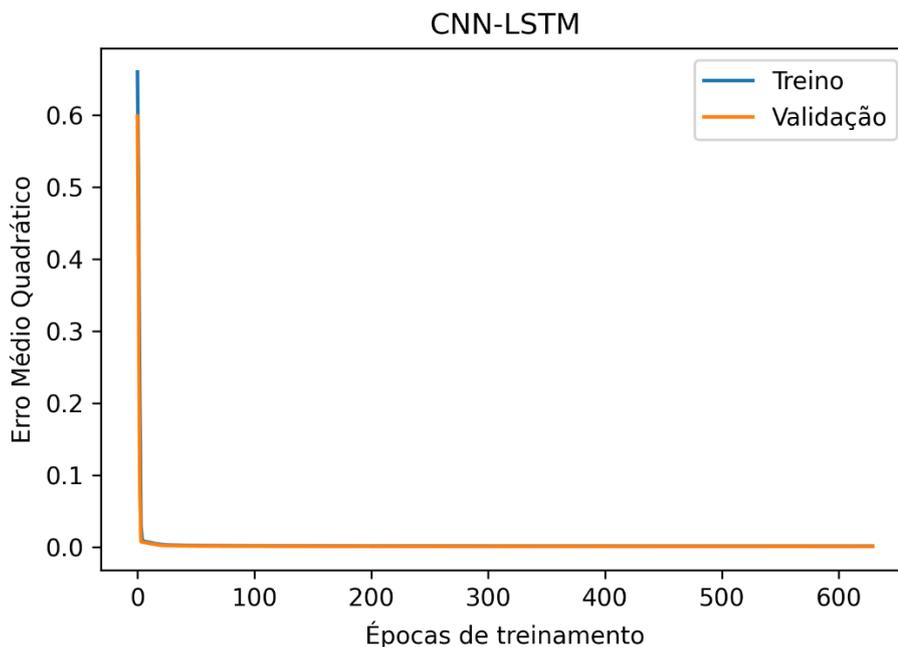
**Tabela 4.** Indicadores de desempenho (Conjunto de Validação).

Métricas	LSTM	CNN-LSTM
MAE (kWh)	359,1	336,37
RSME (kWh)	621,8	585,61
MAPE (%)	3,4	3,1
Tempo de Processamento (s)	431,7	287,4

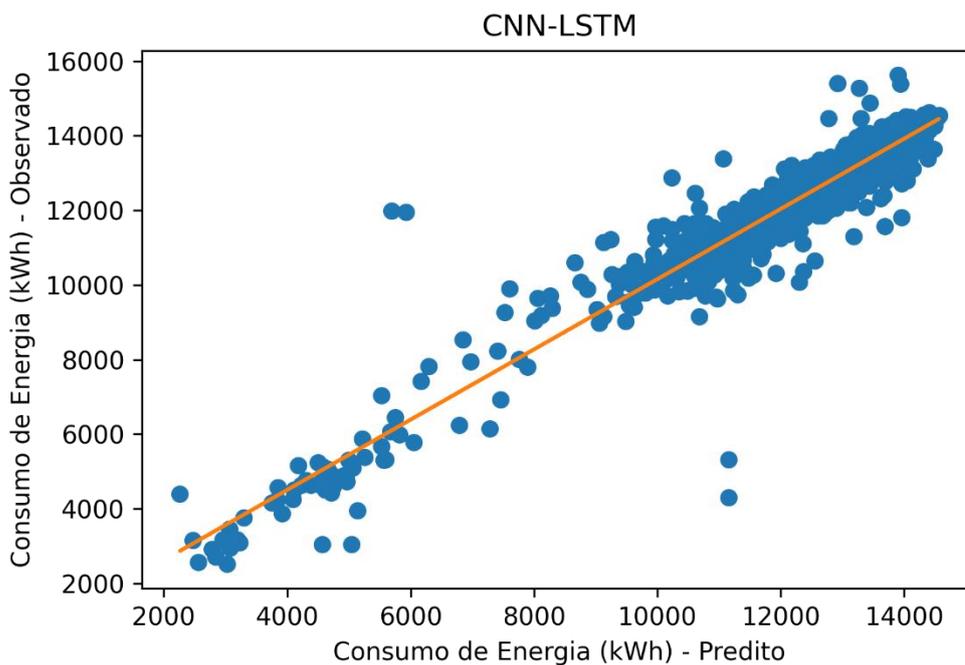
Pode-se observar, dos dados apresentados na Tabela 4, que os indicadores, MAE, RMSE e MAPE obtidos pelos modelos, são similares. Entretanto, a rede CNN-LSTM apresentou menores erros. Observa-se também que a rede CNN-LSTM apresentou um menor tempo de processamento.

Na Figura 6 apresenta-se, como exemplo, a curva de aprendizagem do modelo CNN-LSTM. Pode-se observar nesta figura a boa estabilidade na convergência das curvas de Treino e Validação.

Na sequência, na Figura 7, apresenta-se o gráfico de dispersão, dos valores preditos em relação aos valores observados, para o modelo CNN-LSTM. Pode-se observar, do gráfico, que os dados observados (CCEE) apresentam uma boa correlação com os dados preditos, já que os pontos estão próximos a linha de ajuste.

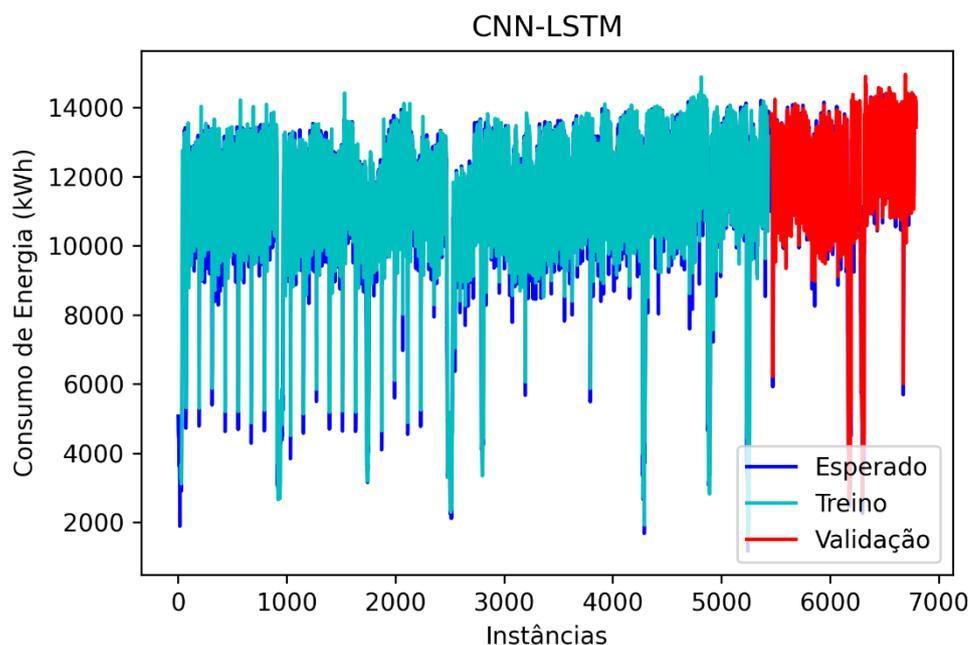


**Figura 6.** Curvas de aprendizagem de Treino e Validação: CNN-LSTM



**Figura 7.** Dados preditos em função dos dados observados: CNN-LSTM

Na Figura 8 apresentam-se os resultados das previsões, de Treinamento e Validação, para o modelo CNN-LSTM. Pode-se notar, por meio da figura, a boa aderência dos dados previstos com os dados reais.



**Figura 8.** Previsão de Treino e Validação: CNN-LSTM

Teste:

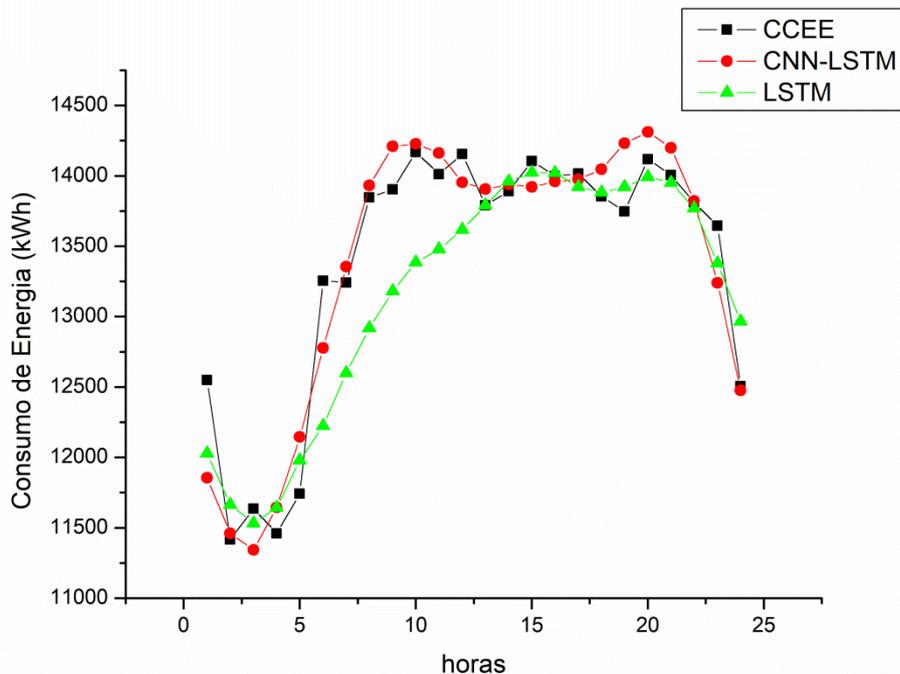
Na sequência, calcularam-se os indicadores de desempenho para as horas que não participaram da etapa de Treinamento e Validação (Conjunto de Teste) (Tabela 5).

**Tabela 5.** Indicadores de desempenho (Conjunto de Teste).

Métricas	LSTM	CNN-LSTM
MAE (kWh)	329,3	206,4
RSME (kWh)	449,3	269,3
MAPE (%)	2,5	1,5

Por meio dos resultados apresentados, na Tabela 5, conclui-se, para o conjunto de teste, que o modelo CNN-LSTM apresenta erros bem menores que o modelo LSTM. Kim e Cho (2019), também concluíram, para o consumo de energia elétrica residencial, que o modelo híbrido CNN-LSTM apresenta melhores previsões que os métodos de previsão clássicos, como o LSTM. Livieris et al. (2020) concluíram, na previsão do preço do ouro, que a utilização de camadas CNN em conjunto com camadas LSTM fornecem um impulso significativo no aumento do desempenho das previsões. Já Sun et al (2019) concluíram, na previsão do rendimento da soja, que o modelo CNN-LSTM pode superar o modelo LSTM.

Os resultados das previsões, do consumo de energia do conjunto de Teste, em termos gráficos, são apresentados na Figura 9.



**Figura 9.** Consumo de energia elétrica (Conjunto de Teste)

#### 4. CONSIDERAÇÕES FINAIS

Neste trabalho, com os dados do consumo de energia elétrica obtidos, do banco de dados da Câmara de Comercialização de Energia Elétrica, construíram-se modelos de previsão baseados nas redes LSTM e CNN-LSTM. Estes modelos passaram pelas fases de preparação de dados, definição das estruturas dos modelos, estimativas dos modelos, avaliação dos resultados dos modelos e validação dos modelos.

Quando os modelos LSTM e CNN-LSTM, implementados para prever o consumo de energia elétrica na empresa, foram aplicados ao conjunto de teste, com dados que não participaram da fase de treinamento e validação, as previsões foram bem precisas e as diferenças entre valores reais e previstos foram pequenas. Contudo, a rede híbrida CNN-LSTM obteve melhor desempenho tanto no conjunto de validação quanto no de teste.

Por fim, vale ainda destacar que, tendo em vista o crescimento do mercado livre de energia, os modelos de redes neurais, implementados neste trabalho, podem ser utilizados

para gerar informações, sobre o consumo de energia futuro, que servirão de suporte à tomada de decisão dos gestores da empresa em estudo.

Apesar dos modelos, LSTM e CNN-LSTM, apresentarem resultados adequados para uma previsão de curto prazo, sugere-se, para outro trabalho de pesquisa, proceder a estimação, com outros modelos de previsão de séries temporais, tais como, ARIMA, SARIMA, RNN, GRU, entre outros.

## REFERÊNCIAS

AMARAL, H. L. M. **Desenvolvimento de uma nova metodologia para previsão de consumo de energia elétrica de curto prazo utilizando redes neurais artificiais e decomposição de séries temporais.** Tese de Doutorado, Universidade de São Paulo, São Paulo, 2020.

BARROS, B. F.; BORELLI, R.; GEDRA, R. L. **Gerenciamento de energia: ações administrativas e técnicas de uso adequado da energia elétrica.** São Paulo: Editora Érica, 2020.

BASTIANI, M.; SANTOS, J. A. A.; SCHMIDT, C. A. P.; SEPULVEDA, G. P. L. Application of data mining algorithms in the management of the broiler production. **Geintec**, 8(4), 4574-4587, 2018.

BINOTI, R. M. L. M. S. **Redes neurais artificiais para prognose da produção de povoamentos não desbastados de Eucalipto.** Dissertação de Mestrado, Universidade Federal de Viçosa, Viçosa, 2010.

CANKURTI, S.; SUBASI, A. Comparasion of linear regression and neural network models forecasting tourist arrivals to turkey. **Eurasian Journal of Science & Engineering**, 1(1), 21-26., 2015.

CBIE (CENTRO BRASILEIRO DE INFRAESTRUTURA). **Como a eletricidade é consumida no Brasil?** Disponível em: <<https://cbie.com.br/artigos/como-a-eletricidade-e-consumida-no-brasil>>. Acesso em: 31 out. de 2021.

CCEE (Câmara de Comercialização de Energia Elétrica) **Plataforma de Sistema de Coleta de Dados de Energia (SCDE).** Disponível em: < <https://www.ccee.org.br/web/guest>>. Acesso em: 20 mar. de 2021.

CHADRAMITASARI, W.; KURNIAWAN, B.; FUJIMURA, S. Building Deep Neural Network Model for Short Term Electricity Consumption Forecasting. **In...** International Symposium on Advanced Intelligent Informatics: Revolutionize Intelligent Informatics Spectrum for Humanity, Yogyakarta, Indonesia, 2019.

GRAVES A. Towards end-to-end speech recognition with recurrent neural networks. **In...** International Conference on Machine Learning (ICML-14), Beijing, China, 2014.

HAYKIN, S. **Neural networks: a comprehensive foundation.** New Delhi: Pearson Prentice

Hall, 2001.

KIM, T. Y.; CHO, S. B. Predicting residential energy consumption using CNN-LSTM neural networks. **Energy**, 182(1), 72-81, 2019.

LIVIERIS, I. E.; PINTELAS, E.; PINTELAS; P. A. CNN-LSTM model for gold price time-series forecasting. **Neural Computing Applications**. 32(1), 17351-17360, 2020.

LUCAS, P. O. (2019) **Previsão de séries temporais de evapotranspiração de referência com redes neurais convolucionais**. Dissertação de Mestrado, Universidade Federal de Minas Gerais. Belo Horizonte, 2019.

PINHEIRO, T. C.; SANTOS, J. A. A.; PASA, L. A. Gestão da produção de frangos de corte por meio de redes neurais. **Revista Holos**, 2(1), 1-15, 2020.

PIMENTEL, F. G. **Curso de estatística experimental**. Piracicaba: Degaspari, 2000.

SANTOS, J. A. A. Aplicação de Redes Neurais na Previsão de Custos de Produção de Frangos de Corte no Estado do Paraná. **Revista FSA**, 18(1), 169-185, 2021.

SANTOS, J. A. A.; CHAUKOSKI, Y. Previsão do consumo de energia elétrica na região sudeste: Um estudo de caso usando sarima e lstm. **Revista Cereus**, 12(4), 93-104, 2020.

SANTOS, J. A. A.; CHAUCOSKI, Y. Aplicação de modelos de redes neurais artificiais na previsão do preço do alumínio. **Revista ABCustos**, 16(2), 31-49, 2021.

SEBASTIAN, S. Performance evaluation by artificial neural network using WEKA. **International Research Journal of Engineering and Technology**, 3(3), 1459-1464, 2016.

SOLIMAN, S. A.; AL-KANDARI. Electrical load forecasting modeling and model construction. Kidlington, UK: Elsevier, 2010.

SUN, J.; DI, L., SUN; Z., SHEN; Y.; LAI, Z. (2019) County-Level soybean yield prediction using deep CNN-LSTM model. **Sensors**, 19(20), 1-21, 2019.

WASSES, M.; TIARA, A. R.; RAMADHAN, F. I.; HAQ, I. N.; PRADIPTA, J. SARIMA and Artificial Neural Network models for forecasting electricity consumption of a microgrid educational building. **In...** IEEE International Conference on Industrial Engineering and Engineering Management (IEEM), Singapore, 2020.

WITTEN, H. I. **Data mining: practical machine learning tools and techniques**. Burligton: Editora Morgan Kaufmann, 2016.

YAN, K.; JI, W.; QI, M.; DU, Y. A Hybrid LSTM Neural Network for Energy Consumption Forecasting of Individual Households. **IEEE Access**, 7(1), 157633-157642, 2019.