



Grupo de Estudo de Comercialização, Economia e Regulação do Mercado de Energia Elétrica-GCR

REDES NEURAS ARTIFICIAIS APLICADAS NA PROJEÇÃO DE CARGA DE CURTO PRAZO

VALERIA NUNES COSTA⁽¹⁾; ROGERIO DE ALMEIDA⁽¹⁾; CAIO CESAR FRANCO PEREIRA⁽¹⁾; FLAVIO ROBERTO SOARES PEREIRA DA SILVA⁽¹⁾; DANILO ZUCOLLI FIGUEIREDO⁽¹⁾
(1) CPFL Energia

RESUMO

A previsão do consumo de energia elétrica é essencial para os processos de gestão das empresas do setor de energia, atuando como insumo importante para a realização de estudos energéticos e financeiros. O presente informe técnico propõe uma metodologia para projeção de carga diária de curto prazo baseada em Redes Neurais Artificiais (RNAs) e apresenta os resultados da aplicação dessa metodologia aos dados de distribuidoras do grupo CPFL Energia. Os resultados obtidos, em termos de Erro Médio Absoluto Percentual (MAPE) das projeções, são similares a resultados descritos na literatura e superiores aos obtidos pelo uso de modelos de médias-móveis.

PALAVRAS-CHAVE

Redes Neurais Artificiais, Projeção de Carga, Curto Prazo, Gestão do consumo, Temperatura.

1. INTRODUÇÃO

A previsão de carga de energia elétrica é um problema prático de interesse para as empresas do setor elétrico, uma vez que a carga de energia é uma informação relevante para o planejamento energético e econômico-financeiro das empresas. Para as empresas de distribuição de energia, a projeção da carga de energia elétrica é insumo de grande importância para processos como, a comercialização de energia, o planejamento da operação dos sistemas elétricos, análises financeiras e contábeis, etc.

A carga de energia elétrica, ou simplesmente carga, de uma distribuidora é definida como a quantidade de energia elétrica injetada em seu sistema de distribuição, considerando também, a energia: (a) produzida por centrais geradoras conectadas a rede da distribuidora; (b) destinados ao atendimento de outras distribuidoras; e (c) injetada no sistema de transmissão.

Em função da aplicação da projeção da carga é utilizado um dado horizonte específico de previsão, sendo que geralmente os horizontes de projeção são classificados como segue [1]:

- a) Curtíssimo prazo: horizonte de projeção de alguns minutos até 24 horas à frente;
- b) Curto prazo: horizonte de projeção de um dia até uma semana à frente;
- c) Médio prazo: horizonte de projeção de uma semana até um ano à frente; e
- d) Longo prazo: horizonte de projeção superior a um ano à frente.

Diferentes métodos têm sido aplicados para a projeção de carga, como métodos estatísticos e baseados em inteligência computacional. Ao longo do tempo as projeções de carga foram elaboradas utilizando técnicas quantitativas que se baseavam em análises de séries temporais, tais como a suavização exponencial e a

metodologia de Box-Jenkins [2] e apenas mais recentemente, devido às não-linearidades intrínsecas ao comportamento da carga de energia e suas relações com os diversos fatores exógenos, vem se expandindo o uso de técnicas de inteligência artificial como redes neurais artificiais (RNAs), lógica Fuzzy e sistemas de inteligência cognitiva [3]. Entre os fatores exógenos que impactam a carga pode-se citar as condições climáticas (destacadamente a temperatura), os hábitos de consumo e os dias da semana.

O presente informe técnico propõe uma metodologia para a projeção de carga de curto prazo com base em um modelo de RNAs. Na literatura existem trabalhos com aplicações de RNAs para a projeção de carga tanto em nível nacional quanto internacional. Dentre esses pode-se citar um trabalho desenvolvido em 2010 por [4] em conjunto com a Companhia Energética de Pernambuco (CELPE) onde foram desenvolvidos modelos de previsão de carga de energia elétrica no curto prazo utilizando RNAs e lógica fuzzy (modelo híbrido) considerando a variável temperatura. Esse trabalho teve como foco a realização da projeção de carga diária de 7 a 14 dias à frente por barramento da área de concessão da CELPE para fins operativos. Outro trabalho nacional que merece destaque foi desenvolvido pela Companhia de Transmissão de Energia Elétrica Paulista (CTEEP), também para fins operativos, cujo objetivo foi a projeção da carga diária (hora-a-hora) com antecedência de até 48 horas, por áreas elétricas [3]. Internacionalmente pode-se citar [5] que realizou a estimativa da demanda de energia elétrica da China utilizando RNAs baseadas em indicadores econômicos e no crescimento populacional, tendo por objetivo o planejamento anual de carga. Existem também trabalhos como [6] que propõe o uso conjunto de modelos autoregressivos e de RNAs para a modelagem dos comportamentos lineares e não-lineares em séries temporais e que podem ser utilizados para a projeção de carga de energia elétrica.

O restante desse informe técnico está organizado da seguinte maneira. Na Seção 2 é apresentada uma metodologia para previsão da carga de curto prazo com base em RNAs. As principais contribuições desse informe técnico são apresentadas nessa seção, em que é apresentada a arquitetura do modelo - baseada na construção de duas RNAs - e o conjunto específico de variáveis explicativas utilizado para a projeção de carga de curto prazo. Essa metodologia foi aplicada para empresas de distribuição de energia do Grupo CPFL Energia localizadas em diferentes regiões do Brasil, com diferentes características climáticas, econômicas e de hábitos de consumo, buscando-se evidenciar a capacidade de generalização do modelo. Os resultados obtidos da aplicação da metodologia às empresas de distribuição do Grupo CPFL Energia são apresentados na Seção 3. Finalmente, na Seção 4 são apresentadas as principais conclusões desse trabalho.

2. METODOLOGIA PARA PREVISÃO DE CARGA DE CURTO PRAZO

Nessa seção é apresentada uma metodologia para previsão de carga de curto prazo baseada em RNAs. Na Subseção 2.1 são introduzidos os conceitos fundamentais sobre RNAs e na Subseção 2.2 são apresentadas a arquitetura e as variáveis de entrada consideradas no modelo para projeção de carga de curto prazo.

1.1 Redes Neurais Artificiais

Uma Rede Neural Artificial (RNA) é uma técnica que simula, por meio de algoritmos matemáticos, o funcionamento do cérebro humano, sendo capaz de solucionar problemas complexos, além de possuir a capacidade de aprender mediante exemplos. As RNAs permitem lidar com dados que contenham ruídos e que sejam incompletos, além do tratamento de problemas não-lineares [7].

De forma análoga ao processamento no cérebro humano, uma RNA recebe informações externas, que são propagadas por meio de conexões (sinapses), gerando na saída da rede uma variável de resposta. A primeira camada da RNA é chamada de camada de entrada, sendo composta por neurônios onde são informadas as variáveis de entrada do problema. A camada de entrada transmite os valores das variáveis de entrada para os neurônios das camadas intermediárias e, por fim, os neurônios das camadas intermediárias transmitem as informações para os neurônios da camada de saída gerando as saídas da RNA. A definição do número de camadas, quantidade de neurônios por camada e a forma como os neurônios se conectam define o que é chamado de arquitetura da rede.

Para que uma RNA possa aprender os padrões de um problema, a mesma deve ser submetida a um processo de treinamento (aprendizado) que consiste na definição (calibração) dos pesos das conexões entre os neurônios [8]. São os pesos atribuídos às conexões entre os neurônios que permitem, após a RNA ter sido

treinada, representar as características mais relevantes (ou padrões) do problema modelado pela RNA.

Na Figura 1 é apresentada a arquitetura de uma RNA do tipo Perceptron Multicamadas (PMC). A PMC é a arquitetura de rede mais popular, composta por uma camada de entrada (onde cada neurônio representa uma variável de entrada), uma ou mais camadas intermediárias e uma camada de saída. Nessa arquitetura, os neurônios de uma camada possuem ligações (conexões ou sinapses) com os neurônios da camada subsequente e cada conexão possui um peso associado. Destaca-se que RNAs do tipo PMC podem ser aplicadas para previsão de séries temporais [9] como a série de carga e, por isso, são aplicadas na metodologia proposta neste informe técnico.

Na Figura 2 é apresentada a estrutura básica de um neurônio. Como pode ser observado, o neurônio recebe as informações dos neurônios da camada anterior (x_1, x_2, \dots, x_n) ponderadas pelos pesos das conexões (w_1, w_2, \dots, w_n) e as processa por meio da função F , chamada de função de ativação do neurônio, gerando assim, um sinal de saída Y que é propagado para a próxima camada.




Figura 1: Perceptron Multicamadas




Figura 2: Estrutura de um neurônio artificial [9]

A Equação 1 representa matematicamente a saída de um neurônio artificial que recebe informações de n conexões (sinapses).

$$Y = F \left(\sum_{i=1}^n x_i w_i \right).$$

(1)

O processo de treinamento consiste na determinação dos pesos (w_1, w_2, \dots, w_n), para todas as conexões sinápticas, de modo a melhor representar o problema em análise. Um exemplo de algoritmo de treinamento é o

backpropagation (retropropagação do erro), cujo ajuste dos pesos ocorre mediante um processo de otimização realizado em duas fases distintas a cada iteração [4]:

- Fase I - Propagação (forward): as características de uma amostra são inseridas na camada de entrada, propaga-se para frente, neurônio a neurônio e emerge na camada de saída. É calculada a resposta fornecida pela RNA para um dado padrão de entrada;
- Fase II - Retropropagação (backward): nessa fase, o desvio (erro) entre a resposta desejada (alvo) e a resposta fornecida pela RNA é utilizado para o ajuste dos pesos das conexões. Os erros que se originam nos neurônios da camada de saída se propagam para trás, camada por camada e os pesos são atualizados.

Ao longo do treinamento, vários padrões de entrada e suas respectivas saídas alvo são apresentadas à RNA, de forma que os pesos de suas sinapses sejam calibrados, de forma iterativa, pelo algoritmo de treinamento, com a finalidade de minimizar alguma métrica de desempenho, como a soma dos erros quadráticos entre as saídas obtidas pela RNA e as saídas alvo [10].

No processo de treinamento, é prática comum utilizar a metodologia de cross-validation (validação cruzada). Na cross-validation várias amostras são selecionadas aleatoriamente para compor o conjunto de treinamento e de teste (validação da rede treinada). Essa sistemática permite a possibilidade de que sejam contempladas diferentes amostras tanto no conjunto de treinamento como no de teste. O desempenho global do processo de cross-validation é dado pela média dos desempenhos individuais de cada experimento [9].

Como no início do processo de treinamento os pesos iniciais das sinapses entre os neurônios são definidos aleatoriamente, para uma mesma topologia de rede a convergência dos pesos sinápticos pode ser diferente, dependendo do ponto de inicialização de seus valores, resultando em diferentes saídas que podem não ser a de menor erro (ótimo global). A Figura 3 representa essa situação, ilustrando possíveis trajetórias entre os valores inicial e final do erro associado à rede treinada.

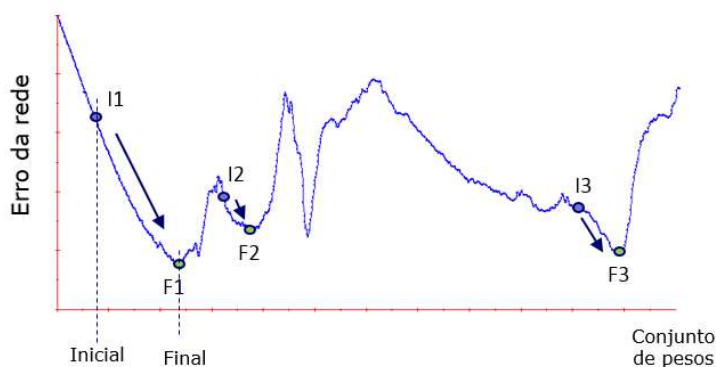


Figura 3: Exemplificação da inicialização dos pesos e a convergência do erro associado à rede [9]

Para obtenção de um melhor resultado de saída, [11] demonstram que a capacidade de generalização de um sistema neural pode ser melhorada combinando várias redes neurais (ensemble) como, por exemplo, treinando redes individualmente e combinando os resultados de suas saídas. Assim, um ensemble é o processo de combinar modelos por meio de suas saídas, tendo em vista que frequentemente um conjunto de modelos tem desempenho melhor do que modelos individuais. O ensemble também ajuda a minimizar os efeitos ilustrados acima na Figura 3.

2.2 Modelo baseado em RNAs para a projeção de carga de curto prazo

No presente trabalho será utilizado modelo de RNA para projetar a **carga global diária de energia elétrica no curto prazo até 7 dias a frente** considerando a variável temperatura, reconhecidamente uma das variáveis de

maior relevância para o caso de projeções de carga no curto prazo [7], além de outras, como dia da semana, estação do ano, feriados e pontes de feriados, que também influenciam o consumo de energia elétrica.

A disponibilidade de um histórico com quantidade e qualidade de dados e a escolha adequada das variáveis mais significativas para a projeção são essenciais para a obtenção de um bom resultado. No presente trabalho foram utilizados 13 anos de dados históricos (2006 a 2018) de carga diária das empresas de distribuição de energia elétrica do grupo CPFL Energia.

Foram propostos dois modelos de previsão de carga diária, um para os meses de janeiro a novembro (Rede A), e outro exclusivo para o mês de dezembro (Rede B). Essa divisão foi efetuada devido à atipicidade do mês de dezembro, onde fatores como festas de final de ano e férias coletivas impactam de maneira significativa no comportamento da carga.

Além dos dados de temperatura médias diárias dos principais municípios da área de concessão das empresas de distribuição, outras variáveis de entrada foram utilizadas. Nas Tabelas 3 e 4 são apresentadas as características das camadas de entrada dos dois modelos de projeção utilizados.

Tabela 3 – Camada de entrada da Rede Neural Artificial A (Rede A)

Número de neurônios	Variável de entrada
1	Carga diária do mesmo dia da semana anterior
1	Pluviometria acumulada dos últimos 5 dias de cidades relevantes
1	Média das últimas 3 cargas diárias do mesmo dia da semana
1	Média das cargas diárias do último ano dos dias de mesmo dia da semana com temperaturas próximas
3	Temperatura média das cidades mais relevantes*
7	Dia da semana (entrada binária, 0 ou 1)
12	Mês correspondente (entrada binária, 0 ou 1)
4	Estação do Ano (entrada binária, 0 ou 1)
1	Informação de Feriado (entrada binária, 0 ou 1)
1	Informação de Ponte de feriado (entrada binária, 0 ou 1)

*com população e mercado significativos regionalmente

Tabela 4 – Camada de entrada da Rede Neural Artificial B (Rede B)

Número de neurônios	Variável de entrada
1	Variável que representa o comportamento típico de final de ano
3	Temperatura média das cidades mais relevantes*
7	Dia da semana (entrada binária, 0 ou 1)
1	Informação de Feriado (entrada binária, 0 ou 1)
1	Informação de Ponte de feriado (entrada binária, 0 ou 1)

*com população e mercado significativos regionalmente

É importante destacar que, as variáveis de entrada do modelo interferem diretamente na qualidade da projeção. Para a definição das variáveis das Tabelas 3 e 4 foram realizados vários testes e simulações exaustivas até a definição do melhor conjunto de variáveis.

No presente trabalho optou-se por apenas uma camada intermediária, cujo número de neurônios foi obtido do teorema de Kolmogorov [16], conforme apresentado na Equação (2):

$$n = \sqrt{i+o} + a, \quad (2)$$

onde n é o número de neurônios, i é o número de variáveis de entrada, o é número de saídas e a é uma constante entre 1 e 10.

Desta forma, variou-se o número de neurônios dentro do intervalo obtido da Equação (2), adotando-se o valor que proporcionou os menores erros para o conjunto de amostras simulados. A Tabela 5 apresenta as configurações da camada intermediária.

Tabela 5 – Número neurônios da camada intermediária

Modelo de projeção	Número de neurônios
Rede A	15
Rede B	8

O número de neurônios da camada de saída está associado à variável projetada, no presente trabalho, a carga diária. Desta forma, os modelos propostos possuem apenas um neurônio na camada de saída e, com base nos comentários feitos na Subseção 2.1, o modelo de RNA adotado foi um ensemble de três RNAs do tipo PMC.

2. RESULTADOS E DISCUSSÕES

A metodologia de projeção proposta foi aplicada a três distribuidoras de energia elétrica do Grupo CPFL, situadas nas regiões Sudeste e Sul do Brasil, de forma que se pudesse avaliar a capacidade da metodologia em capturar suas características regionais diferentes.

O desempenho dos modelos de projeção foi mensurado pelo Erro Médio Absoluto Percentual (MAPE) conforme Equação 3 [11]:

$$MAPE = \left(\frac{1}{N} \sum_{i=1}^N \frac{|y_i - \hat{y}_i|}{y_i} \right),$$

(3)

onde N é o número de projeções realizadas, y_i é a carga observada (real) e \hat{y}_i é a carga projetada pela RNA.

2.1 Avaliação do desempenho dos modelos no período de treinamento

Para avaliar a capacidade de representação dos modelos de projeção propostos (Rede A e Rede B), foram realizadas as projeções de carga diária para o mesmo período em que as redes foram treinadas, com base em dados históricos do período de 2006 a 2017.

A Figura 4 apresenta os valores de carga projetada e realizada para o período de treinamento para uma das distribuidoras consideradas neste estudo. Observa-se que os valores reais e projetados são próximos, apresentando baixos valores de erro em todo o período considerado.

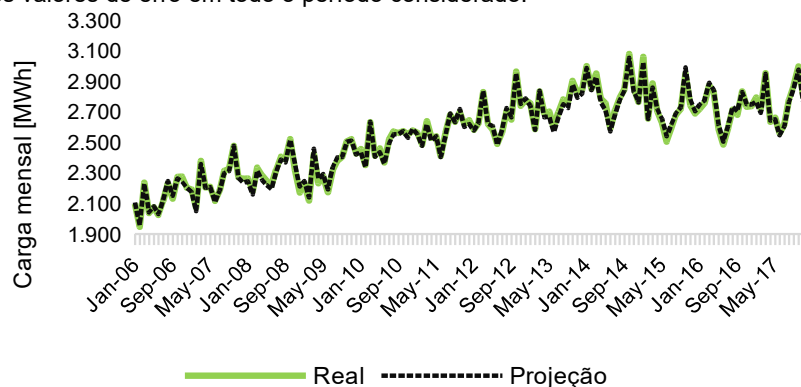


Figura 4: Carga projetada e real do período de treinamento da rede para a Distribuidora 1

Na Tabela 6 são apresentados os Erros Médios Absolutos Percentuais (MAPEs) obtidos para cada mês do período de treinamento para todas as distribuidoras consideradas no estudo. Como pode ser observado, os modelos conduzem a valores de MAPE médio de treinamento de 1,5%, 1,6% e 2,2% para as Distribuidoras 1, 2 e 3 respectivamente, demonstrando a capacidade do modelo proposto em representar a carga destas empresas com reduzido erro.

Tabela 6 - MAPE de cada mês para o período de treinamento

Mês	MAPE da Distribuidora 1	MAPE da Distribuidora 2	MAPE da Distribuidora 3
Janeiro	1,8%	1,5%	2,8%
Fevereiro	1,6%	1,6%	2,2%
Março	1,4%	1,4%	2,0%
Abril	1,7%	1,7%	2,7%
Mai	1,5%	1,5%	2,2%
Junho	1,5%	1,6%	2,0%
Julho	1,2%	1,2%	1,8%
Agosto	1,1%	1,2%	1,6%
Setembro	1,5%	1,4%	1,9%
Outubro	1,5%	1,5%	1,9%
Novembro	1,9%	1,7%	2,3%
Dezembro	2,1%	1,5%	3,0%
Média	1,6%	1,5%	2,2%

2.2 Avaliação do desempenho dos modelos para projeção

Para avaliar a acurácia das projeções realizadas pelos modelos, os mesmos foram utilizados para fazer as projeções das cargas diárias do ano de 2018, período não contemplado no treinamento das RNAs.

Na Tabela 7 são apresentados os MAPEs referentes a cada mês do ano de 2018. Como pode ser observado, os modelos conduzem a um MAPE médio de projeção em torno de 3%. Vale destacar que em [4] foram obtidos valores de MAPE dessa mesma ordem de grandeza e que a metodologia proposta foi capaz de representar o comportamento da carga de empresas de distribuição com áreas de concessão em regiões geográficas distintas.

Tabela 7 - MAPE de cada mês para 2018

Mês	MAPE da Distribuidora 1	MAPE da Distribuidora 2	MAPE da Distribuidora 3
Janeiro	2,8%	2,0%	4,4%
Fevereiro	2,2%	2,2%	2,5%
Março	3,3%	2,9%	3,3%
Abril	3,1%	2,4%	3,8%
Mai	3,8%	3,9%	2,9%
Junho	3,3%	3,6%	3,5%
Julho	2,4%	1,8%	1,8%
Agosto	1,1%	1,2%	1,6%
Setembro	2,5%	3,3%	2,9%
Outubro	2,8%	1,7%	2,3%
Novembro	3,7%	3,2%	3,0%
Dezembro	3,9%	3,7%	5,4%
Média	2,9%	2,7%	3,1%

Na Figura 5 são apresentados os valores de carga diária projetadas e realizadas para o ano de 2018. A última semana de maio/18 foi modelada como "ponte de feriado", de forma a retratar parte dos efeitos da redução de consumo provocados pela greve dos caminhoneiros.

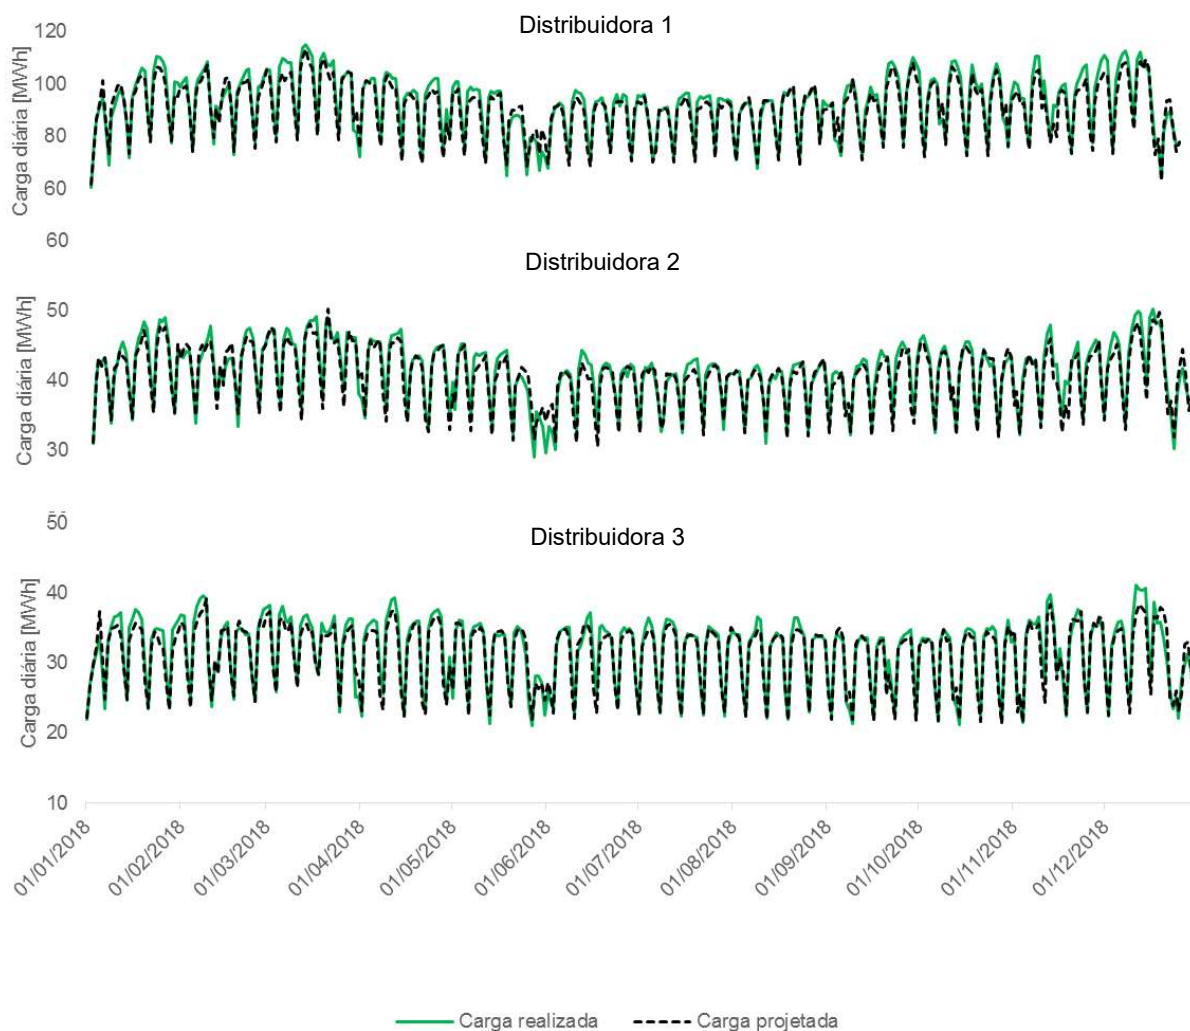


Figura 5 – Carga diária projetada e real de 2018

2.3 Comparação da precisão do modelo com modelo de menor complexidade

A Figura 6 mostra a comparação dos erros de previsão obtidos pela metodologia baseada em RNAs com os erros de previsão obtidos pelo uso de um modelo de médias móveis, que é um modelo de menor complexidade computacional e não envolve variáveis exógenas, sendo comumente utilizado na projeção de carga.

Os resultados apresentados na Figura 6 demonstram que a metodologia baseada em RNAs apresenta maior acurácia, em termos de MAPE, do que o modelo por médias móveis.

É importante salientar que para os estudos foram utilizados dados observados de temperatura. Na prática, para a projeção de carga, trabalha-se com as projeções de temperatura, cuja assertividade é determinante para a obtenção de bons resultados nas projeções de carga.

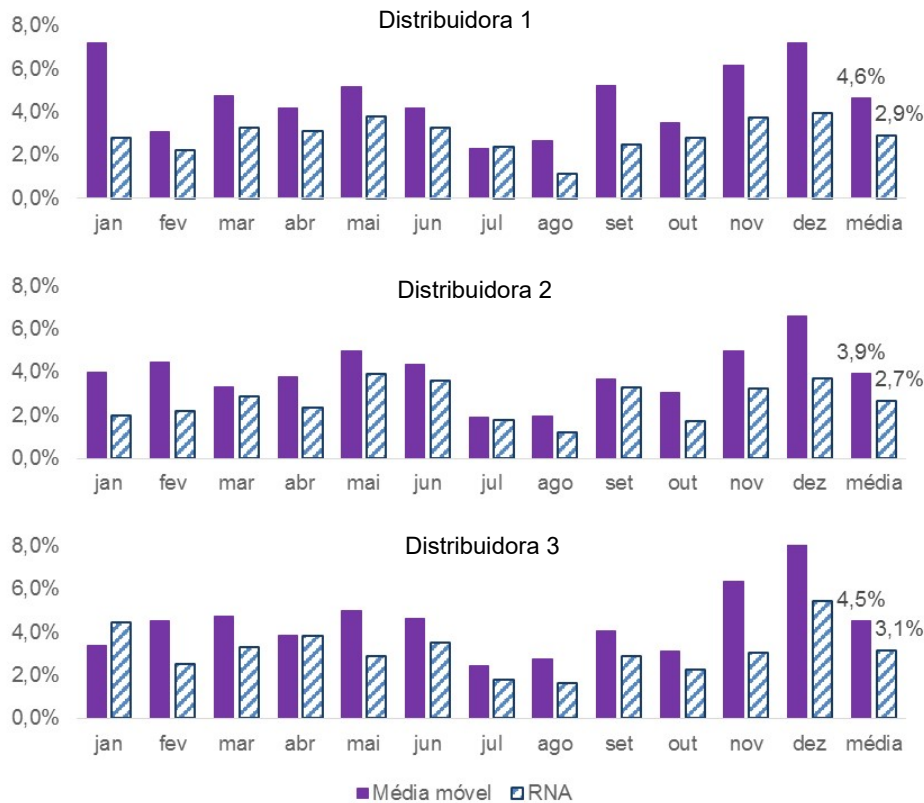


Figura 6 – Comparação modelo médias móveis e RNA para o ano de 2018

3. CONCLUSÃO

Os modelos de projeção baseados em RNAs do tipo PMC, considerando um ensemble de 3 redes, mostraram-se ferramentas adequadas para a realização da projeção de carga diária até 7 dias à frente.

No exemplo de aplicação, o conjunto de dados históricos de 2006 a 2017 foi utilizado para treinamento da rede, enquanto que, a acurácia do modelo foi avaliada com as projeções de carga para o ano de 2018 (período não contemplado no treinamento das redes). Os modelos propostos conduziram a MAPEs de mesma ordem de grandeza observada em estudos similares, mas apresentaram maior acurácia quando comparados a um modelo de projeção por médias móveis.

Destaca-se que as etapas gerais da metodologia proposta nesse trabalho podem ser estendidas para outros estudos de projeção de curto prazo. Além disso, a separação dos dados em duas redes e o conjunto específico de variáveis explicativas utilizado são contribuições que o presente informe técnico apresenta para a obtenção de resultados satisfatórios da modelagem da carga de curto prazo para todos os períodos do ano. A metodologia foi aplicada para empresas de distribuição do Grupo CPFL localizadas em diferentes regiões do Brasil, com diferentes características climáticas, econômicas e de hábitos de consumo, evidenciando a capacidade de generalização dos modelos baseados em RNAs.

REFERÊNCIAS BIBLIOGRÁFICAS

- (1) FAN, T.H.S. Probabilistic electric load forecasting: A tutorial review. 2016. International Journal of Forecasting, vol. 32.2016, 3, p. 914-938.
- (2) FOGLIATTO, F.S. Previsão de demanda por energia elétrica – Método e aplicação. In: XXV Encontro Nac. de Eng. de Produção, Porto Alegre, 2005.
- (3) GUIRELLI, C.R.; OLIVEIRA, E. L. Previsão de carga de curto prazo de áreas elétricas através de técnicas de inteligência artificial. 2006. Dissertação (Doutorado em Engenharia) – Universidade de São Paulo, São Paulo.
- (4) SILVEIRA, T. M. Modelos de previsão de carga em Curto Prazo desenvolvidos com redes neurais e lógica Fuzzy, considerando a variável temperatura. 2010. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal de Pernambuco, Recife.
- (5) DENG, J. Energy demand estimation of china using ANN. School of Business Administration, Changchun Taxation College, Changchun, China. 2010. Third International Conference on Business Intelligence and Financial Engineering.
- (6) LI, Z.; HAOFE, S.J. An ARIMA-ANN Hybrid Model for Time Series Forecasting: In: Systems Research and Behavioral Science, Beihai University, China, 2003.
- (7) HAYKIN, S. Neural Networks: A Comprehensive Foundation: ed 2. Ann Arbor: Prentice Hall, 1999.
- (8) TEIXEIRA JÚNIOR, L.A; PESSANHA, J.F.M; SOUZA, R.C. Análise Wavelet e Redes Neurais Artificiais na Previsão da Velocidade de Vento. In: Simpósio Brasileiro de Pesquisa Operacional. In: SBPO 2011, Ubatuba, 2011.
- (9) SILVA, I.N.; SPATTI, D. H., FLAUZINO, R. A. Redes Neurais Artificiais para engenharia e ciências aplicadas: ed 1. São Paulo: Editora Artliber, 2010.
- (10) OLIVEIRA, E. L. Previsão de demanda de energia elétrica com redes neurais artificiais e análise por série de Fourier. 2016. Dissertação (Mestrado em Engenharia Elétrica) – Universidade Federal de Minas Gerais, Belo Horizonte.
- (11) HANSEN, L.K; SALOMON, P. Neural network ensembles, IEEE Trans. Pattern Analysis and Machine Intelligence, 12, n 10, 1990, p. 993-1001.

DADOS BIOGRÁFICOS



Valéria Nunes Costa - MG, 13 de março de 1993. Analista de Planejamento de Carga na CPFL Energia. Técnica em Eletrotécnica pela Escola de Furnas (2010). Graduiu-se em Engenharia Elétrica pela Universidade Federal de Itajubá (UNIFEI) em 2015. Atualmente cursa o programa de pós-graduação em Sistemas de Energia pela



XXV SNPTEE
SEMINÁRIO NACIONAL DE PRODUÇÃO E
TRANSMISSÃO DE ENERGIA ELÉTRICA

10 a 13 de novembro de 2019
Belo Horizonte - MG

3676
GCR/15

UNICAMP.