

Previsão de Demanda de Energia Elétrica em Microgrid Considerando Níveis Menos Agregados por Meio da Aplicação de Rede Neural Artificial GRNN Combinada com o Método Estatístico SARIMA

Nelson Nunes André Junior*;
Carlos Roberto Mendonça da Rocha**;
Marcos Ricardo Müller***

*Universidade Estadual do Oeste do Paraná, BRASIL
(Tel: 45-99827-5299; e-mail: nelson.junior@unioeste.br).

**Universidade Estadual do Oeste do Paraná, BRASIL
(e-mail: carlos.rocha@unioeste.br).

*** Faculdade UNIGUAÇU, BRASIL).
(e-mail: marcos_ricardo@live.com)

Abstract: The growth in electricity consumption in the world forces countries to have a well-structured planning in relation to forecasting the demand for electricity in their most diverse sectors. Several techniques are used to predict electrical loads, such as artificial intelligence models, statistical models and hybrid models. This work aims to present a model based on the combination of a statistical method, SARIMA, and an artificial neural network, the GRNN, to improve the accuracy of forecasts of demand for electricity consumption. The data set used in this work belongs to a group of buildings located in the Itaipu Technological Park and was acquired through electronic meters installed together with the transformers that serve each of these buildings, performing data collection every 15 minutes. After processing and refining the database, forecasting techniques were applied, each one using a forecast horizon of 1, 3 and 5 days, the first technique being the combination between GRNN and SARIMA and the other techniques used were the methods themselves separately, allowing the comparison of their results. The results obtained with the proposed combined model are, in general, more accurate when compared to the results of the techniques individually, as they combine the advantages of each technique and end up smoothing the negative characteristics of each other, thus causing a balance that reflects on the forecast. generated.

Resumo: O crescimento do consumo de energia elétrica no mundo obriga que países tenham um planejamento bem estruturado em relação a previsão da demanda de energia elétrica de seus mais diversos setores. Utilizam-se diversas técnicas para previsão de cargas elétricas, como, por exemplo, os modelos de inteligência artificial, os modelos estatísticos e os modelos híbridos. Este trabalho tem por objetivo apresentar um modelo baseado na combinação entre um método estatístico, o SARIMA, e uma rede neural artificial, a GRNN, para melhorar a exatidão das previsões de demanda de consumo de energia elétrica. O conjunto de dados utilizados neste trabalho pertence a um grupo de edificações localizadas no Parque Tecnológico Itaipu e foi adquirido por meio de medidores eletrônicos instalados juntos aos transformadores que atendem a cada uma destas edificações, realizando coletas de dados a cada 15 minutos. Após o tratamento e refinamento da base de dados, foram aplicadas técnicas para previsão, cada uma, utilizando-se um horizonte de previsão de 1, 3 e 5 dias, sendo a primeira técnica a combinação entre a GRNN e o SARIMA, e, as outras técnicas utilizadas foram os próprios métodos separadamente, permitindo a comparação de seus resultados. Os resultados obtidos com o modelo combinado proposto são, em geral, mais precisos quando comparados com os resultados das técnicas individualmente, pois combinam as vantagens de cada técnica e acabam suavizando as características negativas uma da outra, ocasionado assim, um equilíbrio que reflete na previsão gerada.

Keywords: SARIMA; Artificial Neural Networks; Demand forecast; Electricity; GRNN.

Palavras-chaves: SARIMA; Redes Neurais Artificiais; Previsão de demanda; Energia Elétrica; GRNN.

1. INTRODUÇÃO

A eletricidade, como recurso energético, desempenha um papel cada vez maior na economia mundial, pois segundo Kheirkhah *et. al.* (2013) cada vez mais sua aplicação impacta na produção das empresas e no dia-a-dia das pessoas, pois elas,

direta ou indiretamente, necessitam da energia elétrica. Pode-se dizer que o consumo de energia elétrica é um dos fatores que determina o bem-estar dos indivíduos e a economia social. No Brasil, cresce a demanda por energia elétrica, o que acaba ocasionando uma preocupação por parte do governo, estados, municípios e empresas quanto a disponibilidade e a qualidade

dos serviços relacionados à distribuição de energia elétrica. Devido as suas proporções continentais, o Brasil exige um planejamento bem estruturado quanto à produção, transmissão e distribuição de energia elétrica. De acordo com o Relatório Síntese do Balanço Energético Nacional 2020 (BEN), publicado pela Empresa de Pesquisa Energética (EPE, 2020), que é referência no setor, a geração de energia elétrica no Brasil em centrais de serviço público e autoprodutores atingiu 626,3 TWh em 2019, resultado 4,1% superior ao de 2018, deste total, centrais elétricas de serviço público, participaram com 83,27% da geração total, e, a geração hídrica, principal fonte de produção de energia elétrica no Brasil, cresceu 2,3% na comparação com o ano anterior. Nesse contexto, a previsão do consumo de energia elétrica se torna um fator primordial para se planejar sistemas de geração de energia. Uma das atividades do planejamento de demanda é a estimativa de consumo com base em previsões projetadas para determinado período no tempo. Segundo Correa (2021) Previsões são úteis tanto para a gestão e controle de processos como para a administração das cadeias de valor. Segundo Junior (2018) a previsão da demanda resulta em informações de comportamento da demanda futura, possibilitando um melhor planejamento da produção de uma organização e uma melhor estruturação da organização para atender essa demanda. Segundo Campagnollo (2017) uma previsão de demanda refinada fornece subsídios para que a programação de produção seja a mais assertiva possível e a utilização de recursos siga dessa mesma forma. Segundo Correa (2021) os métodos de previsão de demanda são classificados, em dois tipos: métodos qualitativos e quantitativos. Os métodos qualitativos se baseiam na opinião de especialistas e os métodos quantitativos tem como base a análise de séries temporais se utilizam de modelos matemáticos a partir de dados disponíveis. Segundo Campagnollo (2017) a escolha do método adequado de previsão de demanda, está atrelado ao horizonte de tempo que se deseja obter a previsão. Segundo Silva (2020) as séries temporais são um padrão formado pelas observações repetidas de demanda para um produto ou serviço em sua ordem de ocorrência. Em tempos mais atuais a previsão da demanda pode ser realizada com base em técnicas de inteligência computacional, segundo Deina (2020) as Redes Neurais Artificiais (RNA's) possuem características que possibilitam sua aplicação na previsão de séries temporais, entre elas, pode-se citar: capacidade de aprendizado, adaptação por experiência, habilidade de generalização, organização de dados, tolerância a falhas e armazenamento distribuído. Tubino (2007) considera que, apesar da existência de variadas técnicas de previsão, há características comuns entre elas, como: a suposição de que as causas que influenciaram a demanda passada continuam a influenciá-las no futuro; a imperfeição das previsões; a diminuição da acuracidade à medida que aumenta o período de tempo considerado; a previsão para grupos de produtos possui maior precisão do que aquela realizada para produtos individuais. Para as séries temporais pode-se realizar as previsões aplicando-se os métodos quantitativos como o ARIMA (Autorregressivo Integrado de Média Móvel) e quando se tem o fator de sazonalidade a ser considerado pode-se aplicar o método SARIMA (Autorregressivo Integrado de Médias Móveis com Sazonalidade) além da possibilidade de aplicação de RNA's.

O objetivo deste trabalho é a aplicação e apresentação dos resultados da combinação do método estatístico SARIMA e da RNA GRNN combinados para a previsão de demanda de energia elétrica em um conjunto de dados de diferentes níveis de agregação, e compará-los com os resultados de cada uma das duas técnicas, GRNN e SARIMA, separadamente, fazendo com que cada uma sirva como *benchmark* para validação dos resultados, a fim de, demonstrar que, quando as duas técnicas são combinadas, os resultados gerados tornam-se mais precisos, devido as características de uma técnica acabar auxiliando nas deficiências de outra para realização das previsões. A forma de combinação das duas técnicas e os passos a serem executados para obtenção dos resultados serão apresentados em um capítulo sobre as metodologias utilizadas.

2. PRINCIPAIS CONTRIBUIÇÕES

Entre os diferenciais deste trabalho está a utilização de dados de um cenário real, localizado no Brasil, com um alto nível de desagregação e, com uma grande variação na demanda de cargas, o que ocasiona um cenário especialmente difícil para se realizar previsões. Outro diferencial é a utilização combinada das previsões de um método estatístico e de uma rede neural artificial neste cenário específico.

3. TRABALHOS RELACIONADOS

Em Jetcheva, Majidpour e Chen (2014) foi feita a previsão da demanda onde foram excluídos dados de datas comemorativas, feriados, finais de semana e horários fora de pico dos dados de treinamento de uma RNA *Multilayer Perceptron*, pois considerou-se que poderiam influenciar no resultado final. Müller e Franco (2014) utilizaram algoritmos de clusterização de dados para realizar previsões com o Método de Dias Similares. Devido a problemas técnicos, o banco de dados encontrava-se com dados faltantes e aberrantes, para resolução deste problema esses dados foram substituídos pelo cálculo da média do vizinho anterior com o vizinho posterior ou desconsiderados quando havia uma sequência grande corrompida. Leng *et al.* (2013) utilizaram uma RNA GRNN para a realizar uma previsão de curto prazo de tráfego urbano, que acabou demonstrando superioridade na previsão quando comparada com RNA's *Backpropagation* e função de base radial. Os valores de MAPE apresentados pelos trabalhos mencionados são explorados no item 8 para fins de comparação com os resultados apresentados por este trabalho.

4. CENÁRIO DE ESTUDOS

Como diferencial este trabalho utiliza dados reais de consumo de energia elétrica originários de uma micro rede inteligente instalada em um conjunto de prédios que se encontra no Parque Tecnológico Itaipu (PTI) localizado na cidade de Foz do Iguaçu - PR (Brasil). Em cada bloco do complexo foram instalados *smart-meters* para a coleta dos dados. Segundo Fortes *et al.* (2017) os *smart-meters* tem a capacidade para capturar, processar, responder e comunicar informações de energia como consumo de energia elétrica, níveis de tensão, corrente e fator de energia, além de compartilhar essas informações com os outros integrantes do sistema elétrico, como as unidades de geração de energia ou ainda elementos do sistema de transmissão e controle, propiciando, entre outras coisas, maior agilidade na identificação e solução de

problemas operacionais e gestão mais eficiente do fluxo de energia

Ao todo foram utilizados três *smart-meters* instalados juntos a diferentes transformadores, o primeiro denominado “RES” refere-se ao equipamento que atende o bloco onde fica o restaurante, além deste, os transformadores “T03” e “T09” também foram monitorados, estes últimos atendem blocos formados por salas de aula, banheiros e salas administrativas do PTI. O banco de dados utilizado possui informações de data e hora e valores da energia ativa consumida, além da temperatura. Os dados coletados correspondem ao período que vai do início do mês de maio ao fim do mês de julho do ano de 2013. Os blocos em questão abrigam o restaurante universitário que atende funcionários e estudantes das universidades que tem cursos dentro do PTI, além de salas de aula, salas utilizadas por departamentos do PTI, banheiros, um ambulatório, uma agência bancária, uma agência dos correios, uma pequena loja de *souvenirs* e um café, estes todos compoem as curvas de carga dos transformadores em questão. A medição, realizada na micro rede, ocorre por prédio, deste modo, cada prédio, com suas particularidades (sala de aula, escritório, lanchonete, entre outros) possuem diferentes perfis de consumo compoem suas cargas, ainda assim, com baixa agregação.

Para este trabalho a curva de carga diária (kW) considerada é composta por 96 medições distintas de consumo de energia ativa igualmente espaçadas no tempo em intervalos de 15 minutos entre uma coleta e outra. O horizonte histórico considerado corresponde aos meses de maio, junho e julho de 2013 (01 de maio a 31 de julho de 2013).

4.1 Outlier

O *outlier* ou dado aberrante pode ser definido como uma observação estatística cujo valor na amostragem é marcadamente diferente dos demais. De acordo com Bento (2018), um *outlier* pode ser definido como uma amostra que desvia de um conjunto de dados, podendo ser causados por erro humano, erros de coleta, problemas em sensores, interferência na transmissão de dados, erros de gravação ou de entrada, entre outros, sendo necessário o tratamento desses dados para que não interfiram negativamente na previsão. Segundo Chen (1993) os dados de séries temporais geralmente estão contaminados com *outliers*. O tratamento de *outliers* ocorre em duas etapas: identificar as posições e os tipos de *outliers* e, em seguida, ajustar os efeitos dos *outliers* para o propósito de estimação do modelo.

Neste trabalho foi realizada uma análise no conjunto de dados a ser utilizado em busca de *outliers*, sendo identificados 19 valores *outliers* em um conjunto de 18144 dados no geral. Por transformador são considerados 6048 dados no período considerado, ou seja, ao todo, os *outliers* representam, aproximadamente, 0,11% da quantidade de valores que foram utilizados para gerar as previsões. Após os mesmos serem identificados utilizou-se como metodologia a troca dos *outliers* pelo valor da interpolação entre os valores válidos imediatamente anterior e posterior à posição do *outlier*. O tratamento dos *outliers* foi feito de forma manual.

4.2 Níveis de Agregação

Quando falamos em consumo de energia elétrica, o nível de agregação deve ser entendido como aglomerados de consumidores de energia elétrica. Geralmente, a agregação das cargas elétricas ocorre em nível de transformadores, alimentadores ou subestações de energia, que são os pontos de medição de consumo de uma região ou local. Neste trabalho, o nível de agregação é baixo, uma vez que os dados correspondem a prédios individuais, cujas cargas são formadas por determinadas atividades, abordadas acima.

5. REFERENCIAL TEÓRICO

Nesse capítulo são apresentadas considerações a respeito da previsão da demanda por energia elétrica.

5.1 SARIMA

O modelo ARIMA foi proposto por Box e Jenkins na década de 1970 e, segundo Walter (2013) se origina em modelos autorregressivo (AR), que se referem ao uso de valores defasados de uma variável-alvo para fazer a previsão, médias móveis (MA), que utiliza os erros de previsão defasados como entradas com a intenção de se obter valores corretos, e da combinação dos modelos AR e MA (ARMA). O modelo ARIMA é utilizado em análise de séries temporais, mas quando se quer analisar dados de frequência mais alta, como alterações semanais ou mensais, deve-se considerar essa sazonalidade, nesses casos pode-se utilizar o modelo ARIMA sazonal multiplicativo, conhecido como SARIMA. Segundo Pinto (2016) sob condições de não estacionariedade e sazonalidade, a metodologia Box-Jenkins pode ser generalizada para os modelos SARIMA, permitindo que se diferencie as séries em estudo, de forma a garantir o controle adequado destes fenômenos.

5.2 Redes Neurais Artificiais (RNA)

As Redes Neurais Artificiais surgiram como resultado de estudos de onde os pesquisadores McCulloch e Pitts (1943) tentavam modelar o funcionamento de um cérebro humano, principalmente o processo de aprendizagem por experiência, que ocasionaria a criação de sistemas inteligentes capazes de realizar tarefas como classificação, reconhecimento de padrões, processamento de imagens, entre outras atividades. Segundo Martiniano (2016) as RNA's apresentam uma grande eficiência para o mapeamento de entradas e saídas de sistemas não lineares, para realizar processamento paralelo, além de simulação de sistemas complexos. As RNA's apresentam a capacidade de generalizar os resultados obtidos para dados previamente desconhecidos, ou seja, geram respostas coerentes para padrões ou exemplos diferentes dos que foram utilizados no seu treinamento. Uma RNA's tem a capacidade de apresentar respostas coerentes mesmo mediante dados diversos daqueles empregados na etapa de treinamento, isso ocorre devido a sua capacidade de generalização. Segundo Haykin (2001) as RNA's não compartilham de uma arquitetura única, existem diferentes arquiteturas propostas, que surgiram para lidar com limitações apresentadas por suas antecessoras, ou para atenderem a novas necessidades.

5.3 Rede Neural de Regressão Generalizada

A Rede Neural de Regressão Generalizada (GRNN) foi proposta, inicialmente, por Specht (1991), segundo Oliveira *et al.* (2015) é uma Rede Neural Artificial do tipo não recorrente, ou seja, do tipo *feedforward*, que estima variáveis dependentes a partir de variáveis independentes, e, nesse processo, envolve um conjunto de variáveis finito. O treinamento para essa RNA é do tipo supervisionada e possui uma estrutura fixa, segundo Silva (2014) essa estrutura é formada por uma camada de entrada, duas camadas intermediárias, chamadas de padrão e soma, e uma camada de saída. O número de neurônios em cada camada tem dependência com os padrões de treinamentos nas camadas de entradas e saídas. Segundo Feng (2004) a GRNN é baseada em uma função de kernel estatística de regressão não linear, ela pode realizar a aproximação do mapa inerente em qualquer amostra de dados, e a estimativa pode convergir para superfície de regressão ótima, mesmo utilizando amostras esparsas; é utilizada em vários campos, como, por exemplo, identificação de sistemas, controle adaptativo, reconhecimento de padrões e previsão de séries temporais. A partir da estimativa da densidade de Parzen a principal fórmula utilizada pela GRNN pode ser definida como:

$$Y(X) = \frac{\sum_{i=1}^n Y_i \exp \left[-\frac{(X-X_i)^T (X-X_i)}{2\sigma^2} \right]}{\sum_{i=1}^n \exp \left[-\frac{(X-X_i)^T (X-X_i)}{2\sigma^2} \right]} \quad (1)$$

Onde:

X , X_i e Y_i são as observações da amostra;

$Y(X)$ é a estimativa associada à amostra X ;

σ é o parâmetro de suavização, *i.e.* a largura do kernel da função gaussiana;

n é o número de amostras.

Segundo Feng (2004) $Y(X)$ é a média ponderada das observações da amostra, X_i é o peso para cada observação, formada pelo exponencial da distância euclidiana quadrada entre a amostra X e X_i .

5.4 Erro Percentual Absoluto Médio (MAPE)

Para a avaliação da assertividade das previsões foi utilizado o cálculo do índice de Erro Percentual Absoluto Médio (MAPE). Segundo Almeida (2018) a acurácia da previsão é o fator mais importante na avaliação da mesma, e por esse motivo se faz necessário a utilização de alguma medida de acuricidade, e, entre as medidas mais conhecidas, tem-se MSE (*Mean Squared Error*), e MAPE. O MAPE é calculado de acordo com a Equação 2.

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{X_t - Y_t}{X_t} \right| \quad (2)$$

Onde:

X_t : valor real;

Y_t : valor resultante da previsão;

n : o tamanho da série temporal.

6. METODOLOGIA

A metodologia empregada consiste em passos bem definidos para se obter os resultados desejados. Inicialmente foi realizada uma análise do conjunto dos dados a serem utilizados nesse trabalho, podendo, assim, identificar eventuais inconsistências e padrões que podem influenciar negativamente no resultado final do trabalho, ou seja, os *outliers*. Como segunda etapa foi realizada a validação dos dados. Nessa etapa foram feitas algumas ressalvas quanto a análise para se obter um melhor resultado como, por exemplo, para o conjunto de dados analisados os dados referentes aos finais de semana e feriados nacionais e municipais não foi considerado já que o consumo de energia elétrica registrado aos finais de semana e feriados é muito inferior ao consumo registrado nos dias úteis da semana, ocasionando uma variação muito grande entre os valores, o que afeta sobremaneira o comportamento dos dados regulares.

Em uma terceira etapa foi feita a identificação e tratamento dos *outliers* que estão no conjunto de dados a ser utilizado. Decidiu-se pela retirada do conjunto de dados os valores referentes aos finais de semana e feriados, que, para este trabalho não teriam relevância pois, nessas datas, o consumo é mínimo e uma vez que os valores alvo de previsão são dias úteis, cujo consumo é significativo. Foram realizadas observações sobre o conjunto de dados em busca de *outliers* e foram identificados, ao todo, 19 valores discrepantes em um conjunto de 18144 dados, sendo considerados 6048 dados por transformador no período considerado, ou seja, os *outliers* representam, aproximadamente, 0,11% da quantidade de valores que foram utilizados.

O tratamento dos *outliers* foi feito de forma manual, tanto para os valores referentes aos dias úteis como para os dias não úteis, e foi calculada a interpolação entre os valores válidos imediatamente anterior e posterior e o resultado passou a ser o valor a ser substituído na posição referente ao antigo valor de *outlier*. Após todo o tratamento nos dados determinou-se que, para efeito de melhor atender as estimativas necessárias dentro da *microgrid* em questão, as previsões deveriam considerar horizontes de previsão de 1, 3 e 5 dias, a partir do entendimento que uma semana é formada por apenas 5 dias úteis. Para cada dia são realizadas 96 coletas por transformador, o que ocasiona que, para as previsões de 1, 3 e 5 dias sejam obtidos 96, 288 e 480 dados previstos.

Para este trabalho foram combinados os valores resultantes das previsões da RNA GRNN e do método estatístico SARIMA, para isso utilizou-se os valores resultantes de cada uma das técnicas de forma que mantivessem características de ambos os previsores. Para o treinamento da RNA foi separada uma amostra de tamanho correspondente a 75% do total dos valores e, posteriormente utilizou-se os 25% do total valores restantes para os testes com a RNA. Após a obtenção dos resultados, foi adotada a média aritmética simples entre RNA e SARIMA, onde foi calculada a média das previsões Y_j e Y_k com um peso w para cada uma delas, onde $w = 0,5$, e foram atribuídas a Y_i de acordo com Equação 3.

$$Y_i = w \cdot Y_j + w \cdot Y_k \quad (3)$$

Onde:

Y_i : média da combinação dos resultados dos previsores na posição i ;

Y_j : resultado da previsão gerada pela GRNN na posição j ;

Y_k : resultado da previsão gerada pelo SARIMA na posição j ;

w : peso.

A Figura 1 apresenta o fluxograma do algoritmo que combina as saídas de previsão.




Fig. 1 Algoritmo de combinação dos resultados dos previsores

A escolha do valor 0,5 para w foi baseada em resultados de previsão nos conjuntos de validação, onde, na maioria das vezes, as previsões do modelo SARIMA, ultrapassavam os valores reais, e as previsões da rede GRNN ficavam abaixo dos valores reais. O comportamento de cada predictor é dependente das características das séries de dados utilizadas, sendo apresentada uma abordagem genérica.

7. RESULTADOS OBTIDOS

Tabela 1. MAPE do Transformador RES

Horizonte preditivo (dias)	Método		
	GRNN	SARIMA	GRNN+SARIMA
1	17,4780	20,6120	13,3088
3	15,0045	18,9908	12,6826
5	15,7531	21,0947	12,9840

Na Tabela 1 são apresentados os resultados do cálculo do MAPE obtidos por cada técnica aplicada para o transformador RES. Com base nos resultados da Tabela 1 pode-se perceber que, para a previsão de carga correspondente a 1 dia, o combinado GRNN+SARIMA gerou um MAPE com melhor desempenho, ou seja, com valor menor que os valores resultantes da GRNN e do SARIMA, além disso, os valores gerados pelo combinado GRNN+SARIMA tiveram uma acurácia melhor do que os valores gerados pelas duas técnicas em separado como pode ser visto na Figura 1. O mesmo fato pode ser observado quando o horizonte preditivo corresponde a 3 e 5 dias, onde o combinado GRNN+SARIMA obteve melhor desempenho com o MAPE de, aproximadamente, 12,68 e 12,98 respectivamente. Se compararmos os melhores desempenhos, o valor do MAPE do combinado chegou a ser melhor em até 23,86% em relação a GRNN, na previsão para 1 dia, e chegou a ser melhor em até 38,47% em relação ao SARIMA, na previsão para 5 dias.

A Tabela 2 apresenta os resultados do cálculo do MAPE obtidos por cada técnica aplicada para o transformador T03.

Tabela 2. MAPE do Transformador T03

Horizonte preditivo (dias)	Método		
	GRNN	SARIMA	GRNN+SARIMA
1	13,3193	12,6075	10,0628
3	11,3978	19,7636	15,0727
5	9,31	16,2439	10,9593

Baseando-se nos resultados da Tabela 2, pode-se perceber que nesse bloco a RNA GRNN obteve um valor menor resultante do cálculo do MAPE nas previsões correspondentes ao horizonte preditivo de 3 e 5 dias, com os valores de 11,39 e 9,31, ou seja o seu desempenho foi melhor que o SARIMA e o combinado GRNN+SARIMA.

Nesse bloco os valores de validação apresentam valores máximos e mínimos mais aproximados e tem como característica o pico de valores de carga se apresentar no começo da curva de carga. Apenas para a previsão referente ao horizonte de 1 dia o combinado GRNN+SARIMA mostrou um melhor desempenho que as outras duas técnicas. A GRNN chegou a ter um desempenho 32,14% melhor que o combinado para a previsão de 3 dias e aproximadamente 42% melhor que o SARIMA para as previsões de 3 e 5 dias.

Os valores obtidos pela previsão da GRNN apresentaram uma acurácia melhor entre as técnicas utilizadas para previsão de 3 e 5 dias. Ainda analisando os valores de MAPE do bloco T03, é possível notar uma menor discrepância entre os resultados dos diferentes previsores quando comparados aos resultados obtidos no bloco RES.

Tabela 3. MAPE do transformador T09

Horizonte preditivo (dias)	Método		
	GRNN	SARIMA	GRNN+SARIMA
1	12,1013	16,1985	11,3270
3	13,7209	13,8591	10,1353
5	14,3918	15,5876	10,1354

A Tabela 3 apresenta os valores obtidos pelo cálculo do MAPE para o transformador T09. Observando-se os resultados obtidos apresentados na Tabela 3 combinado GRNN+SARIMA apresentou melhor desempenho em todos os horizontes preditivos considerados para o transformador T09, sendo a melhor acurácia encontrada nos valores correspondentes ao horizonte preditivo de 1 dia. Em comparação com a GRNN o combinado conseguiu um valor de aproximadamente 30% na previsão para 1 dia, e com relação ao SARIMA houve um resultado de até 35% melhor na previsão de 5 dias.

Pode-se observar pelos resultados apresentados que a aplicação da GRNN consegue, no geral, um resultado do cálculo do MAPE menor em dois dos três transformadores, mas isso ocorre devido as características de consumo de cada bloco separadamente, pois a população que utiliza os blocos é

uma população considerada flutuante, formada por estudantes que utilizam as salas e laboratórios instalados nos blocos, s funcionários dessas instituições, funcionários do próprio PTI, funcionários de empresas incubadas que estão instaladas no PTI e funcionários da ITAIPU Binacional, além destes, esporadicamente ocorrem eventos técnico-científicos que abrangem diferentes quantidades de públicos que também impactam nas cargas observadas. Com isso, dependendo da época do ano, há um maior ou menor consumo de energia, contribuindo com a variação e aleatoriedade das cargas, uma vez da baixa efetividade ou impossibilidade de modelar o componente “vontade humana”.

Observa-se que os resultados obtidos da aplicação do GRNN foram melhores que os obtidos pelo combinado GRNN+SARIMA e do próprio SARIMA no conjunto de dados referentes ao transformador T03. Isso ocorreu em um conjunto de dados onde o pico dos valores de carga coletados ocorre no começo do conjunto de dados e, após o pico, os valores não chegam a ser tão elevados quanto os do começo do conjunto mas mantém um certo padrão de máximos e mínimos em todo o resto do conjunto de dados.

Quando combinados a RNA e o método estatístico os resultados obtidos mostraram um desempenho melhor do algoritmo pois conseguiram melhorar o MAPE na maioria as previsões.

A Fig. 2 e a Fig. 3 demonstram a performance das previsões considerando o horizonte preditivo de 1 dia para os transformadores RES, T03 respectivamente.




Fig. 2 – Previsões referentes a 1 dia para o transformador RES




Fig. 3 – Previsões referentes a 1 dia para o transformador T03

A Fig. 4 e a Fig. 5 demonstram as curvas de carga geradas pelas previsões considerando o horizonte preditivo de 3 dias para os transformadores T03 e T09 respectivamente.




Fig. 4 - Previsões referentes a 3 dias para o transformador T09




Fig. 5 - Previsões referentes a 3 dias para o transformador T09

A Fig. 6 e a Fig. 7 demonstram as curvas de carga geradas entre os métodos aplicados e os dados reais.




Fig. 6 - Previsões referentes a 5 dias para o transformador RES




Fig. 7 - Previsões referentes a 5 dias para o transformador T09

Estas figuras apresentam a performance das previsões considerando o horizonte preditivo de 5 dias para os transformadores RES, T03 e T09 respectivamente. Quando comparados os valores da RNA GRNN e do método estatístico SARIMA pode-se perceber a tendência da GRNN em prever valores um pouco a baixo dos reais, enquanto em vários outros

momentos a técnica estatística (SARIMA) não parecia se limitar a valores inferiores aos reais, principalmente nos momentos iniciais e finais de cada curva de carga. As RNA's possuem dificuldade em ultrapassar máximos históricos enquanto a técnica estatística não apresenta essa característica, explicando, parcialmente, os bons resultados obtidos a partir da combinação das duas técnicas.

8. RESULTADOS DE TRABALHOS RELACIONADOS

Como fator de comparação e utilizando os resultados de MAPE como parâmetro, tendo o horizonte preditivo definido em 1 dia, os resultados obtidos neste trabalho podem ser comparados com aqueles apresentados em outras publicações que utilizam dados obtidos no mesmo cenário de *smart grid*. Em Müller e Franco (2014) foram utilizados algoritmos de clusterização de dados para encontrar curvas de cargas históricas similares, que foram utilizadas para realizar previsões considerando o Método de Dias Similares (MDS). A abordagem considera outras características além das cargas elétricas, entre elas, o dia da semana e a estação do ano, que influenciam no agrupamento dos dados históricos. A abordagem MDS é puramente estatística, e no caso abordado, compreende pré-processamento dos dados. Os resultados obtidos tiveram grande variação, com valores de MAPE compreendidos entre 9,28% e 26,11%.

No trabalho de Alves *et al.* (2016) foram empregadas redes neurais artificiais que implementam a teoria da ressonância adaptativa. Para as tarefas de previsão foram utilizadas uma rede ARTMAP *Fuzzy* tradicional e uma ARTMAP *Fuzzy* modificada, cujos maior e menor valor de MAPE foram de 15,51% e 13,68%, respectivamente.

Em Carvalho (2017) uma GRNN foi empregada em previsões de cargas considerando dados de finais de semana incluídos na série histórica, onde obtiveram valor de MAPE de 12,33% quando utilizados os dados sem nenhum tratamento, e, MAPE de 5,52% quando os dados históricos foram submetidos a um filtro de médias móveis. Os resultados obtidos neste trabalho combinando os dois previsores e tratando os *outliers*, sem utilizar nenhum filtro, obteve valores máximo e mínimo de MAPE bastante próximos dos outros trabalhos citados, ficando entre 13,3088% e 10,1353%, o que demonstra que a combinação entre a RNA e o método de previsão estatístico foi capaz de gerar resultados mais eficientes e precisos do que apenas a aplicação dos métodos separadamente, estando dentro da margem de acurácia de outros trabalhos similares, e, em alguns momentos, apresentando resultados superiores.

9. CONCLUSÕES

Este trabalho teve por objetivo realizar previsões de demanda de energia elétrica em níveis menos agregados. Para isso utilizou-se de uma base de dados formada por valores de coleta de três transformadores instalados em uma *microgrid* dentro do PTI. O público que utiliza essa *microgrid* é flutuante, formado pelos habitantes do PTI das instituições de ensino que possuem convênio com o PTI e da ITAIPU Binacional que circulam e utilizam diariamente esses ambientes para atividades administrativas e letivas que podem aumentar ou diminuir o consumo de energia de acordo com os dias da semana ou atividades realizadas. Existem alguns métodos

utilizados para previsão de demanda de energia que são consagrados pela literatura, mas, com o objetivo de se obter uma melhora nas previsões realizadas optou-se por combinar o método estatístico SARIMA e a RNA GRNN, aproveitando-se assim as vantagens de cada método. A metodologia consistiu na aplicação dos previsores combinados para a obtenção dos resultados e da aplicação de cada um deles separadamente como forma de avaliar e validar o desempenho nas previsões realizadas. As combinações dos resultados de previsão foram realizadas de maneira que os pesos atribuídos aos previsores fossem iguais para esse trabalho. A combinação do SARIMA com a GRNN se mostrou mais eficiente na maioria dos cenários de previsão, em apenas dois casos ela foi superada pelas previsões obtidas pela RNA, essa variação na precisão das previsões é diferente de acordo com o bloco a ser considerado e o objetivo funcional de cada bloco analisado. Se considerarmos o bloco do restaurante é natural que o consumo de energia seja maior em comparação com um bloco onde apenas sejam ministradas aulas, pois o pico de consumo nesse bloco ocorrerá somente nos horários onde a maioria das salas de aula estejam sendo utilizadas.

Mesmo assim, considerando-se essas características, a combinação SARIMA e GRNN se mostrou uma boa opção quando se precisa prever a demanda de energia, pois as características positivas dos dois métodos combinados suavizam as desvantagens da aplicação de cada técnica separadamente.

10. TRABALHOS FUTUROS

Como continuação desta pesquisa, serão realizados estudos e novas simulações com diferentes conjuntos de dados de consumo de energia elétrica, com distintos horizontes preditivos e níveis de agregação, alinhados a realidade das *smart grids*, onde a combinação das previsões utilizando média aritmética ponderada deve ser utilizada.

11. AGRADECIMENTOS

Agradeço ao programa de Pós-Graduação em Engenharia Elétrica e Computação (PGEEC) da Universidade Estadual do Oeste do Paraná (UNIOESTE) pelo apoio dado e ao PTI pela disponibilização dos dados dos *smart-meters* que são utilizados neste trabalho. Agradeço também em especial aos orientadores Carlos Roberto Mendonça da Rocha e Marcos Ricardo Müller pelo auxílio, dedicação e confiança em mim depositados.

REFERÊNCIAS

- Almeida, F. B., Cesar, H. B. (2018). *Aplicação de métodos de previsão de demanda em uma indústria do setor alimentício*. Trabalho de Conclusão de Curso, Faculdade De Administração, Ciências Contábeis, Engenharia De Produção E Serviço Social, Ituiutaba, Brasil.
- Alves, M. F.; Müller, M. R., lotufo; A. D. P.; Lopes, M. L. M. (2016). *Aplicação de redes neurais artificiais baseadas na teoria da ressonância adaptativa na previsão de curtíssimo prazo em níveis menos agregados*, CBA – Congresso Brasileiro de Automática, Vitória, Brasil, pp. 924-929.

- Bento, G. M., Santos, R.T. (2018) *Avaliação de métodos de remoção de outliers e seus impactos na precisão dos métodos de interpolação*. 1º Simpósio Mato-Grossense de Mecanização Agrícola e Agricultura de Precisão, Universidade Federal de Mato Grosso - UFMT, Sinop, Brasil.
- Campagnollo, J. L. (2017). *Proposta de implementação de modelos matemáticos de previsão de demanda para o planejamento de produção da empresa keko acessórios*. Trabalho de Conclusão de Curso, Universidade de Caxias do Sul, Caxias do Sul, Brasil.
- Carvalho, M. P. da R. (2017). *Previsão de demanda de um prédio universitário por redes neurais artificiais*, Dissertação de mestrado, Universidade Estadual Paulista - UNESP, Ilha Solteira, Brasil.
- Chen, C. , Liu, L. (1993). Joint Estimation Of Model Parameters And Outlier Effects In Time Series. *Journal of The American Statistical Association*, n° 88: 284-297.
- Correa, G. L. (2021). *Previsão de demanda: Uma análise em uma fábrica de trufas artesanais da Grande Florianópolis*. Trabalho de Conclusão de Curso, Universidade Federal de Santa Catarina, Florianópolis, Brasil.
- Deina, C. (2020). *Modelo para previsão de demanda de eletricidade com redes neurais artificiais integradas a métodos multicritério*, Dissertação de mestrado, Universidade Tecnológica Federal do Paraná, Pato Branco, Brasil
- EMPRESA DE PESQUISA ENERGÉTICA - EPE. Balanço Energético Nacional, (2020). Acesso em: Fevereiro/2021. Disponível em: <https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-377/topico-494/BEN%202019%20Completo%20WEB.pdf>.
- Feng, Z., chu., F., Song, X. (2004). Application of general regression neural networks to vibration trend prediction of rotating machinery. Acesso em: Janeiro/2021. Disponível em: https://www.researchgate.net/profile/Fulei-Chu-3/publication/220871748_Application_of_General_Regression_Neural_Network_to_Vibration_Trend_Prediction_of_Rotating_Machinery/links/54c5f2f10cf219bbe4f61cc2/Application-of-General-Regression-Neural-Network-to-Vibration-Trend-Prediction-of-Rotating-Machinery.pdf
- Fortes, Marcio, et. al. (2017). Análise da adoção de medidores inteligentes como instrumento da política pública de eficiência energética. *Engevista*, n°. 19. 316-327.
- Haykin, S. (2001). *Redes neurais: princípios e prática*. 2. ed. Bookman: Porto Alegre.
- Jetcheva, J., Majidpour, M., Chen, W. (2014). Neural network model ensembles for building-level electricity. *Energy and Buildings*, n°. 84. 214–223.
- Júnior, R dos S P. (2018) *Proposta de melhorias na previsão de demanda: estudo de caso empresa de ramo de motos*, Dissertação de Mestrado, Universidade Candido Mendes, Campos dos Goytacazes, Brasil.
- Kheirkhah, A.; Azadeh, A.; Saberi, M.; Azaron, A.; Shakouri, H. (2013). Improved estimation of electricity demand function by using of artificial neural network, principal component analysis and data envelopment analysis, *Computers & Industrial Engineering*, vol. 64, no. 1: 425- 441.
- Leng, L et. al. Short-term forecasting model of traffic flow based on GRNN. (2013). CONTROL AND DECISION CONFERENCE – CCDC, Piscataway. pp. 3816-3820
- Martiniano, A. et al. (2016). Utilizando uma rede neural artificial para aproximação da função de evolução do sistema de Lorentz. *Revista Produção e Desenvolvimento*, vol. 2, n°1: 26 - 38.
- Mcculloch, W. S.; Pitts, W. (1943). A logical calculus of the ideas immanentin nervous activity. *Bulletin of Mathematical Biophysics*, vol. 5: 115-133.
- Müller, M. R.; Franco, E. M. C. (2014) *Clusterização de curvas de demanda para o método de dias similares*. V Simpósio Brasileiro de Sistemas Elétricos - SBSE , Foz do Iguaçu, Brasil. pp. 1-6
- Oliveira, A. de. (2015). *Uso de Séries Temporais para Previsão das Precipitações pluviiais mensais da fazenda esmeril - Patrocinio MG*. Trabalho de Conclusão de Curso, Universidade Federal de Uberlândia, Patrocinio, Brasil.
- Oliveira, E., Castro, C., Coelho, F., Saldanha, R., Nóbrega, S., Tavares, L., Rocha, H. (2015). Uso de redes neurais RBF e GRNN para comparação de previsões de carga de longo prazo de energia elétrica. Acesso em: Janeiro/2021 Disponível em: http://abricom.org.br/wp-content/uploads/2016/01/cbic2015_submission_149.pdf
- Pinto, J. M.; LOBO, V. G.; GREER, V. R. A. (2016). Operadores do comércio: um estudo da aplicação de modelos univalorados à previsão de admissões. *Revista UNIABEU*, vol. 9, n°. 21: 72-87.
- Silva, F. R. da. (2020) *Previsão de demanda e planejamento comercial*, Senac, São Paulo.
- Silva, I. A. F. (2014). Aplicações de redes neurais e neuro fuzzy em engenharia biomédica e agronomia, Tese de doutorado, Universidade Estadual Paulista - UNESP, Ilha Solteira, Brasil.
- Specht, D. F. (1991) A general regression neural network. *IEEE transactions on neural networks*. *Citeseer*, vol. 2, n°. 6, pp. 568–576.
- Tubino, D. F. (2007) *Planejamento e controle da produção: teoria e prática*. 2.ed., Atlas S. A, São Paulo.
- Walter, O. M. F. C.; Henning, E., Moro, G., Samohyl, R. W. (2013). Aplicação de um modelo SARIMA na previsão de vendas de motocicletas. *Exacta*, vol. 11, n°. 1: 77-88.