

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

Data de submissão: 09/03/2023

Data de aceite: 03/04/2023

Nelson Nunes André Junior

Universidade Estadual do Oeste do Paraná/ Centro de Engenharia e Ciências Exatas/ Foz do Iguaçu, PR
<http://lattes.cnpq.br/5124958843874927>

Carlos Roberto Mendonça da Rocha

Universidade Estadual do Oeste do Paraná/ Centro de Engenharia e Ciências Exatas/ Foz do Iguaçu, PR
<http://lattes.cnpq.br/4658529903411274>

Marcos Ricardo Müller

Faculdade UNIGUAÇU / Centro de Ciências Exatas/ São Miguel do Iguaçu, PR
<http://lattes.cnpq.br/6275900986006185>

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. Neste trabalho é apresentado um modelo baseado na combinação entre um método estatístico,

o SARIMA, e uma rede neural artificial (RNA) GRNN (Rede Neural de Regressão Generalizada), com objetivo de melhorar a acurácia das previsões de demanda de energia elétrica em um conjunto de dados. As técnicas utilizadas para previsão consideraram 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 foram os próprios métodos previsores separadamente, além da RNA LSTM, muito utilizada para previsão de séries temporais. Os resultados obtidos com o modelo combinado proposto GRNN+SARIMA são, em geral, mais precisos quando comparados com os resultados das técnicas individualmente, pois combinam as vantagens da GRNN e do SARIMA, suavizando as características negativas uma da outra, ocasionado assim, um equilíbrio que se reflete na previsão gerada. Os resultados são semelhantes aos resultados da LSTM em algumas simulações comprovando sua eficácia e tornando-se uma ótima opção com um custo computacional menor do que a LSTM.

PALAVRAS-CHAVE: SARIMA, Redes Neurais Artificiais, Previsão de demanda, GRNN, LSTM.

ELECTRICITY DEMAND FORECAST IN MICROGRID CONSIDERING LESS AGGREGATE LEVELS THROUGH THE APPLICATION OF ARTIFICIAL NEURAL NETWORK GRNN COMBINED WITH THE SARIMA STATISTICAL METHOD

ABSTRACT: The growth of electricity consumption in the world requires countries to have a well-structured plan 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 presents a model based on the combination of a statistical method, SARIMA, and an artificial neural network (ANN) GRNN (Generalized Regression Neural Network), with the aim of improving the accuracy of forecasts of electricity demand in a set of data. The techniques used for forecasting considered a forecasting horizon of 1, 3 and 5 days, the first technique being the combination of GRNN and SARIMA, and the other techniques were the forecasting methods themselves separately, in addition to the ANN LSTM, which is widely used. for time series forecasting. The results obtained with the proposed combined model GRNN+SARIMA are, in general, more accurate when compared with the results of the techniques individually, as they combine the advantages of GRNN and SARIMA, smoothing out the negative characteristics of each other, thus causing a balance which is reflected in the generated forecast. The results are similar to the LSTM results in some simulations, proving its effectiveness and making it a great option with a lower computational cost than the LSTM.

KEYWORDS: SARIMA; Artificial Neural Networks; Demand forecast, GRNN, LSTM.

1 | INTRODUÇÃO

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. Por suas proporções continentais, o Brasil exige um planejamento bem estruturado quanto à produção, transmissão e distribuição de energia elétrica.

Neste trabalho são apresentados os resultados obtidos com a realização da implementação e aplicação da combinação do método estatístico SARIMA (AutoRegressivos Integrados de Médias Móveis com Sazonalidade) e da RNA GRNN (Rede Neural de Regressão Generalizada), para realização de previsões de demanda de energia elétrica em um conjunto de dados que possuem diferentes níveis de agregação, e o comparativo entre os resultados gerados pelas duas técnicas, separadamente, os resultados da RNA LSTM (Rede de Memória de Curto e Longo Prazo), e de uma combinação entre a LSTM e o SARIMA.

O objetivo principal é demonstrar que, quando as técnicas GRNN e SARIMA são combinadas, os resultados gerados tornam-se mais precisos, devido às características da RNA GRNN acabarem auxiliando nas deficiências do método estatístico SARIMA e vice-versa quando aplicado a um conjunto de dados com diferente níveis de agregação, gerando resultados aproximados aos resultados gerados pela RNA LSTM muito utilizada

para previsão de séries temporais, mas obtendo um custo computacional menos que a LSTM.

2 | MATERIAIS E MÉTODOS

Para este trabalho foram utilizados dados reais de consumo de energia elétrica originários de uma 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). Ao todo foram utilizados três *smart-meters* instalados juntos a diferentes transformadores denominados “RES”, onde fica um restaurante, “T03” e “T09”, que atendem blocos formados por salas de aula, banheiros e salas administrativas.

O banco de dados utilizado possui informações de data e hora e valores da energia ativa consumida, além da temperatura. As medições ocorrem por prédio, considerando suas particularidades (sala de aula, escritório, lanchonete, entre outros) com diferentes perfis de consumo compondo suas cargas, ainda assim, com baixa agregação. 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. Antes de serem aplicadas as técnicas de previsão de demanda, foi realizada a validação dos dados a serem utilizados. 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 foram considerados pelo motivo 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. Cada método de previsão possui características únicas em relação ao processamento dos dados. Na análise do conjunto dos dados foram identificadas eventuais inconsistências e padrões que poderiam influenciar negativamente no resultado final do trabalho, ou seja, os chamados *outliers*. Para Bento e Santos (2018), um outlier pode ser definido como uma amostra que desvia de um conjunto de dados. Foram identificados, ao todo, 19 valores discrepantes em um conjunto composto por 18.144 dados, sendo considerados 6.048 dados por transformador no período considerado, ou seja, os *outliers* representam, aproximadamente, 0,105% da quantidade de valores que foram utilizados.

O tratamento dos *outliers* foi feito de forma manual calculando-se a média aritmética 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 foram determinados 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 medições 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 se utilizou os valores resultantes de cada uma das técnicas, de forma que mantivessem características de ambos os previsores. Para o treinamento da RNA GRNN foi separada uma amostra de tamanho correspondente a 75% do total dos valores e os outros 25% dos valores para os testes com a RNA GRNN. Após a obtenção dos resultados, foi adotada a média aritmética simples entre RNA e SARIMA.

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




Figura 1 –Algoritmo de combinação dos resultados dos previsores.

Fonte: Autoria própria.

Para este trabalho os dados reais de consumo de energia elétrica foram submetidos à biblioteca *forecast* do software R para computação estatística que fornece a implementação dos modelos automáticos (*auto.arima*) de previsão *step-wise* com modelos ARIMA (Hyndman, 2022). Para a implementação da RNA GRNN foi utilizado o software Matlab. O Matlab possui várias funções e toolboxes para implementação de RNAs, uma delas é a *Neural Network Toolbox*, que possui a função “*newgrnn*” que cria uma rede neural do tipo GRNN automaticamente de acordo com os parâmetros repassados a ela e dos arquivos que contém os dados reais de consumo de energia elétrica (Mathworks, 1994).

A função *newgrnn* define os pesos da primeira camada como P' , e os bias da primeira camada são todos definidos como $0,8326/\text{distância de dispersão do vetor de entrada}$, a segunda camada tem o número de neurônios igual ao número de vetores de entrada (Mathworks, 1994). Os parâmetros da função são editáveis, mas para este trabalho utilizou-se os valores padrão oferecidos pela *toolbox*. Para a implementação da RNA LSTM utilizou-se a linguagem PYTHON com a biblioteca PyTorch que é uma biblioteca de aprendizado de máquina de código aberto usada para implementações de aprendizado profundo, como visão computacional e processamento de linguagem natural (Pytorch, 2022). Para este trabalho a implementação da LSTM considerou o número de passos anteriores a serem lembrados como 5, por ser considerado um valor bom de comparações anteriores, o número de vetores da camada intermediária e o número de vetores na camada oculta como 4 e camadas recorrentes como 2, que são valores padrão da função.

Segundo Cecatto e Belfiore (2015) a acurácia do modelo de previsão corresponde à porcentagem de acertos do modelo de previsão em relação à demanda real. Para a avaliação da assertividade das previsões foi utilizado o cálculo do índice de Erro Percentual Absoluto Médio (MAPE). No trabalho de Almeida e César (2018) comenta-se que 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 acuracidade, e, entre as medidas mais conhecidas, pode-se citar o erro quadrático médio (MSE) e o MAPE. O MAPE é calculado de acordo com a Equação 2.

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

Sendo:

t : instante t ;

X_t : valor real;

Y_t : valor resultante da previsão;

n : o tamanho da série temporal.

3 I RESULTADOS E DISCUSSÕES

Horizonte preditivo	Método				
	SARIMA	GRNN	LSTM	GRNN+SARIMA	LSTM+SARIMA
1	20,6120	17,4780	12,47299	13,3088	25,57211
3	18,9908	15,0045	12,01754	12,6826	28,0812
5	21,0947	15,7531	13,23118	12,9840	26,8356

Tabela 1 – MAPE do transformador RES.

Fonte: Próprio autor.

Na Tabela 1 são apresentados os resultados do cálculo do MAPE obtidos por cada técnica aplicada para o transformador RES, que corresponde ao transformador que se encontra no bloco do restaurante. Pode-se perceber que, para a previsão de carga correspondente a 1 dia, o combinado GRNN+SARIMA gerou um MAPE com valor menor que os valores resultantes da GRNN e do SARIMA e muito próximo a RNA LSTM, que obteve o melhor desempenho, ou seja, gerou o menor valor de MAPE. A LSTM, por ter a característica de relembrar alguns passos passados e aprender, acaba tendo um melhor desempenho que os outros métodos, mas mesmo com essa característica, o combinado GRNN+SARIMA obtém um MAPE próximo ao da LSTM, demonstrando sua eficiência. O combinado LSTM+SARIMA acabou tendo o pior desempenho entre as técnicas, mas um valor mais aproximado do valor obtido pelo SARIMA separadamente.

O mesmo fato pode ser observado quando o horizonte preditivo corresponde a 3 dias, onde o combinado GRNN+SARIMA obteve melhor desempenho que o SARIMA e a GRNN em separados, com um MAPE de, aproximadamente, 12,68, mas acaba tendo um resultado inferior ao da LSTM, que obteve um MAPE de 12,01754. O combinado GRNN+SARIMA chega a ter um melhor desempenho que as outras técnicas quando o horizonte é de 5 dias obtendo um resultado 1,87% melhor que a LSTM. Analisando os melhores desempenhos do combinado percebe-se que o valor do MAPE 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.

Horizonte preditivo	Método				
	SARIMA	GRNN	LSTM	GRNN+SARIMA	LSTM+SARIMA
1	12,6075	13,3193	6,15455	10,0628	19,049
3	19,7636	11,3978	5,88735	15,0727	20,833
5	16,2439	9,31	5,35401	10,9593	15,916

Tabela 2 – MAPE do transformador T03.

Fonte: Próprio autor.

Baseando-se nos resultados da Tabela 2, pode-se perceber que nesse bloco a RNA LSTM obteve resultados de MAPE amplamente melhores do que os resultados gerados pelos outros métodos. 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, mas obteve um valor de MAPE de até 73,88% maior que o valor de MAPE da LSTM para o horizonte de 5 dias. Analisando-se os resultados do combinado GRNN+SARIMA em relação aos resultados da LSTM, observa-se que, para os horizontes de 1, 3 e 5 dias são gerados resultados de 63,5%, 156% e 104,7% respectivamente maiores que os gerados pela LSTM.

A diferença entre os valores pode ter acontecido por causa da característica do conjunto de dados relativos a este bloco. Neste bloco os valores de validação apresentam máximos e mínimos mais aproximados e tem como característica o pico 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 técnicas SARIMA e GRNN separadamente. 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 que os valores do combinado GRNN+SARIMA utilizado para previsão de 3 e 5 dias, mas, mesmo assim, sendo inferior aos resultados da LSTM. 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. Para todos os horizontes preditivos a combinação entre LSTM e SARIMA acaba tendo o pior desempenho. Essa situação pode ser ocasionada por causa das características do SARIMA que acabam influenciando fortemente na execução da LSTM, uma vez que, separadamente, a LSTM acaba apresentando um desempenho melhor entre todas as técnicas aplicadas.

Horizonte preditivo	Método				
	SARIMA	GRNN	LSTM	GRNN+SARIMA	LSTM+SARIMA
1	16,1985	12,1013	9,97755	11,3270	20,911
3	13,8591	13,7209	10,55699	10,1353	25,7732
5	15,5876	14,3918	10,04812	10,1354	22,9379

Tabela 3 – MAPE do transformador T09.

Fonte: Próprio autor.

A Tabela 3 apresenta os valores obtidos pelo cálculo do MAPE para o transformador T09. Observando-se os resultados obtidos apresentados na Tabela 3 percebe-se que a LSTM apresentou melhor desempenho na maioria dos horizontes preditivos considerados para o transformador T09, apenas no horizonte preditivo de 3 dias o combinado GRNN+SARIMA apresentou melhor desempenho, apresentando uma acurácia 4% melhor que a acurácia da LSTM. 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. Nesse bloco pode-se observar que os valores do combinado GRNN+SARIMA são muito próximos aos valores gerados pela LSTM, sendo que a mesma possui a característica de lembrar de valores de n etapas anteriores, aprendendo com os mesmos para realizar a previsão.

Pode-se observar pelos resultados apresentados que a aplicação da LSTM consegue no geral, um resultado do cálculo do MAPE menor em todos os transformadores, mas não em todos os horizontes preditivos considerados. Se considerarmos apenas as outras técnicas, o combinado GRNN+SARIMA acaba se destacando na maioria dos resultados, e, a GRNN consegue, no geral, um resultado do cálculo do MAPE menor em dois dos três transformadores. Isso ocorre devido às 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, funcionários do próprio PTI, de empresas incubadas e da ITAIPU Binacional. 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 devido à 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 para os horizontes preditivos de 3 e 5 dias. 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 mantêm 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, se aproximando muito dos resultados gerados pela LSTM, principalmente no transformador T09. Apenas quando consideramos o transformador T03 a LSTM se mostrou muito superior que as outras técnicas de previsão. Para uma melhor análise, a seguir são apresentadas curvas de cargas da performance das duas melhores previsões considerando o horizonte preditivo de 1, 3 e 5 dias respectivamente para o transformador RES.

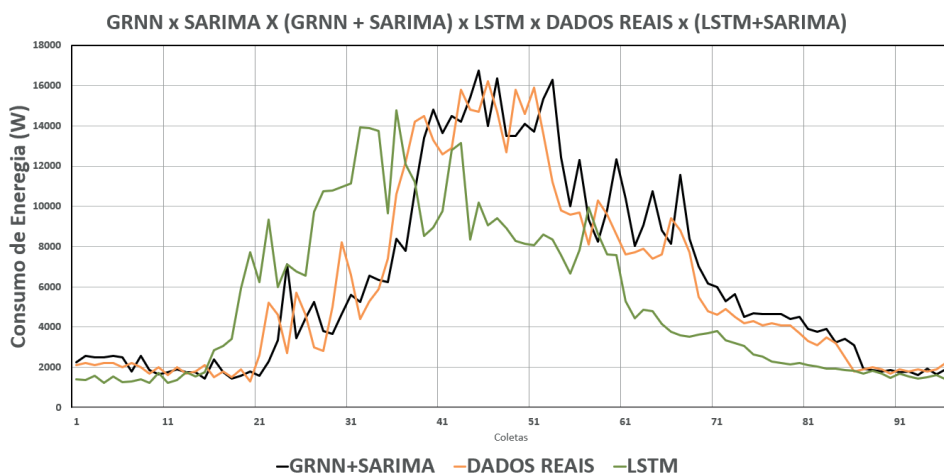


Figura 2 –Algoritmo de combinação dos resultados dos previsores.

Fonte: Autoria própria.



Figura 3 –Algoritmo de combinação dos resultados dos previsores.

Fonte: Autoria própria.

Nas Figura 2, Figura 3 e Figura 4 pode-se observar que a curva de carga do combinado GRNN+SARIMA (cor preta) apresenta uma melhor aproximação com a curva de carga referente aos dados reais (cor laranja) durante todo o horizonte preditivo e, que apesar de apresentar um MAPE melhor, a curva de carga referente a LSTM (cor verde) não acompanha os dados reais de uma forma próxima quanto o combinado GRNN+SARIMA durante toda a extensão do horizonte preditivo.



Figura 4 –Algoritmo de combinação dos resultados dos previsores.

Fonte: Autoria própria.

A seguir são apresentadas curvas de cargas da performance das duas melhores previsões considerando o horizonte preditivo de 1, 3 e 5 dias respectivamente para o transformador T03.




Figura 5 –Algoritmo de combinação dos resultados dos previsores.

Fonte: Autoria própria.




Figura 6 –Algoritmo de combinação dos resultados dos previsores.

Fonte: Autoria própria.

Na Figura 5, Figura 6 e na Figura 7 pode-se destacar uma aproximação da curva de carga referentes ao combinado GRNN+SARIMA (cor preta) com os valores reais (cor laranja) durante todo o horizonte preditivo, assim como pode-se destacar que a RNA LSTM tem a sua curva de carga com pontos onde fica muito acima dos valores reais.




Figura 7 –Algoritmo de combinação dos resultados dos previsores.

Fonte: Autoria própria.

A seguir são apresentadas curvas de cargas da performance das duas melhores previsões considerando o horizonte preditivo de 1, 3 e 5 dias respectivamente para o transformador T09.




Figura 8 –Algoritmo de combinação dos resultados dos previsores.

Fonte: Autoria própria.

Na Figura 8 pode-se destacar que a curva de carga da RNA LSTM (cor verde) obteve picos de valores durante um período considerável durante o horizonte preditivo, em alguns momentos a RNA GRNN acaba também gerando valores que são bem mais altos se comparados com os valores reais, pode-se perceber que o combinado GRNN+SARIMA acaba tendo uma curva de carga bem mais próxima aos valores reais.




Figura 9 –Algoritmo de combinação dos resultados dos previsores.

Fonte: Autoria própria.

Na Figura 9 e Figura 10 pode-se destacar as curvas de carga da RNA LSTM (cor verde) e do combinado GRNN+SARIMA (cor preta) acompanhando a curva de carga dos dados reais (cor laranja) por boa parte do horizonte preditivo, repetindo o mesmo padrão das curvas dos transformadores anteriores onde a curva de carga da LSTM acaba ficando mais afastada em vários pontos do horizonte preditivo se comparada com a proximidade da curva de carga do combinado GRNN+SARIMA em relação aos dados reais.

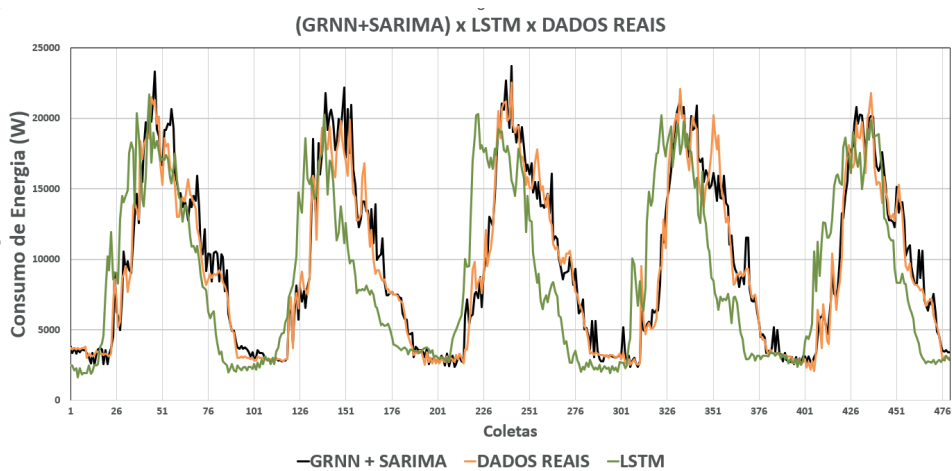


Figura 10 –Algoritmo de combinação dos resultados dos previsores.

Fonte: Autoria própria.

4 | CONCLUSÃO

A RNA LSTM mostrou-se muito eficiente na maioria das simulações realizadas devido à sua característica de lembrar de informações por longos períodos de tempo, o que possibilita mais acurácia em sua previsão, mas essa eficiência se apresenta quando comparamos os valores de MAPE gerados nas simulações, se considerarmos somente as curvas de carga obtidas nas simulações observa-se que o combinado GRNN+SARIMA se mostrou mais eficaz em mais situações. A LSTM apenas se mostrou menos eficiente quando foi combinada com o método estatístico SARIMA.

A combinação do SARIMA com a GRNN se mostrou mais eficiente na maioria dos cenários de previsão quando comparada com as técnicas SARIMA, GRNN e LSTM+SARIMA, essa variação na precisão das previsões é diferente de acordo com o bloco a ser considerado e o objetivo funcional de cada bloco analisado. Os resultados gerados pelo combinado GRNN+SARIMA foram muito semelhantes aos gerados pela LSTM separadamente, que é uma RNA apropriada para previsão de séries temporais do tipo considerado neste trabalho, e, em razão disso, obteve melhores resultados na maioria das simulações, mas a combinação SARIMA e GRNN se mostrou uma boa opção devido a um custo computacional mais baixo que a da LSTM e às características positivas dos dois métodos combinados, que suavizam as desvantagens da aplicação de cada técnica separadamente.

REFERÊNCIAS

ALMEIDA, F. B. de; CESAR, H. P. **Aplicação de métodos de previsão de demanda em uma indústria do setor alimentício**. 2018. Trabalho de Conclusão de Curso (Graduação em Engenharia de Produção) - Universidade Federal de Uberlândia, Ituiutaba, 2018.

BENTO, G. M., SANTOS, R. T. **Avaliação de Métodos de Remoção de *Outliers* e seus Impactos na Precisão dos Métodos de Interpolação**. In: 1 Simpósio Mato-Grossense de Mecanização Agrícola e Agricultura de Precisão - SIMAP, 2018, SINOP. Anais do 1 Simpósio Mato-Grossense de Mecanização Agrícola e Agricultura de Precisão - SIMAP, 2018. p. 1.

CECATTO, C., BELFIORE, P. O uso de métodos de previsão de demanda nas indústrias alimentícias brasileiras. **Gestão & Produção**, v. 22, n. 2, p. 404–418, jun. 2015.

HYNDMAN, R. (2022). **Package forecast**. Disponível em: <https://cran.r-project.org/web/packages/forecast/forecast.pdf>. Acesso em: 22 de outubro de 2022.

MATHWORKS. **Newgrnn: Design generalized regression neural network**. Disponível em: <https://www.mathworks.com/help/deeplearning/ref/newgrnn.html;jsessionid=6d1cd11e3d71df5750250c730bd8>. Acesso em: 22 de outubro de 2022.

PYTORCH CONTRIBUTORS (2022). **PyTorch Documentation**. Disponível em: <https://pytorch.org/docs/stable/index.html#indices-and-tables> . Acesso em: 23 de outubro de 2022.