

Modelo Regressivo e Inteligência Artificial para Previsão de Carga no Longo Prazo: Um Estudo de Caso

Bruno K. Hammerschmitt*. Felipe C. Lucchese*. Fernando G. K. Guarda**. Alzenira R. Abaide*

*Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Santa Maria, RS – BRA
(e-mail: brunokhammer@hotmail.com).

*Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Santa Maria, RS – BRA
(e-mail: felipecluchese@gmail.com).

**Colégio Técnico Industrial, Universidade Federal de Santa Maria, RS – BRA (e-mail: fernando.guarda@ufsm.br).

*Programa de Pós-Graduação em Engenharia Elétrica, Universidade Federal de Santa Maria, RS – BRA
(e-mail: alzenira@ufsm.br).

Abstract: The load forecasting for an electrical system is the basis for expansion projections in generation, transmission and distribution sectors, and also for planning, operation and control. The errors minimization of load forecasting is brought with the reduction of costs and improvement of the general performance of the sectors involved, in such a way as to guarantee the quality of the services provided by the system, and to keep the operation safe and reliable. In this sense, the proposed study consists on carrying out the load forecasting of the Brazil's southern subsystem using three regression models (neutral, optimistic and pessimistic), evaluating the performance of each model considering their trend curve and deviations (maximum and minimum) compared with load data samples. In addition, the load forecasting will be performed from a Multi-Layer Perceptron (MLP) artificial neural network considering the same load data, in order to evaluate the accuracy of the model. Afterwards, the regression model which presents the best performance will be combined with the MLP, extending the forecasting the future load with a long-term horizon, based on the current conjuncture of the Brazilian electricity sector.

Resumo: A previsão de carga para um sistema elétrico é a base para as projeções de expansão do setor de geração, transmissão e distribuição, assim como para as questões de planejamento, operação e controle. A minimização dos erros da previsão de carga traz consigo a redução de custos e melhoria de desempenho geral dos setores envolvidos, de tal forma a garantir a qualidade dos serviços prestados pelo sistema, e manutenção da operação segura e confiável. Neste sentido, o estudo proposto consiste em realizar a previsão de carga do subsistema sul brasileiro, fazendo o uso de três modelos de regressão (neutro, otimista e pessimista), avaliando o desempenho dos modelos considerando a sua curva de tendência e seus desvios (máximo e mínimo) em comparação com amostras de dados de carga. Adicionalmente, será realizada a previsão de carga a partir de uma rede neural *Multi-Layer Perceptron* (MLP) considerando os mesmos dados de carga, avaliando a precisão do modelo. Após, será realizada a junção do modelo de regressão, que apresentar melhor desempenho, com a MLP, fazendo a previsão de carga futura com um horizonte de longo prazo, com base na conjuntura atual do setor elétrico brasileiro.

Keywords: Load Forecasting; Regression Model; Multi-Layer Perceptron Artificial Neural Network; Artificial Intelligence; Long-Term Planning.

Palavras-chaves: Previsão de Carga; Modelo de Regressão; Rede Neural Perceptron Multicamadas; Inteligência Artificial; Planejamento de Longo Prazo.

1. INTRODUÇÃO

Os estudos de previsão de carga vêm se tornando fundamentais na compra e venda de eletricidade, tanto na geração, transmissão e distribuição de energia elétrica. Essas previsões também envolvem consumidores industriais, comerciais e residenciais, com o intuito de suprir as necessidades de mercado, minimizando as perdas ou até a escassez de energia elétrica. As variações do mercado de

energia elétrica tem natureza complexa, pois possuem estreita relação com fatores econômicos locais e nacionais, cenários políticos, fatores sociais, culturais, tecnológicos, e que por consequência atingem o consumo de eletricidade (Xue *et al.*, 2018).

A previsão de carga considera diferentes horizontes e é essa característica que define sua aplicação para as empresas de energia. Esses horizontes são geralmente classificados em:

longo, médio, curto e curtíssimo prazo. De maneira geral, previsões em longo prazo podem ser aplicadas no planejamento técnico e financeiro das concessionárias de energia elétrica, e no planejamento da expansão do sistema que se estendem a um horizonte de um a vários anos. Previsões em médio prazo possuem intervalo de um dia a um ano, são aplicados no planejamento da expansão da rede e da operação de sistemas de potência ou ainda no despacho da geração. As previsões de curto prazo são utilizadas na elaboração de planos da manutenção e operação de sistemas de potência, que atentam para um horizonte de algumas horas a um dia. E por último, as previsões no curtíssimo prazo possuem aplicação na operação em tempo real de sistemas de controle e operação de redes elétricas que se estende para o conceito de *Smart Grids* (Citroen, Ouassaid e Maaroufi, 2015; Mendes, Beluco e Canales, 2017).

Vários fatores contribuem para a adequação de um bom modelo para previsão de carga, tais como, feriados e dias atípicos, fatores meteorológicos, fatores sazonais, horário de ponta e diferentes fusos horários (Silva *et al.*, 2010). Além disso, envolver análises estatísticas e ferramentas matemáticas no desenvolvimento de técnicas de previsão mais precisas, favorecem as previsões de mercado e mapeamento do perfil dos consumidores para dimensionar as necessidades de investimento de expansão da rede (Goswami, Ganguly e Sil, 2018).

A previsão de carga no longo prazo desempenha um papel determinante no planejamento, pois tem um papel importante para a operação segura e econômica do sistema de energia (Sreekumar *et al.*, 2016). Uma das técnicas mais simples e eficazes para previsão de carga no horizonte de longo prazo são os modelos de regressão, que podem ser empregados somente a partir de dados de carga do sistema, ou também em conjunto com outros dados históricos (índices econômicos, produto interno bruto, crescimento populacional) (Sreekumar *et al.*, 2016; Xue *et al.*, 2018; Lindberg *et al.*, 2019).

Com a evolução das técnicas de inteligências artificial associado ao aprendizado de máquinas, houve uma grande propagação dessas técnicas por meio das Redes Neurais Artificiais (RNA) que possuem vasta aplicabilidade nos modelos de previsão de carga, com altos índices de precisão (Baek, 2019; Han *et al.*, 2019; Sehovac e Grolinger, 2020; Sausen *et al.*, 2021). Uma destas técnicas muito utilizada em estudos de previsão de carga são as RNA *Multi-Layer Perceptron* (MLP), que a partir do aprendizado supervisionado possui capacidade de generalizar soluções e que podem modelar relações complexas e não lineares, que a torna apta para modelar as sazonalidades do consumo e de carga global (Barbosa *et al.*, 2018; Tajeuna, Bouguessa e Wang, 2018; Dudek e Pelka, 2021).

Deste modo, este artigo tem por objetivo realizar a previsão de carga em um horizonte de longo prazo utilizando um modelo de regressão associado a RNA MLP. Primeiramente, será realizada a previsão de carga para um horizonte de médio prazo, onde serão estimados os desvios máximos, mínimos, e a curva de tendência de três modelos de regressão (neutro, otimista e pessimista), fazendo ponderações dos modelos e avaliando o seu sucesso. Em seguida, será

realizada a previsão de carga pela MLP considerando o mesmo histórico de dados, avaliando o seu desempenho. Após isto, será efetuada a junção do modelo de regressão que obteve melhores resultados com a MLP, estendendo a previsão de carga para um horizonte de longo prazo, considerando a atual conjuntura do setor elétrico brasileiro.

Espera-se que, com a junção do modelo de regressão e do modelo da MLP haja uma perspectiva mais assertiva das previsões de planejamento de expansão de um sistema de larga escala, analisando os limites máximos e mínimos necessários para uma projeção futura e o comportamento da carga no longo prazo.

As seções a seguir estão divididas da seguinte forma: na seção 2 são apresentados as subdivisões do sistema elétrico brasileiro e é retratado o perfil de carga do Subsistema Sul (SS), subsistema para o qual foi realizado este estudo. Na seção 3 são apresentadas as metodologias do modelo de regressão e da MLP. A seção 4 apresenta os resultados de previsão de carga dos modelos em médio prazo, os quais validam este estudo e que direcionam a seção seguinte. A seção 5 traz os resultados para a previsão de carga a longo prazo, na qual foram associados o modelo de regressão que obteve melhor desempenho com a MLP. E por fim, na seção 6 são apresentadas as conclusões.

2. CARACTERIZAÇÃO DO SUBSISTEMA SUL

O sistema elétrico brasileiro é composto por quatro subsistemas que compõem o Sistema Interligado Nacional (SIN), sendo classificados pela sua localização: Subsistema Sul, Sudeste/Centro-Oeste, Nordeste e a maior parte da região Norte. O Operador Nacional do Sistema (ONS) é o principal responsável para gestão do SIN, que em parceria com outros órgãos realizam os estudos de planejamento e da operação eletro energética do Brasil (ONS, 2021b).

Dentre os subsistemas, o SS pode ser considerado autossustentável no balanço de carga e geração, na qual possui capacidade de geração de energia superior a demanda de carga (Mendes, Beluco e Canales, 2017). Porém, nos últimos anos, pelo fato da economia nacional estar estagnada, seu perfil de carga se mantém em um crescente quase estável na comparação ano a ano. A Fig.1 ilustra a demanda horária máxima registrada mensalmente para o SS do Brasil, obtida de (ONS, 2021a).

De certa forma, o crescimento da demanda de carga de um sistema a cada ano tende a ter um aumento devido ao crescimento populacional, aumento na demanda dos consumidores residenciais, comerciais e industriais. No entanto, crises no setor financeiro e epidemiológicas a níveis nacionais e globais tendem a reduzir o consumo de eletricidade. Isso pode ser observado pelo decréscimo de consumo no ano de 2014, onde houve uma forte crise econômica no país motivada por problemas políticos (Barbosa Filho, 2017), bem como no caso do vírus da COVID-19 e o alto grau de isolamento social (Alvarez e Sarli, 2021; Sausen *et al.*, 2021). Deste modo, há a necessidade de um melhor planejamento do setor em todos os

horizontes de tempo, no que trata também do controle e operação do sistema.

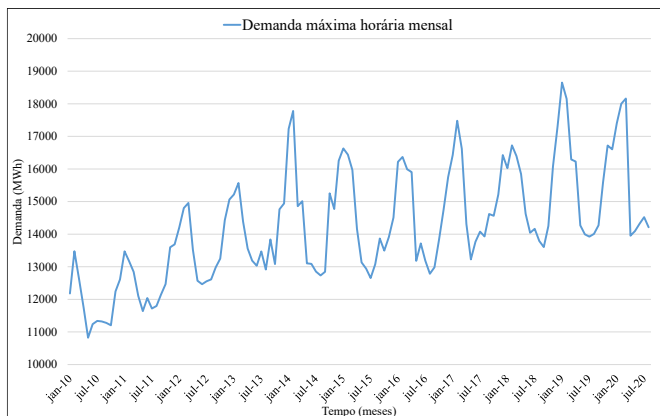


Fig. 1 Demanda horária máxima mensal do SS

Seguindo neste contexto, a previsão de carga faz-se necessária em um sistema elétrico de potência como o brasileiro, agindo como um elo essencial para que se possam planejar investimentos no sistema, e, principalmente, em relação à integração de fontes de energia renováveis intermitentes (Citroen, Ouassaid e Maaroufi, 2015). Com o estudo do comportamento da variação de demanda ao longo dos anos, é possível estimar cenários futuros de carga a partir de modelos matemáticos com base em histórico de dados. Isso torna possível ter uma estimativa de demanda futura e assim tomar as medidas de planejamento e expansão do setor elétrico de potência (Citroen, Ouassaid e Maaroufi, 2015; Tang, Yi e Peng, 2019).

3. METODOLOGIA

A metodologia deste estudo segue pelo desenvolvimento de um modelo de previsão de carga para sistemas de grande escala, a partir de modelos de regressão e da RNA MLP. Para o modelo de regressão foram considerados três cenários de previsão avaliados do ponto de vista de operação e planejamento, sendo eles: neutro; otimista; e pessimista. A MLP foi modelada usando a técnica de aprendizagem supervisionada que expressa a capacidade de solucionar problemas complexos e não lineares, uma vez que as inconstâncias da carga ao longo dos anos observada na Fig. 1 corrobora a aplicação desta técnica. A seguir, são apresentados os modelos propostos neste estudo, seguindo pelos modelos de regressão, e em seguida, pela MLP.

3.1 Modelos de Regressão

Para a condição neutra, que se caracteriza por um crescimento de carga suave e linear, foi utilizado o modelo de regressão linear para previsão da carga. Na condição otimista, a carga em análise deve se manter constante ou até mesmo diminuir no decorrer do tempo, sendo utilizada para tal o modelo de regressão logarítmico. Já em condição pessimista, a carga deve ter um aumento significativo na sua evolução, a qual foi modelada pela função de regressão exponencial. As expressões características dos modelos de regressão foram obtidas pela linha de tendência média do histórico de dados, e

pelo desvio padrão destes dados obtido por (1) foi possível delimitar os valores máximos e mínimos de acordo com (2).

$$SD = \sqrt{\sum_{i=1}^n \frac{(y_i - \bar{y})^2}{n}} \quad (1)$$

$$AT \pm SD \quad (2)$$

Onde:

- SD é o desvio padrão da série histórica;
- y_i é o valor real da demanda máxima horária registrada mensalmente no SS;
- \bar{y} é a média aritmética da série histórica;
- n é o número de amostras da série histórica;
- AT é a tendência média da série histórica em análise.

Para mensurar os erros de previsão das curvas de tendência média, máxima e mínima dos modelos de regressão, foram utilizados os métodos de MAE (Mean Absolute Error) e $MAPE$ (Mean Absolute Percentage Error), que se referem respectivamente a média dos erros da previsão de carga e a média dos erros percentuais, expressos respectivamente por:

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - AT(\text{ou } AT \pm SD)|, \quad (3)$$

$$MAPE = \frac{100\%}{n} \sum_{i=1}^n \frac{|y_i - AT(\text{ou } AT \pm SD)|}{y_i}, \quad (4)$$

onde, n é o número de amostras, y_i é o valor real de carga, e $AT(\text{ou } AT \pm SD)$ o valor obtido para previsão de carga para cada modelo de regressão em seus desvios médio, máximo e mínimo.

3.2 Rede Neural Multi-Layer Perceptron

A principal motivação vinculada ao uso da MLP é a capacidade de aprendizado por meio de um processo de treinamento supervisionado. Esse processo consiste basicamente em fornecer à MLP um conjunto de amostras que representam a série histórica em análise, onde ela irá aprender as relações entre as entradas e saídas, tornando-a capaz de generalizar soluções para nova amostras de dados entradas (Haykin, 2008; Silva, Spatti e Flauzino, 2016; Barbosa *et al.*, 2018). A aprendizagem da MLP se dá pelas interações entre as camadas de entrada, oculta e saída, que correspondem a matrizes e vetores interligadas entre si, como exposto pela Fig. 2.




Fig. 2 Estrutura da MLP

Entre a camada de entrada e oculta, e entre a camada oculta e de saída, estão os pesos sinápticos (w_{im} e w_{mn}), que são atualizados à medida em que haja iterações entre as camadas. Estes pesos são multiplicados pelas amostras de entradas conforme em (5), e que representam o sinal de propagação para as próximas camadas. A função de ativação é o sinal de saída da camada oculta e da camada de saída, onde neste estudo foi escolhida a expressão sigmoide em (6), a este processo se dá o nome de *feed-forward* (Barbosa *et al.*, 2018; Hammerschmitt *et al.*, 2019), o qual é expresso por:

$$k_m = \sum_{i=1, m=1}^{i, m} y_i * w_{im}, \quad (5)$$

$$x_m = \frac{1}{(1 + \exp^{-k_m})}, \quad (6)$$

onde:

- k_m é o sinal de propagação, y_i são as amostras de dados, e w_{im} os pesos sinápticos antes da camada oculta;
- x_m é a função de ativação de cada neurônio entre a camada de entrada e camada oculta;
- as equações (5) e (6) serão as mesmas entre a camada oculta e camada de saída para o sinal de propagação k_n e a função de ativação y_n .

O erro de aprendizagem da MLP foi calculado por *MAE*, similar a (3), e expresso em (7), o qual será parâmetro indicativo de parada de treinamento da MLP:

$$MAE = \frac{1}{n} \sum_{i=1, n=1}^{i, n} |y_i - y_n|, \quad (7)$$

onde, n é o número total de amostras de saída, y_i é o objetivo do treinamento (valor real normalizado), e o y_n é o sinal obtido pelo cálculo da função de ativação da camada oculta até a camada de saída.

A etapa denominada *back-propagation* é onde serão atualizados os pesos e novas iterações. Para simplificação, será realizada a atualização dos pesos seguindo pelo estudo de (Hammerschmitt *et al.*, 2019). Para atualização dos pesos, dois parâmetros devem ser informados, a que se referem pelo

momentum e a taxa de aprendizagem, que neste estudo foram os valores de 1 e 0,05, respectivamente.

A validação dos dados, que corresponde a previsão de carga de médio prazo, será avaliada por *MAE* em (7) e por

$$MAPE = \frac{100\%}{n} \sum_{i=1, n=1}^{i, n} \frac{|y_i - y_n|}{y_i}, \quad (8)$$

onde, n é o número de amostras de saída de validação, y_i é o valor real normalizado, e o y_n é o sinal obtido pelo cálculo da função de ativação da camada oculta até a camada de saída.

A normalização das amostras de entrada da MLP foi obtida mediante o cálculo que segue em

$$y_i = \frac{x_{max} - x}{x_{max} - x_{min}}, \quad (9)$$

onde, y_i é a amostra normalizada, x é a amostra real, x_{max} é a amostra de maior valor contida na série histórica ($x_{max} = 18.652$), e x_{min} é a amostra de menor valor contida na série histórica ($x_{min} = 10.822$).

Para este estudo, a arquitetura da MLP foi composta por 4 entradas, 8 neurônios ocultos e uma saída. As iterações da MLP que compreendem o *feed-forward* e *back-propagation* foram processados até onde *MAE* fosse inferior a 0,055.

4. RESULTADOS DA PREVISÃO DE MÉDIO PRAZO

A previsão de carga para o SS foi desenvolvida em linguagem de programação Python e implementado no *software Spyder 3.7* do pacote ANACONDA®, em um *notebook* com processador Intel Core i5 de 2.5 GHz, 8 GB de memória RAM, DDR 4 de 2133 MHz, placa de vídeo GeForce MX 930, e um sistema operacional *Microsoft Windows 10*.

Os dados empregados neste estudo foram obtidos por meio do histórico da operação do ONS em (ONS, 2021a), que correspondem a demanda máxima horária registrada mensalmente no SS. Foram utilizados dados de janeiro de 2010 a agosto de 2020 para obtenção das expressões características e desvio padrão dos modelos de regressão e para treinamento da MLP. Para validar os modelos foi realizada a previsão de médio prazo, utilizando dados de setembro de 2020 a fevereiro de 2021, para mensurar os erros e avaliar qual o modelo de regressão será empregado com a MLP para a previsão de longo prazo (março de 2021 a dezembro de 2022).

Os resultados da previsão de médio prazo, que foram utilizados como validação dos modelos de regressão e da rede neural MLP, bem como na identificação do modelo de regressão que melhor representa as a atual conjuntura do SS, estão apresentados nas subseções que seguem.

4.1 Resultados dos Modelos de Regressão

O modelo de regressão linear para o cenário neutro apresenta um crescimento de carga neutro em que se mantém ascendente, porém de maneira suave. Em (10) se encontra a expressão da linha de tendência, variando no tempo (t), obtida para este cenário de previsão,

$$AT_{linear} = 0,937864t - 25.257,397221. \quad (10)$$

O cenário otimista evidencia a redução de consumo acarretando um crescimento mínimo ou até mesmo em um decréscimo na curva de carga, que pode ser ocasionada pela recessão da economia. A expressão em (11) expressa a função obtida da série histórica pela linha de tendência do modelo de regressão logarítmico,

$$AT_{log} = 1.118,035 \log(t) + 9.901,00002. \quad (11)$$

A previsão de carga para um cenário pessimista, ilustra o aumento de consumo de maneira acelerada, que pode estar vinculada a movimentação econômica ou até mesmo ao aumento populacional e o uso de eletrodoméstico para conforto térmico. O modelo de regressão polinomial expressa o equacionamento para tendência de previsão de carga deste cenário, que segue por

$$AT_{exp} = 846,892116 \exp^{0,000067 t}. \quad (12)$$

Os resultados obtidos para os três cenários de modelos de regressão, para previsão de carga considerando o horizonte de médio prazo (com $SD = 1719,6$) encontram-se nas Tabelas 1, 2 e 3.

Tabela 1. Previsão de médio prazo para a regressão linear

Mês – Ano	ONS (MWh)	Linear (MWh)		
		AT	$AT+SD$	$AT-SD$
set-20	14.728	16.079	17.799	14.359
out-20	15.478	16.107	17.827	14.387
nov-20	16.943	16.136	17.856	14.417
dez-20	16.762	16.164	17.884	14.445
jan-21	17.537	16.193	17.913	14.474
fev-21	17.255	16.222	17.942	14.503
MAE (MWh)		960	1.419	2.020
$MAPE$ (%)		5,87	9,04	11,95

Tabela 2. Previsão de médio prazo para a regressão logarítmica

Mês – Ano	ONS (MWh)	Logarítmica (MWh)		
		AT	$AT+SD$	$AT-SD$
set-20	14.728	15.334	17.054	13.615
out-20	15.478	15.343	17.063	13.623
nov-20	16.943	15.352	17.071	13.632
dez-20	16.762	15.360	17.080	13.641
jan-21	17.537	15.369	17.088	13.649
fev-21	17.255	15.377	17.097	13.657
MAE (MWh)		1.297	827	2.814
$MAPE$ (%)		7,67	5,36	16,79

Tabela 3. Previsão de médio prazo para a regressão exponencial

Mês – Ano	ONS (MWh)	Exponencial (MWh)		
		AT	$AT+SD$	$AT-SD$
set-20	14.728	16.230	17.949	14.510
out-20	15.478	16.262	17.982	14.543
nov-20	16.943	16.296	18.016	14.577
dez-20	16.762	16.329	18.049	14.609
jan-21	17.537	16.363	18.083	14.643
fev-21	17.255	16.397	18.117	14.677
MAE (MWh)		900	1.582	1.857
$MAPE$ (%)		5,56	10,03	10,96

Deste modo, a partir dos resultados de MAE e $MAPE$, os modelos de regressão que apresentaram melhores resultados foram os modelos linear e exponencial, que representam respectivamente os cenários neutro e pessimista pelo ponto de vista do planejamento. No entanto, outros fatores devem ser levados em consideração para se fazer esta afirmação, como os efeitos da pandemia ocasionada pelo vírus da COVID-19 (Lindberg *et al.*, 2019; Siqueira *et al.*, 2021).

Sendo assim, para a previsão de carga no horizonte de longo prazo ser mais assertiva, deve ser levado em consideração a atual conjuntura do cenário nacional, onde a economia se encontra em um longo período sem crescimento notável. Isto se agrava ainda mais pois há os efeitos da pandemia que afeta o mundo todo pelo vírus da COVID-19, onde haverá recessão econômica (Governo Federal, 2021), e logicamente, diminuição ou estagnação do consumo de eletricidade (Alvarez e Sarli, 2021; Sausen *et al.*, 2021). Portanto, a previsão de carga no horizonte de longo prazo foi realizada pelo modelo de regressão logarítmico. Este retrata um cenário otimista pelo lado do planejamento, sendo mais indicado para a atual conjuntura a nível nacional, também devido a retração ou crescimento pouco significativo da economia brasileira (Banco Central do Brasil, 2021).

4.2 Resultados da MLP

Os resultados obtidos pela MLP para previsão de carga no horizonte de médio prazo foram de MAE de 326 MWh e $MAPE$ de 1,98%, sendo estes resultados bem expressivos considerando as grandes amplitudes de carga do SS,

principalmente nas estações de inverno (Jun-Jul-Ago) e verão (Dez-Jan-Fev) (Wen *et al.*, 2020). Os resultados se encontram na Tabela 4, onde são informados os dados reais de carga do SS e a resposta obtida pela MLP.

Tabela 4. Previsão de Médio Prazo para a MLP

Mês - Ano	ONS (MWh)	MLP (MWh)
set-20	14.728	14.315
out-20	15.478	15.387
nov-20	16.943	16.242
dez-20	16.762	16.980
jan-21	17.537	17.347
fev-21	17.255	16.914
<i>MAE</i> (MWh)		326
<i>MAPE</i> (%)		1,98

5. RESULTADOS DA PREVISÃO DE LONGO PRAZO

Os resultados obtidos para a previsão de carga para o SS considerando o horizonte de longo prazo para a MLP e para o modelo de regressão logarítmico com seus respectivos desvios máximo e mínimo são ilustrados na Fig. 3.

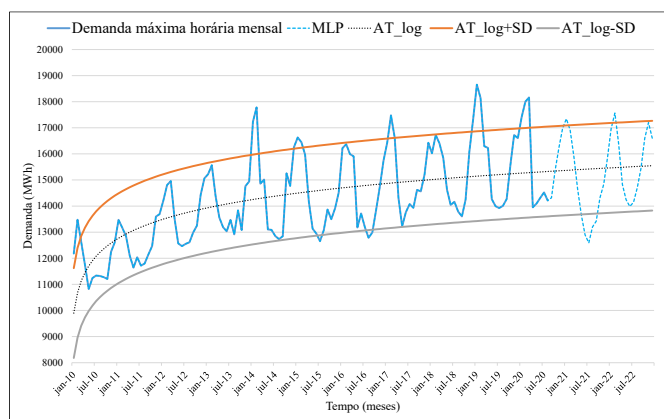


Fig. 3 Resultado gráfico da MLP e regressão logarítmica no longo prazo

Conforme exposto na Fig. 3, a representação da MLP associada a técnica de regressão logarítmica obtida por (11) evidencia a atual conjuntura nacional no que diz respeito a evolução do consumo de eletricidade para o SS. É observado que os picos de máxima carga resultante da MLP se localizam próximos da linha de tendência logarítmica mais seu desvio padrão ($AT_{log}+SD$), onde o resultado esperado para a condição de carga máxima corresponde a 17.565 MWh para fevereiro de 2022. Da mesma forma, é identificado que os pontos de mínima carga da MLP e da curva de tendência logarítmica menos seu desvio padrão ($AT_{log}-SD$) estão próximas. Uma ressalva pode ser feita para os resultados da MLP para o período de junho a agosto de 2021 que tiveram resultados pouco distantes, tendo como resultado para condição de carga mínima ocorrendo em julho de 2021 com resultado previsto de 12.587 MWh.

Neste sentido, com o impacto da pandemia na previsão de carga futura, os resultados sinalizam uma redução

significativa do consumo de eletricidade na primeira metade do ano de 2021, e após isso mantendo forma e padrão estável até o final de 2022, o que é justificado pela retração da economia. Logo, outros fatores devem ser levados em consideração para uma previsão mais assertiva, sendo as principais no momento o crescimento populacional e a evolução da economia pós efeito da pandemia. No entanto, todas as previsões realizadas no atual momento são embasadas na análise probabilística e não determinística, pois ainda há reflexos dos efeitos da pandemia no setor elétrico nacional, motivado pela retração da economia para o período analisado.

6. CONCLUSÕES

Os estudos de previsão de carga são essenciais no planejamento do setor elétrico, no que trata das questões de expansão, reforços e reparos da rede elétrica, e no controle e operação do sistema, mantendo os níveis de confiabilidade e segurança dentro dos limites adequados de funcionamento. Para isso, foi realizada a previsão de carga para o SS considerando primeiramente um horizonte médio prazo, a partir de modelos de regressão estimando três possíveis cenários, e fazendo o uso de inteligência artificial pela MLP. A seguir foi realizada a identificação do modelo de regressão que melhor representa a atual conjuntura do setor elétrico brasileiro, e ampliada a previsão para um horizonte de longo prazo associando o modelo de regressão com a MLP.

Para avaliação do modelo de regressão que melhor se assemelha as condições de carga futura e que se detém na atual conjuntura, na qual o país sofre com os efeitos da pandemia, foi identificado que se não houvesse o fator pandemia ocasionado pela doença do COVID-19, a perspectiva de carga teria uma ascensão similar aos modelos de regressão linear e/ou exponencial. No entanto, a realidade tem mostrado que haverá um longo período de recessão da economia e que a perspectiva da carga do SS deve seguir uma característica de estagnação ou decréscimo, sendo melhor representado pelo cenário otimista e expresso pelo modelo de regressão logarítmico.

Portanto, a previsão de carga em um horizonte de longo prazo foi realizada seguindo pelo modelo de regressão logarítmico que demonstra uma tendência de crescimento suave da carga no SS, e que associado a MLP expressam com maior fidelidade os efeitos da pandemia no Brasil, conduzidos pela retração da economia que reflete na redução de consumo de eletricidade.

AGRADECIMENTOS

Os autores agradecem ao apoio técnico e financeiro do Instituto Nacional de Ciência e Tecnologia em Sistemas de Geração Distribuída (INCTGD), Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq - nº 465640/2014-1), Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES - nº 23038.000776/2017-54), Fundação de Amparo à Pesquisa do Estado do Rio Grande do Sul (FAPERGS - nº 17/2551-0000517-1) e Universidade Federal de Santa Maria (UFSM), Instituições Brasileiras.

REFERÊNCIAS

- Alvarez, G. E. and Sarli, J. L. (2021) ‘Mathematical model to control the Argentine Energy System during the COVID 19 pandemic’, *IEEE Latin America Transactions*, 19(6), pp. 874–883. doi: 10.1109/TLA.2021.9451231.
- Baek, S.-M. (2019) ‘Mid-term Load Pattern Forecasting With Recurrent Artificial Neural Network’, *IEEE Access*, 7, pp. 172830–172838. doi: 10.1109/ACCESS.2019.2957072.
- Banco Central do Brasil (2021) *Panorama econômico*. Available at: <https://www.bcb.gov.br/> (Accessed: 15 March 2021).
- Barbosa, E. H. C. *et al.* (2018) ‘Critical analysis of pattern recognition load curves using multi-layer perceptron neural network’, in *2018 13th IEEE International Conference on Industry Applications (INDUSCON)*. IEEE, pp. 91–98. doi: 10.1109/INDUSCON.2018.8627168.
- Barbosa Filho, F. de H. (2017) ‘A crise econômica de 2014/2017’, *Estudos Avançados*, 31(89), pp. 51–60. doi: 10.1590/s0103-40142017.31890006.
- Citroen, N., Ouassaid, M. and Maaroufi, M. (2015) ‘Long term electricity demand forecasting using autoregressive integrated moving average model: Case study of Morocco’, in *2015 International Conference on Electrical and Information Technologies (ICEIT)*. IEEE, pp. 59–64. doi: 10.1109/EITech.2015.7162950.
- Dudek, G. and Pelka, P. (2021) ‘Pattern similarity-based machine learning methods for mid-term load forecasting: A comparative study’, *Applied Soft Computing*, 104, p. 107223. doi: 10.1016/j.asoc.2021.107223.
- Goswami, K., Ganguly, A. and Sil, A. K. (2018) ‘Day Ahead Forecasting and Peak Load Management using Multivariate Auto Regression Technique’, in *2018 IEEE Applied Signal Processing Conference (ASPCON)*. IEEE, pp. 279–282. doi: 10.1109/ASPCON.2018.8748661.
- Governo Federal (2021) *Ministério da Economia*. Available at: <https://www.gov.br/economia/pt-br> (Accessed: 15 March 2021).
- Hammerschmitt, B. K. *et al.* (2019) ‘Short-Term Generation Forecasting Against the High Penetration of the Wind Energy’, in *2019 8th International Conference on Modern Power Systems (MPS)*. IEEE, pp. 1–6. doi: 10.1109/MPS.2019.8759654.
- Han, L. *et al.* (2019) ‘Enhanced Deep Networks for Short-Term and Medium-Term Load Forecasting’, *IEEE Access*, 7, pp. 4045–4055. doi: 10.1109/ACCESS.2018.2888978.
- Haykin, S. (2008) *Redes Neurais: Princípios e Prática*. 2ª Edição. Edited by P. M. Engel. Porto Alegre: Bookman.
- Lindberg, K. B. *et al.* (2019) ‘Long-term electricity load forecasting: Current and future trends’, *Utilities Policy*, 58(January), pp. 102–119. doi: 10.1016/j.jup.2019.04.001.
- Mendes, C. A. B., Beluco, A. and Canales, F. A. (2017) ‘Some important uncertainties related to climate change in projections for the Brazilian hydropower expansion in the Amazon’, *Energy*, 141, pp. 123–138. doi: 10.1016/j.energy.2017.09.071.
- ONS (2021a) *Histórico da Operação*, ONS. Available at: http://www.ons.org.br/Paginas/resultados-da-operacao/historico-da-operacao/demanda_maxima.aspx (Accessed: 15 March 2021).
- ONS (2021b) *Operador Nacional do Sistema Elétrico (ONS)*. Available at: <http://ons.org.br/> (Accessed: 15 March 2021).
- Sausen, P. S. *et al.* (2021) ‘Proposal for a Methodology Based on Electricity Consumption to Analyze Social Isolation During a COVID-19 Pandemic: Case Study’, *IEEE Latin America Transactions*, 19(6), pp. 909–916. doi: 10.1109/TLA.2021.9451235.
- Sehovac, L. and Grolinger, K. (2020) ‘Deep Learning for Load Forecasting: Sequence to Sequence Recurrent Neural Networks With Attention’, *IEEE Access*, 8(MI), pp. 36411–36426. doi: 10.1109/ACCESS.2020.2975738.
- Silva, C. V. M. *et al.* (2010) ‘Variáveis climáticas aplicadas à previsão de demanda em curtíssimo prazo’, in *CIDEL 2010*. Buenos Aires, Argentina, pp. 1–6. Available at: <http://sg.cier.org.uy/Publicaciones/revista.nsf/16c07680540db07c03257132007871c9/d242c539e5b67d11832576f000451e3b?OpenDocument> (Accessed: 10 March 2021).
- Silva, I. N. da, Spatti, D. H. and Flauzino, R. A. (2016) *Redes Neurais Artificiais Para Engenharia e Ciências Aplicadas: Fundamentos Teóricos e Aspectos Práticos*. 2ª Edição. São Paulo: ARTLIBER EDITORA LTDA.
- Siqueira, E. *et al.* (2021) ‘Temporal Prediction Model of the Evolution of Confirmed Cases of the New Coronavirus (SARS-CoV-2) in Brazil’, *IEEE Latin America Transactions*, 19(6), pp. 937–943. doi: 10.1109/TLA.2021.9451238.
- Sreekumar, S. *et al.* (2016) ‘Matrix based univariate and multivariate linear approach towards Long Term electrical Load Forecasting’, in *2016 IEEE 1st International Conference on Power Electronics, Intelligent Control and Energy Systems (ICPEICES)*. IEEE, pp. 1–5. doi: 10.1109/ICPEICES.2016.7853379.
- Tajeuna, E. G., Bouguessa, M. and Wang, S. (2018) ‘A Network-Based Approach to Enhance Electricity Load Forecasting’, in *2018 IEEE International Conference on Data Mining Workshops (ICDMW)*. IEEE, pp. 266–275. doi: 10.1109/ICDMW.2018.00046.
- Tang, L., Yi, Y. and Peng, Y. (2019) ‘An ensemble deep learning model for short-term load forecasting based on ARIMA and LSTM’, in *2019 IEEE International Conference on Communications, Control, and Computing Technologies for Smart Grids (SmartGridComm)*. IEEE, pp. 1–6. doi: 10.1109/SmartGridComm.2019.8909756.
- Wen, Z. *et al.* (2020) ‘Long term electric load forecasting based on TS-type recurrent fuzzy neural network model’, *Electric Power Systems Research*, 179(November 2019), p. 106106. doi: 10.1016/j.epr.2019.106106.
- Xue, W. *et al.* (2018) ‘Medium and Long Term Load Forecasting of Regional Power Grid in the Context of Economic Transition’, in *2018 2nd IEEE Conference on Energy Internet and Energy System Integration (EI2)*. IEEE, pp. 1–4. doi: 10.1109/EI2.2018.8582055.