

## Análise da Influência da Temperatura para Previsão de Potência Máxima em Subestações Utilizando Redes Neurais

Thommas Kevin Flores\* Pedro H. M. de Andrade\*\*  
Isaac Medeiros\*\*\* Juan M. M. Villanueva\*\*\*\*  
Igleyce K. A. da Silva†

\* *Universidade Federal da Paraíba, João Pessoa-PB, (e-mail: thommas.flores@cear.ufpb.br)*

\*\* *Universidade Federal do Rio Grande do Norte, Natal-RN, (e-mail: pedrohmeira@ufrn.edu.br)*

\*\*\* *Universidade Federal da Paraíba, João Pessoa-PB, (e-mail: isaac.medeiros@cear.ufpb.br)*

\*\*\*\* *Universidade Federal da Paraíba, João Pessoa-PB, (e-mail: jmauricio@cear.ufpb.br)*

† *Universidade Federal da Paraíba, João Pessoa-PB, (e-mail: igleyce.silva@cear.ufpb.br)*

---

**Abstract:** Load forecasting studies are of great importance for companies in the electric energy sector, because there is a need to allocate resources in advance, requiring short, medium and long-term planning. These resources include the purchase of equipment, acquisition and construction of transmission lines, preventive maintenance and commercialization of energy. Therefore, a computational tool was developed to support specialists in the area of strategic planning in electrical distribution systems, using Artificial Neural Networks to forecasting demand, and including temperature as an external factor. In the proposed methodology, a short-term forecasting system was implemented for a real substation, using computer artificial intelligence techniques based on Artificial Neural Networks, using Matlab software. For this, were used active power data provided by the power utility, and the history of local temperature values were obtained from INMET's website, all for the year 2008. The forecast window used was 12 lagged values to obtain the following 4. Finally, the accuracy of the networks obtained from training were measured considering MAPE and percentage error.

**Resumo:** Os estudos de previsão de demanda têm grande importância para empresas do ramo de energia elétrica, pois existe a necessidade de alocação de recursos com antecedência, exigindo um planejamento a curto, médio e longo prazo. Tais recursos incluem a compra de equipamentos, aquisição e construção de linhas de transmissão, manutenções preventivas e comércio de energia. Diante disso, foi desenvolvida uma ferramenta computacional de apoio aos especialistas da área de planejamento estratégico em sistemas de distribuição elétrica, utilizando Redes Neurais Artificiais (RNA) para previsão da potência ativa demandada, além de incluir a temperatura como fator de influência externo. Na metodologia proposta, foi implementado um sistema de previsão a curto prazo para a subestação de uma cidade da Paraíba, utilizando técnicas computacionais de inteligência artificial baseadas em Redes Neurais Artificiais, com auxílio do *software* Matlab. Para isso, foram utilizados dados de potência ativa, fornecidos pela concessionária de energia, e o histórico dos valores de temperatura locais foram obtidos através da base de dados do Instituto Nacional de Meteorologia (INMET), para o ano de 2008. A janela de previsão utilizada foi de 12 valores atrasados para fornecer um horizonte de 4 dias. Finalmente, a acurácia das redes obtidas via treinamento foi medida considerando o MAPE e erro relativo percentual.

*Keywords:* Load Forecasting; Electric Power Distribution; Time Series Forecasting; Artificial Neural Networks; Artificial Intelligence.

*Palavras-chaves:* Previsão de Demanda, Distribuição de Energia Elétrica; Previsão de Séries Temporais; Redes Neurais Artificiais; Inteligência Artificial.

---

## 1. INTRODUÇÃO

A principal função do Sistema Elétrico de Potência (SEP) é fornecer energia elétrica aos usuários, com qualidade apropriada, na medida em que for solicitada, convertendo energia de naturezas diversas (hidráulica, mecânica, térmica, etc.) em energia elétrica e assim, distribuindo aos consumidores (Kagan et al. (2005) e Andrade (2010)).

A energia gerada pelo sistema de geração necessita ser distribuída em todo o país e, para isso, existe o Sistema Interligado Nacional (SIN), que inclui a maior parte do território nacional, e é formado por conexões entre as cinco regiões do Brasil.

As empresas de distribuição de energia elétrica devem elaborar relatórios periódicos de previsões de demanda das cargas localizadas em sua área de concessão, nos horizontes definidos pelo Operador Nacional do Sistema (ONS) e pela Empresa de Pesquisa Energética (EPE) (Ribeiro et al. (2006)).

Além desses estudos, as empresas realizam análises internas, com o objetivo de planejar as decisões de operação, controle e manutenção dos sistemas. Em relação aos recursos que necessitam de antecedência de reserva, destacam-se: construção de novas linhas transmissão, compra e venda de energia, compra de novos equipamentos e manutenções preventivas.

A previsão de demanda pode ser feita para os horizontes de longo, médio, curto e curtíssimo prazo (Anwar et al. (2018)). A possibilidade de diversos horizontes de planejamento, portanto, conduz a prática de previsão de demanda para grande complexidade. A previsão a longo prazo possui como horizonte o período de anos ou décadas, e objetiva o planejamento para incrementar a capacidade das linhas de transmissão ou construção de novas plantas de geração.

Por outro lado, a previsão de demanda de médio prazo, que ocorre desde semana a meses, permite às concessionárias e empresas de energia elétrica alocar seus recursos como: manutenções nas redes elétricas, a compra de equipamentos, expansão do seu sistema, estratégias no mercado de energia (Ghiassi et al. (2006) e Anwar et al. (2018)). A previsão de curto prazo possui algumas horas como horizonte, e pode avaliar a segurança do sistema, analisar confiabilidade, além do planejamento de manutenções. A previsão de curtíssimo prazo prevê minutos à frente, sendo importante na regulação entre a demanda e oferta por energia elétrica a fim de evitar flutuações, ajustando a geração de energia às constantes mudanças (Carmona et al. (2002)).

Para uma visão a longo prazo, o intervalo de tempo deverá variar de cinco a dez anos, se aproximando do limite superior para redes de transmissão de subestações, e do limite inferior para redes de distribuição. A atualização destes planos deve ser anual, de forma a permitir ao regulador e à sociedade acompanhar mudanças de tendências nos

investimentos, bem como, comparar o que foi planejado e o que foi efetivamente implementado, considerando, naturalmente, as motivações e barreiras de caráter econômico, estrutural, legal e ambiental (Santos et al. (2008)). Os estudos de previsão de demanda têm como objetivo auxiliar no plano anual de expansão.

Neste sentido, anterior ao surgimento da Inteligência Artificial (IA), apenas os métodos estatísticos e probabilísticos, liderados pelos modelos Box e Jenkins (Box et al. (2015)) eram aplicados em séries temporais para previsão. Com o desenvolvimento de técnicas computacionais, que levam vantagem diante da não linearidade dos dados e sem depender de modelos matemáticos complexos, métodos de inteligência artificial passaram a ser utilizados em previsão de demanda (Andrade et al. (2020), Sonmez et al. (2017) e Hapuarachchi et al. (2018)).

Peřka and Dudek (2020) utilizam uma rede LSTM (*Long Short-Term Memory*) para previsão da demanda mensal de energia, considerando um horizonte de um ano a partir dos dados temporais. Dudek et al. (2020) também utilizam LSTM, porém combinada com a suavização exponencial (*ETS - exponential smoothing*) com o objetivo de melhorar a performance da previsão ao levar em consideração a sazonalidade da série temporal.

Ali et al. (2019) propõem um método para previsão de demanda com o horizonte de curtíssimo prazo: 1 hora à frente. O método criado mapeia a série temporal em busca de padrões semelhantes criando *clusters*. O interessante deste trabalho é que leva em consideração as condições do tempo para aquela hora em estudo. O menor valor de MAPE encontrado foi 4,3% para 5 *clusters*.

Liao and Pan (2019) implementam uma nova estrutura para previsão a curto prazo. É utilizada o conceito de *Dense Average Connection* para a criação de uma rede neural para estimação de carga que leva em consideração os valores passados da demanda e da temperatura. O menor MAPE calculado foi 0,36%, considerando a nova estrutura proposta.

Lang et al. (2019) utilizam redes neurais convolucionais com uma dimensão para prever a demanda de energia elétrica em 36 horas no futuro. Massaoudi et al. (2019) combinam a rede LSTM com a NARX (*Nonlinear autoregressive exogenous*) para formar um modelo híbrido de previsão de consumo de potência em sistemas fotovoltaicos. Nesse trabalho, além da temperatura foram consideradas como entradas exógenas a umidade relativa, velocidade do vento e a radiação solar. Massaoudi et al. (2019) encontrou 0,269% como menor valor do MAPE.

Este trabalho, portanto, consiste em desenvolver uma ferramenta computacional para previsão de demanda, destinada a especialistas da área de planejamento estratégico em sistemas de distribuição, com enfoque em Redes Neurais Artificiais (RNA). Além disso, será investigado a

influência da variável temperatura na previsão, além de uma comparação entre os resultados considerando ou não este aspecto.

## 2. METODOLOGIA

### 2.1 Previsão de demanda

O processo de previsão de demanda proposto neste trabalho por meio da RNA ocorre, basicamente, em três etapas: treinamento, validação e teste. A etapa de treinamento consiste em apresentar os dados à rede para que ocorra o aprendizado. Na validação, são realizados testes ao fim de cada iteração de treino. O teste, ou previsão, fornece o resultado desejado pelo usuário.

Como entradas das RNA, foi considerada uma janela de valores de demanda passados, bem como, dados correspondentes de temperatura. Estudos anteriores indicam maior eficiência no resultado das previsões quando outras variáveis altamente correlacionadas com a demanda são consideradas (Ali et al. (2019), Liao and Pan (2019), Mas-saoudi et al. (2019)).

Neste contexto, serão apresentadas a seguir as etapas para o uso da RNA para um estudo prático em uma subestação no estado da Paraíba, cujo seu diagrama unifilar encontra-se na Figura 1. Finalmente, será testada a hipótese de que a inclusão da temperatura irá melhorar a performance dos modelos de previsões desenvolvidos.




Figura 1. Diagrama unifilar de uma subestação na Paraíba.

### 2.2 Implementação do conjunto de dados

Os dados de potência ativa foram cedidos pela concessionária de energia local, os quais foram obtidos através de um sistema de aquisição de dados (SCADA, do inglês *Supervisory Control and Data Acquisition*), que é responsável pela aquisição nos equipamentos/barramentos da subestação e envio para um banco de dados.

Além disso, para todo o intervalo de tempo em que foi feita a análise de potência ativa, foram acrescentados os devidos valores diários de temperatura correspondentes, adquiridos via site do Instituto Nacional de Meteorologia (INMET), para a cidade em estudo na Paraíba.

O sistema realiza as medições a cada 15 minutos, totalizando 96 medições por dia. As máximas diárias de cada uma destas variáveis estão ilustradas no gráfico da Figura

Tabela 1. Amostra do banco de dados utilizado.

Dia	Mês	Ano	Potência (MW)	Temperatura (°C)
1	1	2008	2,481	31,0
2	1	2008	2,418	31,8
3	1	2008	2,355	31,8
4	1	2008	2,557	32,3

2. A Tabela 1 apresenta os 4 primeiros valores do banco de dados utilizado neste trabalho.

Do banco de dados, 30% (109 dias) foi separado para os testes expostos na Seção dos Resultados. Do conjunto complementar, 80% foi utilizado para treinamento, 10% para validação e 10% para teste. Ou seja, foram utilizados 256 dias para a criação do modelo.




Figura 2. Máximas diárias de temperatura e potência.

Para uma análise prévia dos conjuntos de dados elétricos e climáticos, elaborou-se os gráficos com a média e triplo do desvio padrão, ilustrados nas Figuras 3 e 4. Estes gráficos correspondem aos valores máximos de cada dia ao longo do ano em estudo, afim de detectar possíveis medidas anômalas, por exemplo valores nulos e pontos fora da curva ou *outliers*. O tratamento das anomalias do sinal foi desenvolvido por este grupo de pesquisa em Andrade et al. (2020), mas está fora do escopo deste trabalho; contudo destaca-se a sua necessidade.

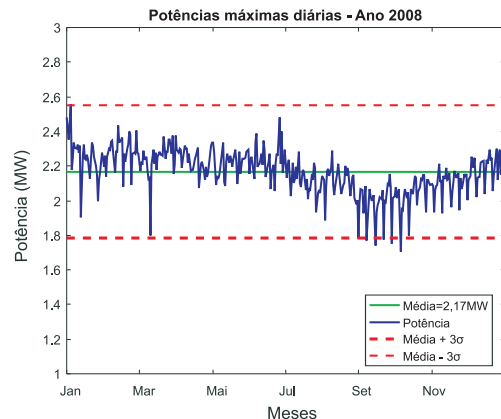


Figura 3. Limiar das máximas diárias da potências.

### 2.3 Treinamento da RNA

Para o treinamento da RNA, foi proposto um horizonte de previsão fixo, para potência e temperatura máximas

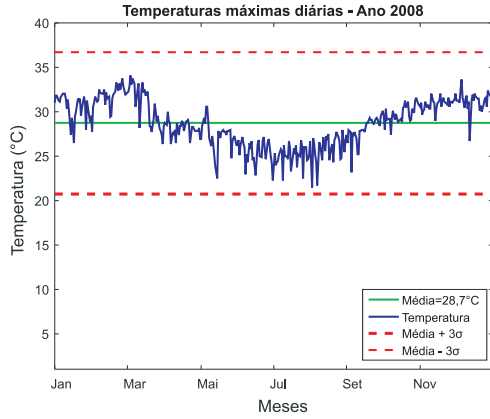


Figura 4. Limiar das máximas diárias da temperatura.

diárias, de 4 dias à frente, caracterizando em uma previsão a curto prazo. Ademais, considerou-se como entradas doze amostras passadas de ambas as variáveis (janela de previsão).

Este estudo de caso considerará duas condições como entradas da RNA: potência ativa máxima(a) da Figura 5, e outra considerando as amostras da potência ativa e temperatura máximas (b) da Figura 5. Além disso, em ambos os casos os valores passados das saídas serão retroalimentados.

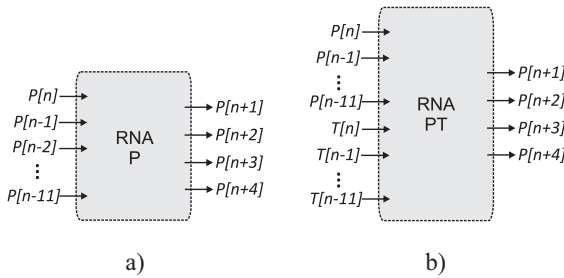


Figura 5. Entradas e saídas da RNA e janelamento desconsiderando a temperatura.

O ambiente computacional para realização de todas as simulações foi o Matlab (®) e os parâmetros foram definidos da seguinte forma:

- Número de camadas: 2;
- Número de neurônios: para o treinamento da rede, foram variadas e combinadas as quantidades de neurônios de 1 a 40 para cada camada, afim de encontrar a melhor rede neste intervalo;
- Algoritmo de aprendizado: Algoritmo de Levenberg-Marquardt (LM).

O algoritmo Levenberg-Marquardt (LM) é definido neste software como "trainlm", como aperfeiçoamento do tradicional algoritmo *Backpropagation*. O algoritmo LM faz uso do erro quadrático médio para corrigir os pesos da rede quando sua saída diferir da desejada e é bastante efetivo para redes neurais pequenas (Levenberg (1944), Marquardt (1963)).

#### 2.4 Teste e validação da RNA

Foram elaborados algoritmos para que, ao final do treinamento de todas as redes, fossem obtidas as melhores

configurações de RNA a partir das seguintes métricas de avaliação: menor erro relativo e erro médio percentual absoluto (MAPE, do inglês *Mean Absolute Percentage Error*), durante a fase de testes. Definidos matematicamente por 1 e 2, respectivamente.

$$E_r = \frac{P_j - T_j}{P_j} \quad (1)$$

$$MAPE(\%) = \frac{1}{N} \sum_{j=1}^N \left| \frac{P_j - T_j}{P_j} \right| \times 100 \quad (2)$$

Em que,

- $N$ : tamanho do conjunto de validação;
- $P_j$ : previsão do modelo, para  $j= 1,2,3, \dots, N$ ;
- $T_j$ : teste (banco de dados), para  $j= 1,2,3, \dots, N$ .

A validação está atrelada a simulação da rede para o conjunto de dados que não foram aplicados no treinamento. A cada passo, o valor previsto será realimentado para o grupo de entradas, de forma que os valores a serem previstos sofram influência da previsão anterior. Portanto, quanto menor o valor do MAPE, menor é o erro de estimação.

#### 2.5 Análise da correlação

Buscando verificar o nível de relação entre a temperatura e demanda neste trabalho, foi implementado um código em Matlab R2018b (®) para obter um coeficiente de correlação, que irá definir a sincronia de comportamento entre a potência ativa e a temperatura.

Dessa forma, foram extraídas as informações do conjunto de dados e por meio do comando "*corrcoef(A,B)*", em Matlab(®) em que A e B representam os vetores dos valores de potência e temperatura, respectivamente, pode-se obter uma matriz simétrica de coeficientes de correlação, da seguinte forma:

$$\begin{pmatrix} \rho(A, A) & \rho(A, B) \\ \rho(B, A) & \rho(B, B) \end{pmatrix} = \begin{pmatrix} 1 & 0,1385 \\ 0,1385 & 1 \end{pmatrix} \quad (3)$$

em que,  $\rho(A, A)$  e  $\rho(B, B)$  correspondem a correlação entre a medida e ela mesma, já  $\rho(A, B)$  e  $\rho(B, A)$  correspondem a medida de correlação entre a variável A em relação a variável B e vice-versa.

A correlação é um método estatístico usado para avaliar uma possível associação linear entre duas variáveis contínuas. Assim, como o coeficiente de correlação entre temperatura e potência resultou em um valor baixo (para um valor positivo, considera-se baixa a correlação no intervalo de 0 a 0,5 (Mukaka (2012))), é possível supor que, para esse estudo de caso, a inclusão da temperatura como variável de entrada na Rede Neural não afetará significativamente os valores de demanda previstos. Possivelmente, devido à baixa variação de temperatura na região geográfica estudada. Tal hipótese será investigada na próxima seção.

### 3. RESULTADOS

Neste capítulo, serão expostos os resultados do trabalho em detalhes. Desse modo, serão levadas em consideração

as topologias de RNA propostas na seção anterior, para a previsão de demanda. Os desempenhos das redes foram avaliados na etapa de teste, considerando o MAPE e erro relativo como métricas de avaliação.

Buscando encontrar a melhor topologia da RNA, foram realizados treinamentos utilizando duas camadas ocultas, em que cada uma poderia comportar no máximo 40 neurônios. Portanto, foram obtidas 1600 configurações de redes para testes e avaliação da que apresentaria a melhor performance.

### 3.1 Previsão considerando potência e a temperatura como entradas

Com a topologia da Rede Neural apresentada na Figura 5 b), denominada "RNA PT", tendo como entradas temperatura e potência, para a previsão da demanda, foi inicialmente realizado o procedimento de treinamento. Para isso, os parâmetros utilizados foram os presentes na seção 2.3.

Uma vez realizado o treinamento de todas as redes, estas foram avaliadas utilizando os dados de teste, considerando um período de 106 dias, equivalente a 30% do número total de amostras. Na Figura 6, foi esboçado o comportamento do MAPE para todas as redes encontradas, em que o eixo  $y$  representa o número de neurônios da primeira camada,  $x$  a quantidade de neurônios da segunda camada e, finalmente, o valor no eixo  $z$  representa o valor absoluto da métrica MAPE, em porcentagem.

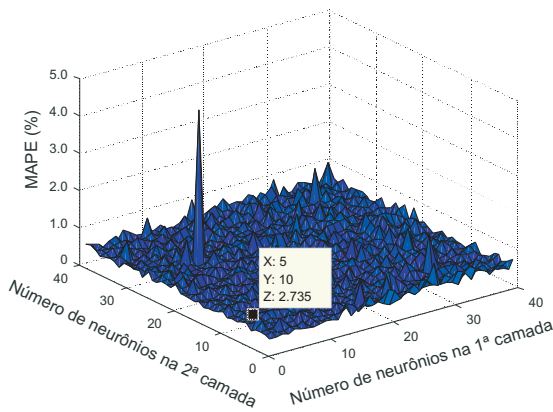


Figura 6. MAPE considerando potência e temperatura.

Sendo assim, a RNA que apresentou menor valor de MAPE, 2,73%, foi a rede com 10 e 5 neurônios na primeira e segunda camadas, respectivamente. Ademais, a rede com 31 e 5 neurônios na primeira e segunda camadas, respectivamente, foi a que exibiu o menor erro relativo, igual a 8,71%.

Nas Figuras 7 e 8 estão os resultados do teste para a RNA de topologia com o menor MAPE e menor erro relativo, respectivamente, para 106 dias. Nota-se que a topologia de melhor MAPE apresenta resultado superior, divergindo com menor frequência da curva objetivo quando comparado ao gráfico da Figura 8, o qual a topologia da RNA leva em consideração o menor erro relativo.




Figura 7. Previsão da rede de menor MAPE.

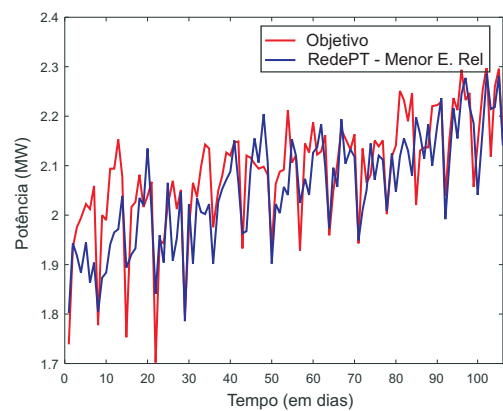


Figura 8. Previsão da rede de menor erro relativo.

### 3.2 Previsão considerando apenas a potência como entrada

Na Figura 5 a) está ilustrada a RNA cujas entradas são apenas os valores de potência para a previsão da demanda de potência elétrica. Inicialmente, é realizado o procedimento de treinamento considerando os parâmetros utilizados presentes na seção 2.3.

Após o treinamento de todas as redes, é feita a avaliação a partir dos dados de teste, considerando um período de 106 dias. Na Figura 9, foi esboçado o comportamento do valor absoluto do MAPE para todas as redes encontradas.

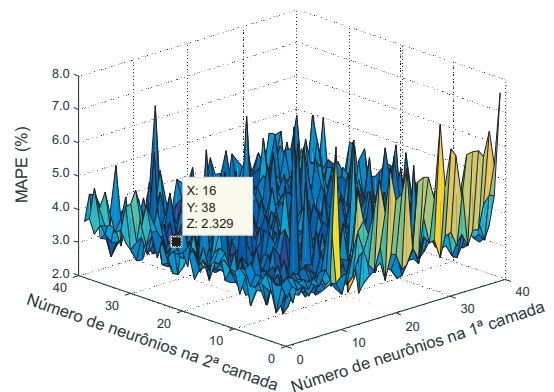


Figura 9. MAPE considerando apenas a potência.

Portanto, a RNA que apresentou menor valor de MAPE, 2,33%, foi a rede com 16 e 38 neurônios na primeira e segunda camadas, respectivamente. Ademais, a rede com 31 e 5 neurônios na primeira e segunda camadas, respectivamente, foi a que exibiu o menor erro relativo, igual a 6,8%.

Nas Figura 10 e 11 estão os resultados do teste para a RNA de topologia com o menor MAPE e menor erro relativo, respectivamente, para 106 dias. Como no resultado anteriormente apresentado em que a topologia de melhor MAPE apresenta resultado superior, divergindo com menor frequência da curva objetivo quando comparado ao gráfico da Figura 8, no qual a topologia da RNA leva em consideração o menor erro relativo.

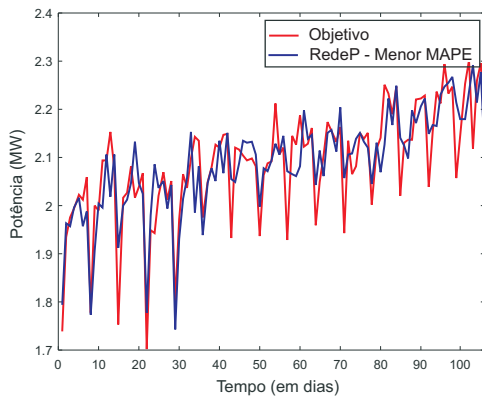


Figura 10. Previsão da rede de menor MAPE.

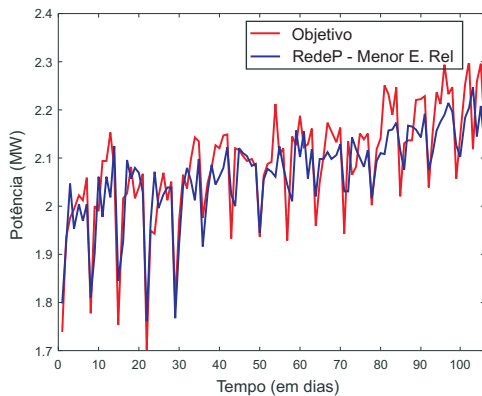


Figura 11. Previsão da rede de menor erro relativo.

Nota-se que, em ambos os casos, isto é, a rede neural que utiliza o critério de menor MAPE apresenta menor convergência em relação aos picos e vales do sistema ao longo do tempo, quando comparado a rede que considera o menor erro relativo. Este fato, deve-se ao modelo matemático do MAPE, o qual propõem uma medida normalizada, faz a RNA desconsiderar os pontos espúrios que são vistos no sinal real.

Por outro lado, o erro relativo, tende a variar dentro da média do sinal real, como pode ser visto nas Figuras 8 e 11, respectivamente.

Por fim, foi realizada a comparação entre as topologias de redes adotadas, em que "RedeP", denota a rede que possui apenas a potência como variável de entrada e "RedePT",

denota a rede que possui a potência e a temperatura como variáveis de entrada. O critério adotado foi o erro relativo entre o sinal estimado e o valor real, conforme exposto no gráfico da Figura 12.

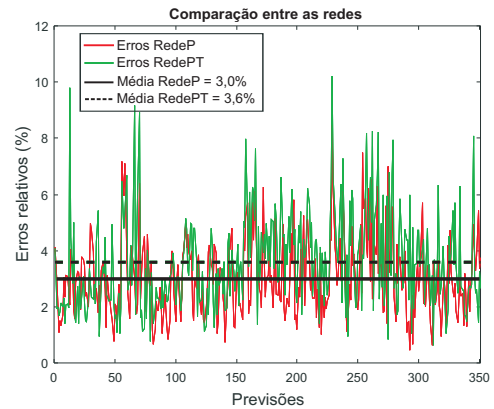


Figura 12. Comparação considerando os erros relativos.

A Figura 12 ilustra a comparação entre as redes através do erro relativo e pode-se observar que a rede treinada com apenas a potência como entrada, denominada "RNA P", apresenta menor média de erro relativo, igual a 3%. Enquanto que a rede utilizando dados de potência e temperatura, "RNA PT" apresenta média do erro relativo igual a 3,6%. Portanto, a temperatura influencia negativamente na previsão de demanda neste estudo, devido sua baixa variação no período estudado. Dessa forma, confirmando o resultado exposto pela matriz de correlação calculada na Seção 2.3 e refutando a hipótese que a temperatura melhoraria o modelo de previsão de demanda.

#### 4. CONCLUSÃO

Em vista de tudo que foi apresentado, nota-se que a temperatura apresenta baixa correlação com a variável de potência desta subestação. Comprovado pelo fato da média do erro relativo da topologia sem a presença de temperatura ter sido menor que a topologia da RNA que considera a temperatura: 3% e 3,6%, respectivamente.

Outro ponto importante está na estratégia de mapeamento da quantidade de neurônios. Os resultados indicaram que a RNA com apenas potência como entrada, levando em consideração o critério de menor MAPE, apresentou menos neurônios na primeira e segunda camada, quando comparado a RNA com potência e temperatura como entradas. Por outro lado, neste mesmo mapeamento, quando a métrica de comparação para escolha da RNA foi o menor erro relativo, ambas as topologias apresentaram o mesmo número de neurônios na primeira e segunda camada.

Finalmente, o modelo implementado neste trabalho apresenta performance significativa para previsão de demanda em subestações de energia elétrica, ressaltando que a inserção de temperatura não afetou positivamente em melhoria nas previsões. Em trabalhos futuros, o objetivo será analisar regiões do país que apresentem elevada variação de temperatura ao longo do ano.

## REFERÊNCIAS

- Ali, S., Mansoor, H., Khan, I., Arshad, N., Khan, M.A., and Faizullah, S. (2019). Hour-ahead load forecasting using ami data.
- Andrade, L.C.M.d. (2010). *Abordagem neurofuzzy para previsão de demanda de energia elétrica no curtíssimo prazo*. Ph.D. thesis, Universidade de São Paulo.
- Andrade, P.H.M., Mauricio Villanueva, J.M., and Macedo Braz, H.D. (2020). An outliers processing module based on artificial intelligence for substations metering system - (aceito). *IEEE Transactions on Power Systems*, 1–9.
- Anwar, T., Sharma, B., Chakraborty, K., and Sirohia, H. (2018). Introduction to load forecasting. *International Journal of Pure and Applied Mathematics*, 119, 1527–1538.
- Box, G.E., Jenkins, G.M., Reinsel, G.C., and Ljung, G.M. (2015). *Time series analysis: forecasting and control*. John Wiley & Sons.
- Carmona, D., Jaramillo, M.A., González, E., and Alvarez, J.A. (2002). Electric energy demand forecasting with neural networks. In *IEEE 2002 28th Annual Conference of the Industrial Electronics Society. IECON 02*, volume 3, 1860–1865. IEEE.
- Dudek, G., Pelka, P., and Smyl, S. (2020). A hybrid residual dilated lstm end exponential smoothing model for mid-term electric load forecasting.
- Ghiassi, M., Zimbra, D.K., and Saidane, H. (2006). Medium term system load forecasting with a dynamic artificial neural network model. *Electric power systems research*, 76(5), 302–316.
- Hapuarachchi, D., Hemapala, K., and Jayasekara, A. (2018). Long term annual electricity demand forecasting in sri lanka by artificial neural networks. In *2018 IEEE PES Asia-Pacific Power and Energy Engineering Conference (APPEEC)*, 290–295. IEEE.
- Kagan, N., Oliveira, C.C.B.d., and Robba, E.J. (2005). Introdução aos sistemas de distribuição de energia elétrica.
- Lang, C., Steinborn, F., Steffens, O., and Lang, E.W. (2019). Electricity load forecasting – an evaluation of simple 1d-cnn network structures.
- Levenberg, K. (1944). A method for the solution of certain problems in least-squares. *Quarterly Applied Mathematics*, 2, 164–168.
- Liao, Z. and Pan, H. (2019). Short-term load forecasting with dense average network.
- Marquardt, D. (1963). An algorithm for least-squares estimation of nonlinear parameters. *SIAM Journal Applied Mathematics*, 11, 431–441.
- Massaoudi, M., Chihi, I., Sidhom, L., Trabelsi, M., Refaat, S.S., and Oueslati, F.S. (2019). A novel approach based deep rnn using hybrid narx-lstm model for solar power forecasting.
- Mukaka, M. (2012). Statistics corner: a guide to appropriate use of correlation in medical research. *Malawi Medical Journal*, 24(3), 69–71.
- Pelka, P. and Dudek, G. (2020). Pattern-based long short-term memory for mid-term electrical load forecasting.
- Ribeiro, P., Garrido, D., Velásquez, R., Falcão, D., and da Silva, A. (2006). Sistema computacional para previsão de demanda por energia em pontos de suprimento e subestações da coelba. *XVII Seminário Nacional de Distribuição de Energia Elétrica–SENDI. Belo Horizonte*.
- Santos, A.H.M., Haddad, J., and Cruz, R.A.P.d. (2008). Planning the expansion of distribution: technical and regulatory considerations; planejamento da expansão da distribuição: considerações técnicas e regulatórias.
- Sonmez, M., Akgüngör, A.P., and Bektaş, S. (2017). Estimating transportation energy demand in turkey using the artificial bee colony algorithm. *Energy*, 122, 301–310.