

**PREVISÃO DE CARGA ELÉTRICA DO SUBSISTEMA
SUDESTE/CENTRO-OESTE DO SISTEMA INTERLIGADO NACIONAL
UTILIZANDO REDES NEURAIIS ARTIFICIAIS**

**ELECTRICAL LOAD FORECAST OF THE SOUTHEAST/MIDWEST
SUBSYSTEM OF THE NATIONAL INTERCONNECTED SYSTEM USING
ARTIFICIAL NEURAL NETWORKS**

Entrega dos originais à redação em: 26/12/2022

Mateus Antonio Guelfi
Bacharelado em Engenharia Elétrica

Editoração em: 15/01/2023

José Guilherme Magalini Santos Decanini
Instituto Federal de Educação, Ciência e Tecnologia de São Paulo –
Câmpus Presidente Epitácio

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, neste artigo foram desenvolvidos sistemas inteligentes para previsão de carga de curto prazo em sistemas de energia elétrica. Mais especificamente, empregaram-se como ferramentas para concepção do módulo predictor distintas, recentes e promissoras redes neurais artificiais, i.e., LSTM, Encoder-Decoder LSTM e Encoder-Decoder CNN-LSTM. Dentro desta perspectiva, realizaram-se simulações para previsão de carga para um período de 24h relativa ao subsistema Sudeste/Centro-Oeste, considerando dados de carga e dados exógenos. Os resultados evidenciam que as metodologias propostas para previsão de carga horária em um subsistema elétrico brasileiro, abarcando um período de consideráveis alterações no comportamento da curva de carga, são robustas, eficazes e de alta performance computacional.

Palavras-chave: Previsão de carga elétrica. Sistemas elétricos de potência. Redes neurais artificiais.

Electric load forecasting is a fundamental study for the operation and planning of electrical power systems. Considering the electric energy sector desregulation, the greater competitiveness and the technological and philosophical transformations arising from the design and construction of smart grids, the knowledge of the loads future behavior of the electric energy systems becomes essential for the adequate decision making process. Within this context, the researches addressing load forecasting take place in the long, medium, short and very short-term horizons. In addition, researchers and companies of 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 computational performance. Therefore, in this paper, intelligent systems were developed for short-term load forecasting in electric power systems. More specifically, distinct, recent and promising artificial neural networks were used as tools to design the predictor module, i.e., LSTM, Encoder-Decoder LSTM and Encoder-Decoder CNN-LSTM. Within this perspective, simulations were carried out to load forecast for a period of 24 hours relating to the Southeast/Midwest subsystem, considering load and exogenous data. The results show that the methodologies proposed for forecasting the hourly load in a Brazilian electrical subsystem, covering a period of considerable changes in the load curve behavior, are robust and effective with a high computing performance.

Keywords: Electrical load forecast. Electrical power systems. Artificial neural networks.

1 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.

O aumento da competitividade de mercado, as exigências impostas pela agência reguladora e a crescente exigência na qualidade do produto recebido pelos usuários corroboram para o progresso. 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), (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). Com a introdução da desregulamentação na indústria de eletricidade, as previsões se tornaram mais importantes no que se refere à investimentos em setores de distribuição, planejamento em energia elétrica e em estratégias de gerenciamento em sistemas regionais e nacionais. 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 desempenhem um papel crucial na composição destes preços, contribuindo diretamente para a indústria do abastecimento (HIPPERT; PEDREIRA; SOUZA, 2001).

Como o sistema brasileiro está em constante evolução, ao passar dos últimos anos acentuou-se a modernização dos processos de aquisição, monitoramento, controle e tomada de decisão no que tange as redes elétricas, inerentes da inserção de tecnologias que utilizam sistemas denominados inteligentes oriundos do desenvolvimento de tecnologia digital, na qual se obteve novos materiais e dispositivos que proporcionam extrema velocidade e qualidade de comunicação, e da tecnologia da informação, onde destacam-se a consolidação e concepção de técnicas de processamento de sinais.

Estes procedimentos devem ser concebidos levando-se em consideração o dinamismo inerente aos sistemas elétricos de potência. Flexibilidade, robustez, eficiência e rapidez de resposta são características imprescindíveis aos módulos previsores. Buscam-se artifícios para que se satisfaçam os requisitos relacionados à eficiência operativa em um mercado competitivo.

Dentro deste contexto, nesta pesquisa desenvolveram-se metodologias inteligentes para previsão de carga de curto prazo em sistemas elétricos de potência, mais especificamente, realiza-se a previsão de carga horária relativa ao subsistema Sudeste/Centro-Oeste do Sistema Interligado Nacional (SIN), considerando dados relativos aos anos de 2019 e 2020.

2 ESTRUTURA DA METODOLOGIA PROPOSTA

A concepção do sistema inteligente para previsão de carga tem como base a composição do banco de dados por meio de informações disponíveis no site do Operador Nacional do Sistema Elétrico (ONS). Por conseguinte, a estrutura do sistema de diagnóstico pode ser descrita sucintamente em quatro etapas: aquisição de dados; pré-processamento das informações e janelamento; aplicação de recentes e distintas arquiteturas de redes neurais artificiais para previsão de carga, e a impressão da previsão, conforme mostrado na Figura 1.

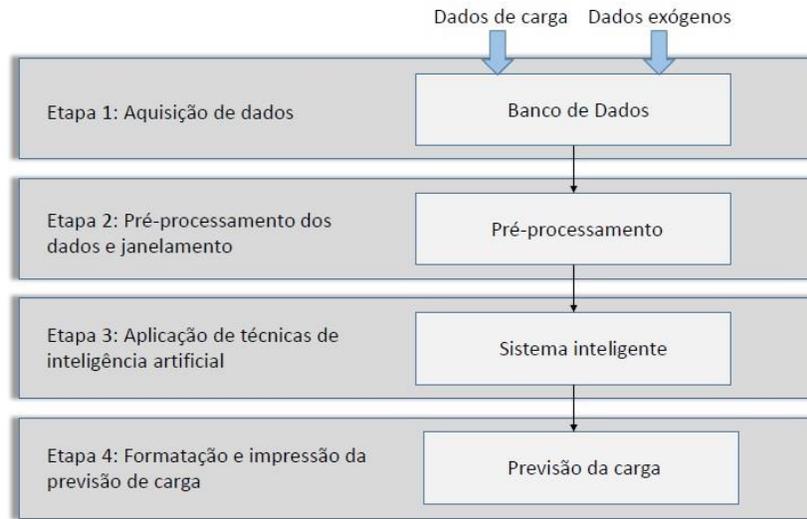


Figura 1 - estrutura da metodologia proposta para previsão de carga em sistemas elétricos de potência.

Fonte: Elaborada pelos autores.

3 REDES NEURAIAS ARTIFICIAIS

As redes neurais artificiais (RNAs) (HAYKIN, 2008) têm como característica principal “simular” o funcionamento do cérebro humano, reproduzindo artificialmente a maneira como os estímulos são processados por nossos neurônios. As RNAs com seus mecanismos de associação, generalização e auto-organização conquistaram espaço dentro do mundo moderno (FILHO, 2011).

A vantagem do uso das redes neurais é a capacidade da rede em se instruir somente através das relações existentes entre os padrões de entrada e de saída. Normalmente, os padrões de entrada são dados das cargas atuais e passadas. A saída é composta por valores da carga futura (um passo à frente). Além disso, as redes neurais possuem a capacidade de efetuar aproximações de funções contínuas com uma precisão desejada. Assim, podem ser vistas como métodos multivariados (LOPES, 2005).

3.1 Redes Neurais *Long Short Term Memory* (LSTM)

A Figura 2 apresenta uma RNN (do inglês *Recurrent Neural Networks*). Observa-se que à esquerda da Figura 2 tem-se uma RNN profunda, na qual são empilhadas múltiplas camadas de células. Já à direita da Figura 2, mostra-se como ocorre o desenvolvimento através do tempo.

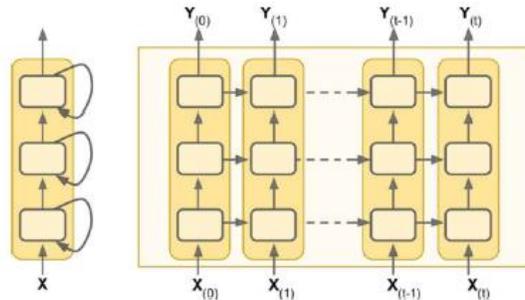


Figura 2 – *Recurrent Neural Networks*.

Fonte: Géron (2019).

As redes neurais recorrentes possuem limitações e para superar essas limitações podem usar algumas de suas variações, como por exemplo a LSTM (*Long Short Term Memory*), um tipo de rede recorrente, que pode ser usada em diversos problemas (HOCHREITER; SCHMIDHUBER, 1997).

As LSTMs ajudam a preservar o erro que pode ser copiado por tempo e camadas. Ao manter um erro constante, fazendo com que as RNNs continuem aprendendo durante vários passos de tempo, abrindo então um canal para vincular causas e efeitos remotamente (HOCHREITER; SCHMIDHUBER, 1997).

As redes LSTMs possuem informações fora do fluxo normal das RNN em uma só célula fechada. As informações podem ser armazenadas, escritas ou lidas a partir de uma única célula, como dados na memória de um computador. Fazendo com que as células tomem decisões sobre o que armazenar, e quando permitir leituras, gravações e exclusões, através de portões abertos e fechados. Ao contrário do armazenamento digital em computadores, no entanto, esses portões são analógicos, implementados com a multiplicação de elementos por sigmóides, que estão todos no intervalo de]0,1[. Analógico tem a vantagem sobre o digital por ser diferenciável e, portanto, adequado para a *backpropagation* (HOCHREITER; SCHMIDHUBER, 1997).

3.1.1 Célula LSTM

A célula da LSTM poderá ser utilizada de maneira muito semelhante a uma célula básica se considerá-la como uma caixa preta, porém com um desempenho muito melhor, convergência no treinamento mais rápida e detectará dependências de longo prazo (GÉRON, 2019). Sua arquitetura básica é mostrada na Figura 3.

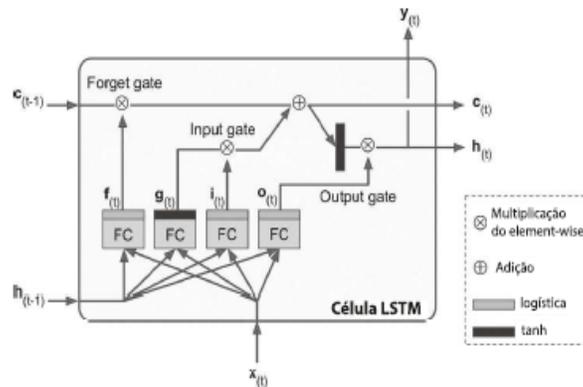


Figura 3 – Célula LSTM.

Fonte: Géron (2019).

A célula LSTM pode ter seu estado dividido em dois vetores: $h_{(t)}$ e $c_{(t)}$, podendo ser representado $h_{(t)}$ como o estado de curto prazo e $c_{(t)}$ como o estado de longo prazo (GÉRON, 2019).

3.2 Redes Neurais Convolucionais

As redes neurais convolucionais, do inglês *Convolutional Neural Networks* (CNNs), são um tipo específico de rede neural artificial proposta inicialmente por Yann LeCun (LECUN et al., 1998). Demonstrando-se muito eficazes desde sua criação para resolver problemas que envolvem classificação, provando ser uma boa alternativa quando comparado aos métodos tradicionais de resolução desse tipo de problema. A CNN possui também desvantagens como o fato de haver a necessidade de uma grande quantidade de dados para a extração dos padrões (RODRIGUES, 2018).

Convolução consiste em aplicar uma matriz “núcleo” (*kernel*) a uma matriz maior percorrendo-a, formando uma nova, no qual cada elemento da nova matriz é a soma da multiplicação em termos de elementos do *kernel*, formando uma subseção da matriz maior. Este *kernel* é aplicado repetidamente à medida que percorre através de uma matriz/imagem. Sendo feito com um número pré-especificado de *kernels* para que diferentes características surjam.

A LeNet-5, famosa arquitetura introduzida por Yann LeCun, é amplamente utilizada pelos bancos para reconhecer números preenchidos a mão em cheques. Esta arquitetura utiliza camadas conectadas e funções de ativação empregadas em outras arquiteturas de redes, mas também introduz novos blocos de construção: camadas convolucionais (do inglês *convolutional layers*) e camadas pooling (do inglês *pooling layers*) (GÉRON, 2019).

3.2.1 Camada Convolutiva

A camada convolutiva em uma CNN é responsável por extrair as informações de entrada ou *features*. O processo no qual essas *features* são extraídas se dá por meio de filtros convolucionais (ou *kernels* de convolução) de tamanhos reduzidos, no qual os filtros percorrem os dados de entrada nos tamanhos de sua dimensão, realizando assim a operação de convolução sobre eles (RODRIGUES, 2018).

Durante o período de treinamento da rede, os filtros vão se ajustando de tal modo a disparar quando as entradas conterem determinadas características comuns aos lotes de entrada. Conforme o treinamento da rede, os filtros aprendem estruturas cada vez mais complexas, ou seja, quanto mais filtros convolucionais, mais *features* são extraídas da entrada (RODRIGUES, 2018).

3.2.2 Camada *Pooling*

A chamada camada *pooling* consiste basicamente em reduzir o tamanho dos dados de entrada, sendo normalmente empregada após uma camada convolucional, com isso as próximas camadas de convolução receberão uma outra forma de representação dos dados, possibilitando assim a rede aprender diversas outras representações dos dados, e com isso evitar o *overfitting*, que surge quando a rede aprende demais com seus dados de treinamento e conseqüentemente acaba-os decorando (RODRIGUES, 2018).

Uma técnica amplamente empregada para executar o *pooling* é intitulada de *max pooling*, nessa técnica, reduz-se subpartes dos dados originais pelo maior valor encontrado nessas sub-regiões, reduzindo deste modo a quantidade de dados por um fator $m \times n$. Esta técnica beneficia a rede neural, de modo que reduz a quantidade de dados para a camada seguinte e melhora a regularização da rede, reduzindo significativamente o custo de memória e processamento (RODRIGUES, 2018).

3.2.3 Camada Totalmente Conectada

As camadas totalmente conectadas se situam no final da rede, onde as *features* extraídas nas camadas de convolução anteriores são utilizadas para realizar a classificação (RODRIGUES, 2018).

As arquiteturas CNNs típicas empilham algumas camadas convolucionais, depois uma camada *pooling*, depois outras camadas convolucionais, depois outra camada *pooling*, e assim por diante. A imagem vai ficando cada vez menor à medida em que se avança pela rede, mas também ficando mais profunda, ou seja, com mais informações, consultando a Figura 4 pode-se observar essa arquitetura típica.

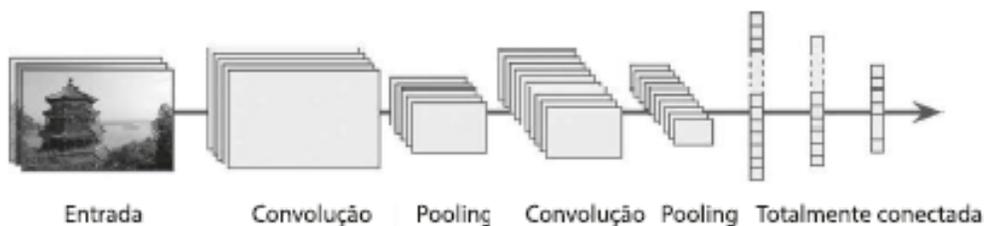


Figura 4 – Arquitetura CNN típica.

Fonte: Géron (2019).

3.3 Autoencoders

Segundo Géron (2019) os *autoencoders* são um tipo de rede neural capaz de aprender representações eficientes dos dados de entrada, como codificações, sem supervisão (ou seja, o conjunto de dados não possuirá rótulo). Estas codificações geralmente detêm uma dimensionalidade muito menor do que os estados de entrada, o que as torna úteis para redução da dimensionalidade. O mais importante, os *autoencoders* atuam como detectores de características poderosos e são utilizados para pré-treinamento não supervisionado de redes neurais profundas. Por fim, eles são capazes de gerar novos dados aleatoriamente que são muito semelhantes aos dados de treinamento. A Figura 5 apresenta a rede relativa aos *autoencoders*.

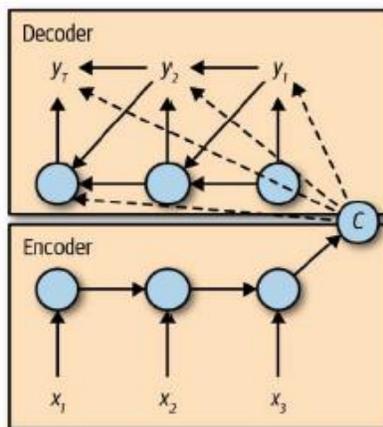


Figura 5 – Autoencoders.

Fonte: Nielsen (2019).

4 METODOLOGIA

O sistema inteligente para previsão de carga em sistemas elétricos de potência foi concebido de forma modular o que propicia maior flexibilidade sendo basicamente desenvolvido em quatro processos: composição do banco de dados, pré-processamento das informações e janelamento, aplicação de técnicas de inteligência artificial, mais especificamente, redes neurais artificiais, para a devida previsão horária de carga do subsistema Sudeste/Centro-Oeste do Sistema Interligado Nacional, e por fim, a impressão dos resultados.

4.1 Banco de dados

A composição do banco de dados deu-se por meio da aquisição das informações relativas à carga horária do subsistema Sudeste/Centro-Oeste, disponível no site do ONS, a fim de subsidiar o projeto com informações atuais e de alta confiabilidade. 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.

4.2 Pré-processamento dos dados e janelamento

A qualidade de uma boa previsão depende da escolha das entradas, ou seja, as variáveis mais significativas para poder realizar a previsão, a fim de compreender o comportamento do sistema para que os métodos de inteligência artificial possam aprender por meio do processo de treinamento. Para tanto é preciso determinar quais grandezas que impactam no sistema, além da própria carga. O comportamento da curva de carga depende diretamente de fatores diversos. Assim, determinar quais são esses fatores é de extrema relevância para o método proposto. Esses fatores podem ser denominados de variáveis exógenas, e dentre elas podemos citar fatores sociais, econômicos e climáticos.

Dentro deste contexto, métricas estatísticas foram empregadas para determinar o grau de dissimilaridade das possíveis variáveis de entrada do sistema inteligente. Primeiramente, realizou-se a análise da variável “Dias da Semana” para verificação do comportamento (similaridade/dissimilaridade) da carga, como evidenciado pela Figura 6.

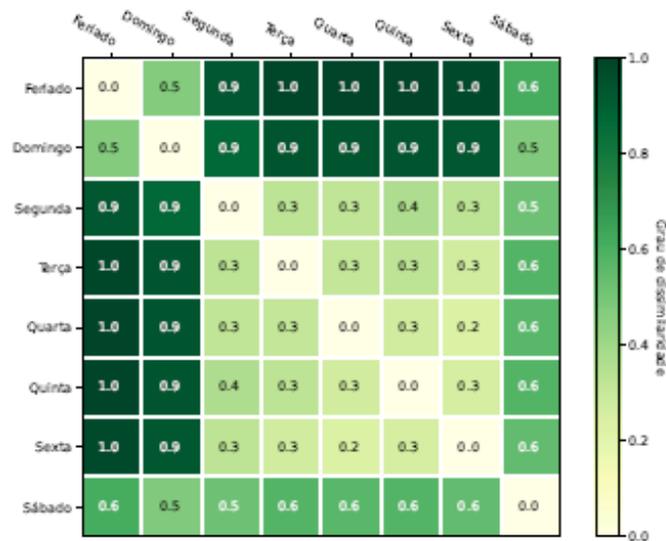


Figura 6 – Distância Euclidiana dos valores de carga relativos aos dias da semana.

Fonte: Elaborada pelos autores.

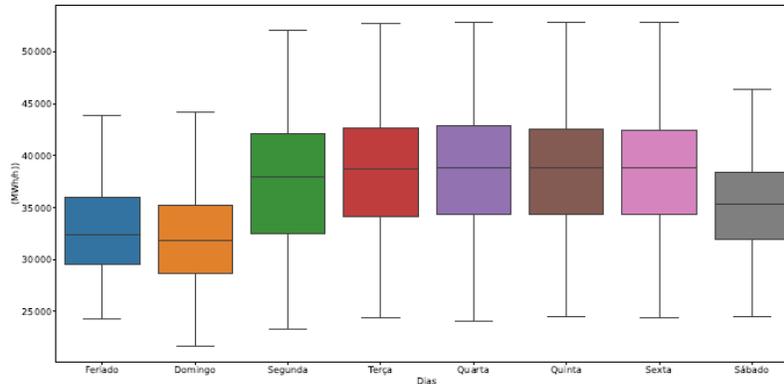


Figura 7 – Comportamento da carga ao longo da semana.

Fonte: Elaborada pelos autores.

Como se pode observar na Figura 6, os dias do meio da semana possuem um grau de dissimilaridade baixo entre si. Também evidenciado pelo *boxplot* apresentado na Figura 7, na qual nota-se um tamanho de caixa relativamente curto, ou seja, compacticidade entre os dados correspondentes aos dias do meio da semana, apresentando inclusive mediana similar entre os mesmos. Nesta perspectiva, pode-se a priori considerar uma representação única para os dias “Segunda”, “Terça”, “Quarta”, “Quinta” e “Sexta” no que tange a variável “Dias da Semana”. Como também pode se observar na Figura 6 há um grande grau de dissimilaridade no que tange os dias definidos como “Feriado”, “Domingo” e “Sábado”, conjecturando outras três possíveis codificações para a variável de entrada “Dias da Semana”. Ressalta-se que os dados apresentados correspondem à uma amostra de trezentos horas para fins de apresentação e da aplicação de métodos estatísticos para definição de possíveis variáveis de entrada do sistema inteligente. Similarmente, realizou-se a análise de dissimilaridade e comportamento da carga quanto aos meses e estações climáticas do ano.

Deve-se ressaltar que no ano de 2020 houve a pandemia de COVID-19 que impactou no comportamento da carga, sendo assim, apesar de não ser comumente o emprego de variáveis exógenas de âmbito econômico para previsão de carga de curto prazo verificou-se se indicador econômico, *i.e.*, Indicador Antecedente Composto da Economia Brasileira da FGV/Ibre (IACE), contribui positivamente com a previsão, visto as variações de consumo não habituais (em tempo, período e carga).

Nesta etapa de pré-processamento realizou-se a normalização dos dados de maneira a ser condizente para entradas das redes neurais artificiais, visando se obter no processo de treinamento uma maior capacidade de aprendizado das mesmas, e conseqüentemente que se resulte em alta performance no processo de teste. Por conseguinte, os cálculos arrolados abaixo foram efetuados para se estabelecer a normalização dos padrões de entrada.

$$\bar{x} = \frac{1}{n} \sum_{k=1}^n x_k \quad (1)$$

$$\sigma = \sqrt{\frac{1}{n} \sum_{k=1}^n (x_k - \bar{x})^2} \quad (2)$$

$$x_{norm} = \frac{(x_k - \bar{x})}{\sigma} \quad (3)$$

Assim, definiu-se a composição dos padrões de entrada do sistema inteligente, os quais são compostos por informações relativas à: carga, dia da semana, mês do ano, mínimo, média e máximo da janela, e considerar-se-á o padrão de entrada com e sem a inclusão da variável econômica, todas devidamente codificadas e normalizadas para apresentação à rede neural artificial.

Por fim, para a apresentação dos padrões de entrada para as redes neurais artificiais, empregou-se a técnica de janelamento das sequências, considerando uma janela de 48 horas anteriores a fim de se obter um passo de previsão de 24 horas futuras.

4.3 Sistemas Inteligentes Previsores de Carga

Nesta subseção serão apresentados os sistemas inteligentes previsores de carga elétrica. Ressalta-se que cada módulo predictor foi empregado para prever um passo de 24 horas à frente por meio de três arquiteturas distintas de redes neurais artificiais, *i.e.*, rede LSTM, rede Encoder-Decoder LSTM e rede Encoder-Decoder CNN-LSTM.

Com intuito de se obter uma melhor performance dos sistemas inteligentes propostos foram empregadas ferramentas que propiciam uma otimização no processo de aprendizagem da rede. A primeira, intitulada *Early Stopping* da biblioteca Abadi et al. (2015), é empregada para que não haja *overfitting* (“Sobretreinamento”), em que a rede neural decora os dados quando na verdade deveria aprender com eles, devido ao número excessivo de épocas, e nem *underfitting* (“Subtreinamento”), quando não há aprendizado suficiente para a capacidade de generalização. A segunda ferramenta utilizada no presente trabalho 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.

O treinamento das redes neurais artificiais supracitadas foi realizado utilizando o banco de dados presente no endereço <<https://github.com/MateusGuelfi/Banco-de-Dados>>, sendo que 80% dos dados foram empregados para o treinamento e 20% para o teste.

4.3.1 Rede LSTM

A arquitetura proposta para a previsão de carga utilizando a rede neural LSTM é mostrada na Figura 8. Observa-se que as camadas consistem nas células da rede que tem como objetivo, após o devido treinamento, prever corretamente a carga elétrica do subsistema Sudeste/Centro-Oeste.

Além das células da LSTM previamente apresentadas, empregou-se como explicitado outras *layers* e função de ativação.

- *Return Sequence*: Quando em estado verdadeiro, retorna para a rede todos os estados ocultos da rede a cada passo de tempo;
- ReLU: função de ativação, na qual é uma unidade linear retificada, definida como:

$$f(x) = \max(0, x) \quad (4)$$

- Dense: Semelhante às camadas totalmente conectadas das redes convolucionais, ela é uma camada densamente conectada.

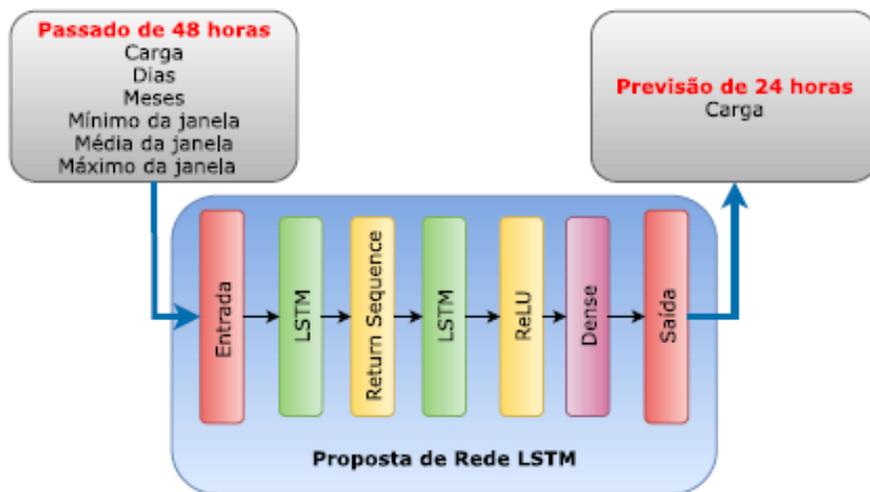


Figura 8 – Rede LSTM proposta para a previsão de carga.

Fonte: Elaborada pelos autores.

4.3.2 Rede Encoder-Decoder LSTM

A arquitetura empregada na previsão de carga utilizando a rede neural Encoder-Decoder LSTM é apresentada na Figura 9. Como abordado na proposta anterior foram empregadas outras *layers* e função de ativação, além das já abordadas destacam-se:

- *Repeat Vector*: esta *layer* adiciona uma dimensão extra ao conjunto de dados;
- *TimeDistributed*: consiste em aplicar a mesma operação às camadas a cada fatia temporal de uma entrada.



Figura 9 – Rede Encoder-Decoder LSTM proposta para a previsão de carga.

Fonte: Elaborada pelos autores.

4.3.3 Rede Encoder-Decoder CNN-LSTM

A arquitetura proposta para a previsão de carga utilizando a rede neural Encoder-Decoder CNN-LSTM é disposta na Figura 10. A concepção deste módulo predictor deu-se por meio da rede convolucional, da LSTM e de Autoencoders, conjuntamente com outras *layers* e função de ativação. Nesta perspectiva, além das previamente explicitadas, cita-se:

- *Flatten*: provoca um achatamento nos dados, adicionando uma dimensão de canal extra.

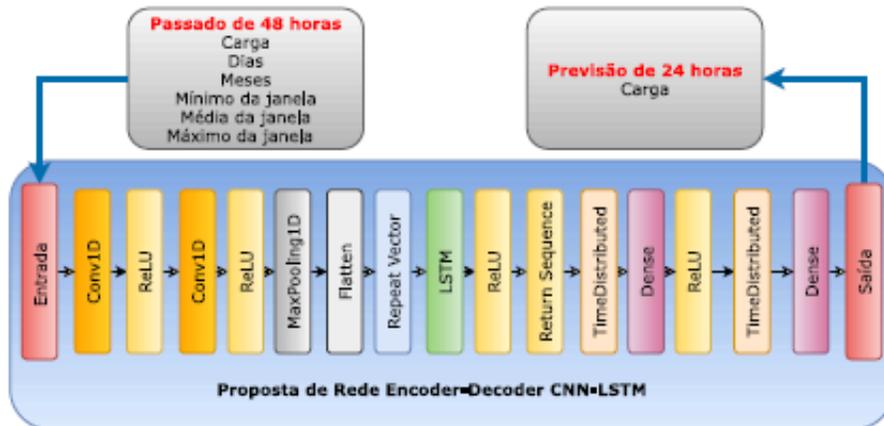


Figura 10 – Rede Encoder-Decoder CNN-LSTM proposta para a previsão de carga.

Fonte: Elaborada pelos autores.

Ressalta-se que para cada sistema inteligente predictor supracitado realizou-se também a inclusão do índice IACE como variável de entrada.

5 RESULTADOS

Os sistemas inteligentes propostos para previsão de carga horária, relativa a 24 horas futuras, no que tange o subsistema Sudeste/Centro-Oeste do Sistema Interligado Nacional apresentou eficácia e robustez às dificuldades comumente encontradas devido ao dinamismo do comportamento da carga. Ressalta-se que o período em análise compreende também o surgimento da pandemia de COVID-19 que impactou no comportamento da carga.

Por conseguinte, os resultados apresentados são correspondentes à performance dos sistemas inteligentes concebidos via linguagem Python, considerando os parâmetros previamente estabelecidos nas seções anteriores. Dentro desta abordagem, apresentam-se os resultados obtidos para cada rede proposta por meio de índices de desempenho comumente empregados na literatura especializada e pelos órgãos reguladores, e via análise gráfica.

5.1 Sistema Previsor Composto por Rede Neural Artificial LSTM

Os resultados relativos à rede LSTM com janela de entrada de 48 horas e previsão de carga de 24 horas à frente, sem a inclusão da variável econômica, estão apresentados na Tabela 1.

Tabela 1 – Índices de desempenho do sistema previsor composto por rede neural artificial LSTM sem a inclusão de variável econômica.

	MAE	RMSE	MAPE
Etapa de Teste	1315,80	1880,24	3,45

Fonte: Elaborada pelos autores.

Na Figura 11 constam as curvas de carga real e prevista, considerando um período de uma semana de análise.

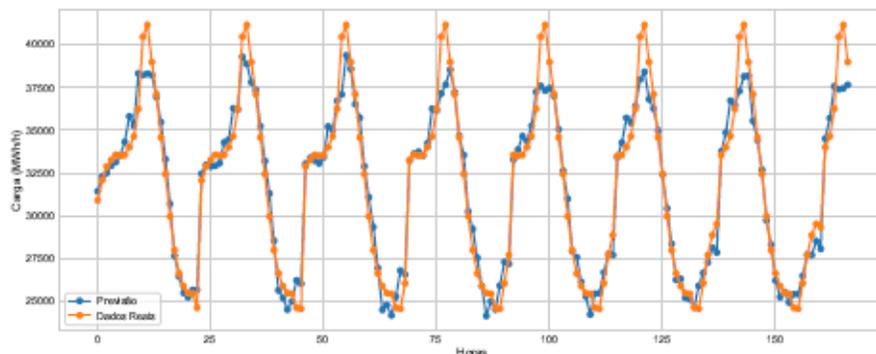


Figura 11 – Previsão de carga por um período de uma semana empregando a rede neural artificial LSTM – sem a inclusão de variável econômica.

Fonte: Elaborada pelos autores.

Considerando a inserção da variável econômica, IACE, também como entrada do sistema predictor obtiveram-se os resultados apresentados na Tabela 2 e Figura 12.

Tabela 2 – Índices de desempenho do sistema predictor composto por rede neural artificial LSTM com a inclusão de variável econômica.

	MAE	RMSE	MAPE
Etapa de Teste	1328,13	1901,59	3,48

Fonte: Elaborada pelos autores.

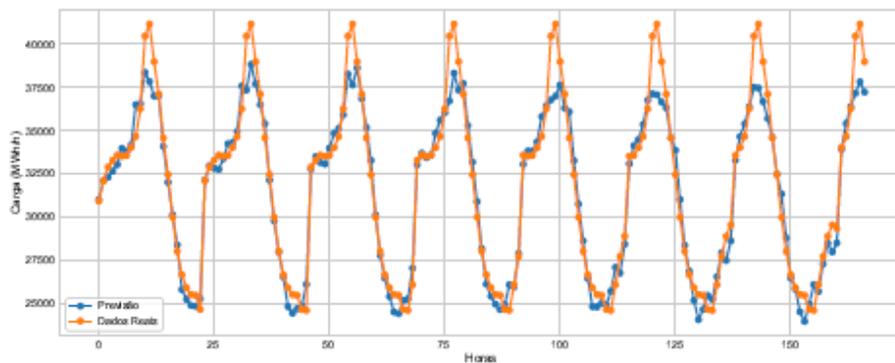


Figura 12 – Previsão de carga por um período de uma semana empregando a rede neural artificial LSTM – com a inclusão de variável econômica.

Fonte: Elaborada pelos autores.

5.2 Sistema Predictor Composto por Rede Neural Artificial Encoder-Decoder LSTM

O sistema predictor composto por rede neural artificial Encoder-Decoder LSTM com janela de entrada de 48 horas e previsão de carga de 24 horas à frente, sem a inclusão da variável econômica, proveu os resultados mostrados na Tabela 3.

Tabela 3 – Índices de desempenho do sistema predictor composto por rede neural artificial Encoder-Decoder LSTM sem a inclusão de variável econômica.

	MAE	RMSE	MAPE
Etapa de Teste	1131,33	1698,30	2,96

Fonte: Elaborada pelos autores.

As curvas de carga real e prevista, considerando um período de uma semana de análise, são apresentadas na Figura 13.

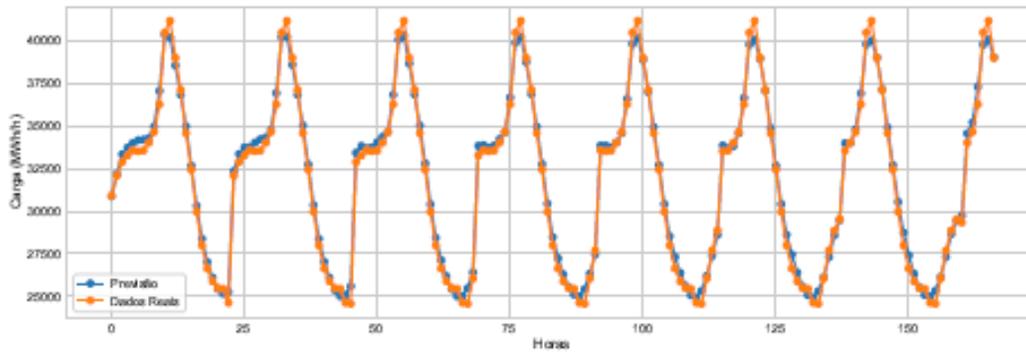


Figura 13 – Previsão de carga por um período de uma semana empregando a rede neural artificial Encoder-Decoder LSTM – sem a inclusão de variável econômica.

Fonte: Elaborada pelos autores.

Com a inclusão da variável econômica, IACE, também como entrada do sistema predictor obtiveram-se os resultados apresentados na Tabela 4 e Figura 14.

Tabela 4 – Índices de desempenho do sistema predictor composto por rede neural artificial Encoder-Decoder LSTM com a inclusão de variável econômica.

	MAE	RMSE	MAPE
Etapa de Teste	1315,02	1864,50	3,43

Fonte: Elaborada pelos autores.

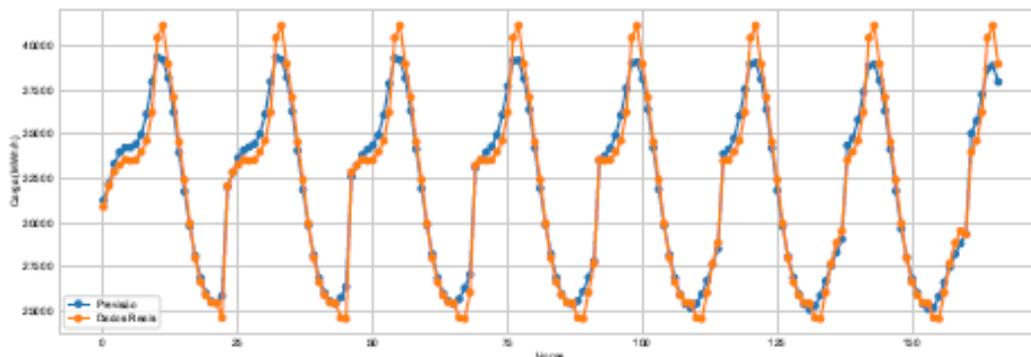


Figura 14 – Previsão de carga por um período de uma semana empregando a rede neural artificial Encoder-Decoder LSTM – com a inclusão de variável econômica.

Fonte: Elaborada pelos autores.

5.3 Sistema Previsor Composto por Rede Neural Artificial Encoder-Decoder CNN-LSTM

O sistema previsor composto por rede neural artificial Encoder-Decoder CNN-LSTM com janela de entrada de 48 horas e previsão de carga de 24 horas à frente, sem a inclusão da variável econômica, apresentou os resultados dispostos na Tabela 5.

Tabela 5 – Índices de desempenho do sistema previsor composto por rede neural artificial Encoder-Decoder CNN-LSTM sem a inclusão de variável econômica.

	MAE	RMSE	MAPE
Etapa de Teste	1151,81	1697,40	3,03

Fonte: Elaborada pelos autores.

As curvas de carga real e prevista, considerando um período de uma semana de análise, são apresentadas na Figura 15.

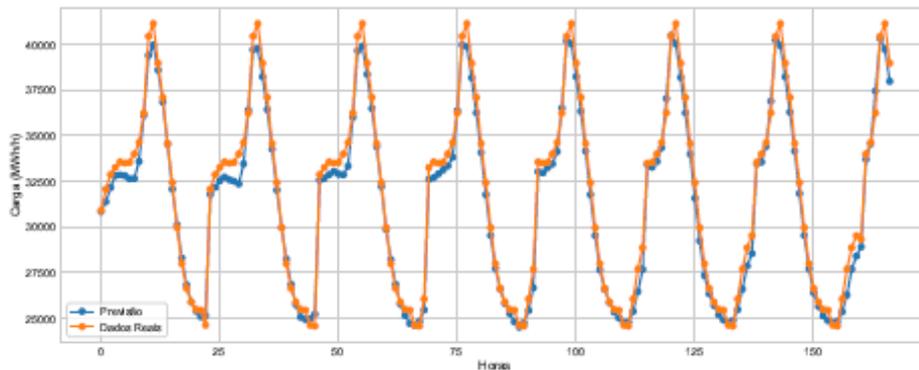


Figura 15 – Previsão de carga por um período de uma semana empregando a rede neural artificial Encoder-Decoder CNN-LSTM – sem a inclusão de variável econômica.

Fonte: Elaborada pelos autores.

Com a inclusão da variável econômica, IACE, também como entrada do sistema previsor obtiveram-se os resultados apresentados na Tabela 6 e Figura 16.

Tabela 6 – Índices de desempenho do sistema previsor composto por rede neural artificial Encoder-Decoder CNN-LSTM com a inclusão de variável econômica.

	MAE	RMSE	MAPE
Etapa de Teste	1450,90	2021,51	3,79

Fonte: Elaborada pelos autores.

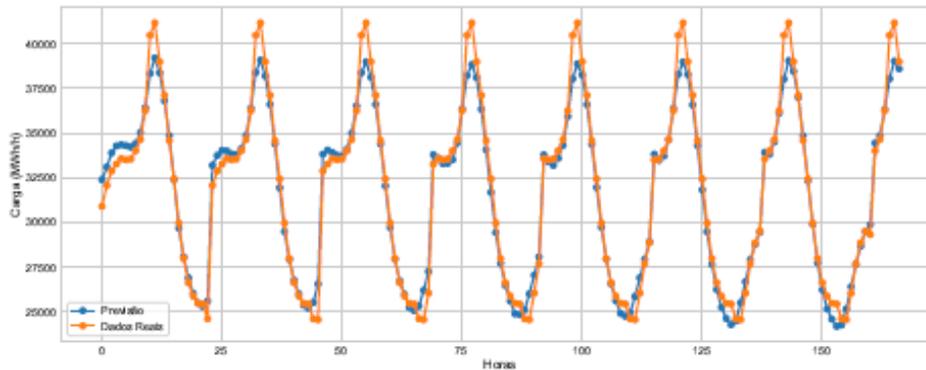


Figura 16 – Previsão de carga por um período de uma semana empregando a rede neural artificial Encoder-Decoder CNN-LSTM – com a inclusão de variável econômica.

Fonte: Elaborada pelos autores.

6 CONCLUSÕES

Neste artigo foram concebidos sistemas inteligentes empregando modernas técnicas de inteligência artificial, *i.e.*, redes neurais artificiais recentes e promissoras, para previsão de carga em sistemas elétricos de potência. Dentro deste contexto, foram desenvolvidos módulos previsores de carga empregando redes neurais profundas, com diversas camadas ocultas com distintos tipos de *layers*.

A fim de subsidiar o sistema inteligente com informações atuais de alta confiabilidade compôs-se o banco de dados por meio de informações relativas à carga horária do subsistema Sudeste/Centro-Oeste do Sistema Interligado Nacional, disponível no site do ONS, as quais foram pré-processadas objetivando fornecer à rede padrões de entrada normalizados e adequados para se obter uma maior performance do sistema predictor.

Por conseguinte, desenvolveram-se três sistemas inteligentes para previsão de carga com passo de vinte e quatro horas à frente. Os resultados obtidos são extremamente promissores (MAPE<4%), sendo que a rede neural Encoder-Decoder LSTM apresentou uma pequena vantagem quanto ao desempenho (MAPE < 3%), evidenciando assim a capacidade dos modelos previsores concebidos realizarem as previsões de carga com alta acurácia, o que propicia confiabilidade e segurança para a operação e o planejamento dos sistemas elétricos de potência, provendo deste modo maior simplicidade à rotina diária dos operadores.

Por fim, destaca-se que os sistemas inteligentes previsores de carga obtiveram MAPE substancialmente menor que 5%, valor este utilizado como referência por órgãos reguladores e que a inclusão da variável econômica não ocasionou alterações significativas no desempenho dos módulos previsores.

AGRADECIMENTOS

Os autores agradecem à Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP) e ao Instituto Federal de Educação, Ciência e Tecnologia de São Paulo (IFSP) pelo apoio financeiro e suporte fornecidos para o desenvolvimento desta pesquisa.

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>>>.
- GÉRON, A. **Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: Concepts, tools, and techniques to build intelligent systems**. [S.l.]: O'Reilly Media, 2019.
- HAYKIN, S. **Neural Networks and Learning Machines**. 3rd. chapter 4. [S.l.]: Pearson Education, 2008.
- 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.
- HOCHREITER, S.; SCHMIDHUBER, J. Long short-term memory. **Neural computation**, MIT Press, v. 9, n. 8, p. 1735–1780, 1997.
- LECUN, Y. et al. Gradient-based learning applied to document recognition. **Proceedings of the IEEE**, IEEE, v. 86, n. 11, p. 2278–2324, 1998. Disponível em: <<http://yann.lecun.com/exdb/publis/pdf/lecun-01a.pdf>>.
- 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.

RODRIGUES, D. A. **Deep Learning e redes neurais convolucionais: reconhecimento automático de caracteres em placas de licenciamento automotivo.** 37 f. Monografia (Graduação) — Universidade Federal Da Paraíba, João Pessoa, 2018.

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.]