

Determinação de Curva de Irradiância Solar Utilizando Redes Neurais Artificiais para Aplicação no Planejamento Eletro-Energético de Microrredes

Mariana Antonia Aguiar-Furucho

Universidade Tecnológica Federal do Paraná (UTFPR)
Grupo de Estudos em Engenharia, Neurociências e
Sistemas Bioinspirados (GENeSis)
Curitiba, Brasil
marianafurucho@utfpr.edu.br

Álvaro Afonso Soeiro Sandim

Universidade Tecnológica Federal do Paraná (UTFPR)
Curitiba, Brasil
alvaroafonso10@gmail.com

Erico Gurski

Universidade Tecnológica Federal do Paraná (UTFPR)
Programa de Pós-graduação em Sistemas de Energia
(PPGSE)
Curitiba, Brasil
erico_gurski@hotmail.com

Rodrigo Braun dos Santos

Companhia Paranaense de Energia S.A. (COPEL DIS)
Curitiba, Brasil
rodrigo.braun@copel.com

Raphael Augusto de Souza Benedito

Universidade Tecnológica Federal do Paraná (UTFPR)
Programa de Pós-graduação em Sistemas de Energia (PPGSE)
Curitiba, Brasil
raphaelbenedito@utfpr.edu.br

Resumo—No planejamento e operação de redes de distribuição de energia elétrica, integradas com fontes renováveis como a solar, a estimativa de valores de irradiância torna-se um grande diferencial estratégico. Para auxiliar na resolução deste problema, pesquisadores da área propõem inúmeras soluções como, por exemplo, aplicação de séries temporais regressivas, utilização de dados previstos por agências meteorológicas e emprego de técnicas de inteligência artificial, entre outros. Considerando a abordagem conexionista, as redes neurais artificiais (RNA) vêm sendo cada vez mais utilizadas em problemas de classificação e regressão não-linear devido à sua aplicabilidade na análise de dados e previsão, incluindo em aplicações na área de energias renováveis. A disponibilidade de dados históricos em bancos de dados meteorológicos torna a RNA ainda mais atrativa nos problemas de estimação de irradiância solar, uma vez que esta é capaz de executar um mapeamento não-linear entre conjuntos de variáveis de entrada e de saída. Assim, este trabalho objetiva desenvolver duas diferentes arquiteturas de RNA, a *Multilayer Perceptron* (MLP), com algoritmo de treinamento *Backpropagation*, e a *Generalized Regression Neural Network* (GRNN), para analisar a contribuição de cada uma para a determinação de uma curva típica de irradiância solar para o mês de janeiro de 2019 na cidade de Curitiba-PR. Foram implementadas duas arquiteturas distintas para cada tipo de RNA, variando o número de neurônios na camada oculta da MLP e o valor de espalhamento (*spread*) para a GRNN, visando avaliar o impacto dos parâmetros estruturais no desempenho de cada algoritmo. Embora ambas as arquiteturas demonstrem, assim como menciona a literatura, resultados

satisfatórios para problemas que envolvem aproximação de funções, a GRNN com espalhamento de 0,3 se destacou na solução proposta neste trabalho, seguida pela MLP com 25 neurônios na camada oculta.

Palavras-chave—irradiância solar; planejamento eletro-energético de microrredes; redes neurais artificiais; multilayer perceptron; generalized regression neural network.

I. INTRODUÇÃO

A integração de fontes renováveis às redes elétricas de distribuição de energia aumenta a complexidade no planejamento e operação das mesmas, por conta da natureza variável e estocástica de suas fontes primárias [1][2].

Este fato se intensifica principalmente no contexto de microrredes, que são sistemas elétricos de menor escala capazes de operar ilhados ou não, compostos por grupos de consumidores, geração de energia distribuída e sistemas de armazenamento de energia [3][4]. Nas microrredes, as fontes renováveis podem estar entre as maiores contribuintes na geração de energia.

Dentro deste contexto, a intermitência e a não-controlabilidade da geração solar fotovoltaica, mais especificamente, traz ainda uma série de desafios ao planejamento da operação de microrredes, tais como flutuações

de tensão, problemas na qualidade de energia e estabilidade do sistema [1].

Como a potência gerada fotovoltaica tem forte correlação com os níveis de irradiância solar incidente nos módulos fotovoltaicos [5], percebe-se que a obtenção de valores estimados (ou faixas) para o nível de irradiância torna-se uma tarefa essencial para o planejamento adequado da operação e segurança das microrredes, uma vez que, tendo-se a irradiância, a potência fotovoltaica gerada pode ser posteriormente determinada.

Na literatura da área, a previsão de geração solar, para planejamento e operação de microrredes, tem sido feita utilizando-se de abordagens distintas, dentre elas pode-se citar [3]: utilização de comportamento estocástico para obtenção da potência gerada com base em dados históricos; aplicação de séries temporais regressivas; utilização de dados previstos por agências meteorológicas; emprego de técnicas de inteligência artificial em estratégias considerando tanto dados históricos quanto previstos; entre outras.

As redes neurais artificiais (RNA) vêm sendo cada vez mais utilizadas em problemas de classificação e regressão não-linear dentro da meteorologia, devido à sua aplicabilidade na análise de dados e previsão. A disponibilidade de dados históricos em bancos de dados meteorológicos torna a RNA ainda mais atrativa nos problemas de previsão de irradiância, uma vez que esta é capaz de executar um mapeamento não-linear entre conjuntos de variáveis de entrada e de saída [1][6]. Por este motivo, o presente estudo se dedica a desenvolver um modelo de redes neurais artificiais para estimação da irradiância solar, restringindo-se à estimação da irradiância global horizontal.

Importante destacar que este trabalho faz parte do projeto de pesquisa e desenvolvimento intitulado “Metodologia para Análise, Monitoramento e Gerenciamento da Geração Distribuída por Fontes Incentivadas” da Companhia Paranaense de Energia (COPEL).

Após a seção I apresentar a contextualização da integração da geração solar fotovoltaica aos sistemas elétricos de potência, a seção II descreve a metodologia empregada neste trabalho para o desenvolvimento de um modelo de RNA para estimação da curva característica de irradiância solar. Na Seção III são apresentados os resultados obtidos durante a modelagem desenvolvida, enquanto na Seção IV são analisados e discutidos esses resultados bem como apontadas as limitações deste estudo. As principais conclusões e considerações finais sobre o estudo são descritas na Seção V.

II. ESTUDO DE CASO: APLICAÇÃO DE RNA PARA LEVANTAMENTO DA CURVA CARACTERÍSTICA DE IRRADIÂNCIA SOLAR DA CIDADE DE CURITIBA

Para a solução proposta, utilizando técnicas de RNA, se faz necessário a obtenção de uma base de dados histórica que seja representativa do problema de se obter um adequado planejamento da operação de microrredes. Para obter a curva de irradiância solar típica do mês de janeiro de 2019 na cidade de Curitiba-PR, os dados de irradiância global horizontal foram coletados diretamente do site do Instituto Nacional de

Meteorologia (INMET)¹ que disponibiliza uma base histórica com amostragem horária, para os 365 dias anteriores contados a partir da data atual.

A escolha pelo mês de janeiro deu-se por ser este um mês típico de verão, com alto índice de irradiância e relativa estabilidade de condições meteorológicas na cidade de Curitiba-PR. A Fig. 1 apresenta as curvas de irradiância solar, em kW/m^2 , dos 31 dias de janeiro de 2019 obtidas na cidade de Curitiba-PR.

Convém destacar que os sinais apresentados na Fig. 1 possuem amostragem horária (em Tempo Universal Coordenado - UTC) e que a forma contínua deve-se à escolha pelo tipo de gráfico adotado.

Visando obter a curva representativa do conjunto de dados de irradiância, dois tipos de RNA foram analisados e tiveram seus resultados comparados: a MLP, com algoritmo de treinamento *Backpropagation*, contendo uma camada oculta, e a GRNN, proposta por Specht [7], ambas implementadas no software MATLAB®.

A escolha pela MLP deve-se a seu reconhecido uso como aproximador universal de função [1][6] [8] e por ser um dos algoritmos mais utilizados em trabalhos que utilizam abordagem conexionista [1].

A GRNN, por sua vez, apresenta arquitetura baseada em uma camada oculta tipo *Radial Basis Function* (RBF) com o acréscimo de uma segunda camada oculta com função de ativação linear. Sua utilização se deu por conta de seu desempenho em problemas que envolvem aproximação de função, por não exigirem algoritmo de treinamento iterativo e por possuir a vantagem de não apresentar mínimos locais no perfil de erro, quando comparada à MLP [9][10].

Para realizar o treinamento e o teste das redes escolhidas foi utilizada uma base de dados (Ψ) composta por uma matriz de dimensões 31×24 , representando os 31 dias de janeiro por 24 amostras horárias do valor da irradiância solar.

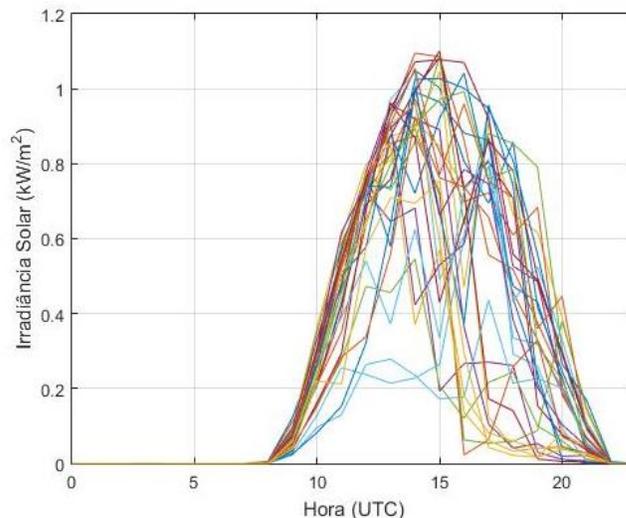


Fig. 1. Curvas de irradiância solar em janeiro 2019 na cidade de Curitiba-PR

¹ Disponível em: <<http://www.inmet.gov.br/portal/>>.

Os dados foram divididos em 80% para base de treinamento (Ψ_{tt}) dentre os quais 20% foram utilizados para a base de validação (Ψ_v), e os demais 20% não constituintes de Ψ_{tt} compuseram a base de teste (Ψ_t). As bases Ψ_v e Ψ_t foram obtidas através de um algoritmo de escolha aleatória para não enviesar os resultados das redes. O algoritmo em questão foi elaborado utilizando-se a função $randi([i_{min}, i_{max}], n_{linhas}, m_{colunas})$ que retorna um vetor de números inteiros, gerados aleatoriamente, composto de n linhas e m colunas dentro do intervalo fechado i_{min} e i_{max} . Convém explicar que trata-se de uma pseudo-aleatoriedade visto que o MATLAB® utiliza o conceito de sementes (*seeds*) que são utilizadas para a geração de valores “aleatórios” através de funções como a *randi*.

Para obtenção da curva típica de irradiância solar de janeiro de 2019, a entrada das redes (Ψ_{in}) foi organizada em um vetor composto por 24 pontos correspondentes às horas do dia, pareada com o vetor de saída composto por Ψ_t . A escolha dos vetores de entrada e saída deu-se em razão de que, para auxiliar na resolução do problema de planejamento da operação de redes elétricas de distribuição de energia que utilizam como fonte alternativa painéis fotovoltaicos (PV), torna-se interessante que o parâmetro de entrada seja o valor horário e que a RNA responda com o nível de irradiância solar estimado. De posse dessa informação, o planejamento da atuação sobre a planta elétrica pode ser devidamente realizado.

III. RESULTADOS OBTIDOS

Através das fases de treinamento e validação, buscou-se obter os parâmetros que melhor representassem o poder de generalização das redes, apresentando a melhor curva característica de irradiância.

A. Resultados MLP

A Fig. 2 apresenta o resultado do treinamento da MLP utilizando 25 neurônios na camada oculta, erro médio quadrático (MSE) de 0,0236 e parada pelo vetor gradiente com módulo menor do que 0,000001. Para o teste da rede, foram utilizados os dados de irradiância dos dias 6, 9, 16, 19, 26 e 31, selecionados através de um algoritmo de escolha aleatória, como mencionado anteriormente, apresentados na Fig. 3.

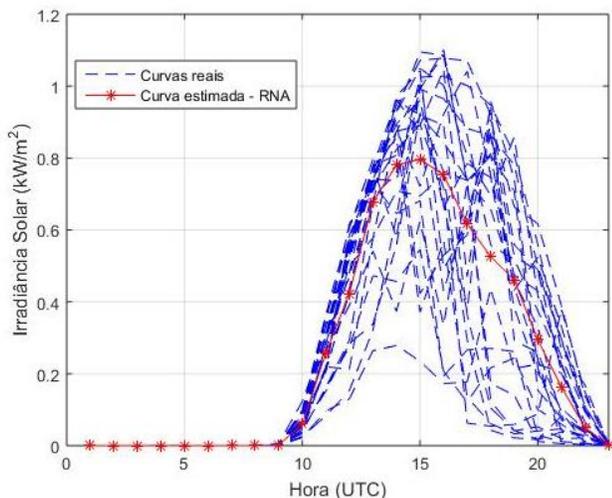


Fig. 2. Comparação entre as curvas reais de irradiância (Ψ_{tt}) e a resposta da MLP

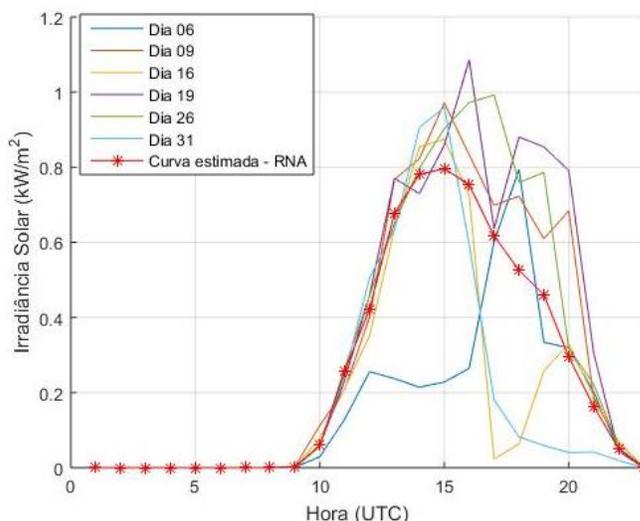


Fig. 3. Visualização da curva estimada pela rede MLP e dados da Ψ_t

Visando avaliar o impacto do número de neurônios MLP sobre o desempenho da rede, um novo estudo foi realizado mantendo a arquitetura, mas alterando para 31 o número de neurônios da camada oculta. Os resultados desta alteração podem ser observados na Fig. 4, com MSE igual a 0,0221.

B. Resultados GRNN

Como mencionado, a GRNN não apresenta a necessidade de um algoritmo de treinamento recursivo, sendo utilizada para estimar a função de densidade conjunta dos dados de entrada e dos dados de saída para qualquer problema de regressão [6].

A Fig. 5 apresenta o resultado da GRNN composta por duas camadas, erro médio quadrático (MSE) de 0,0232 e largura do campo receptivo da função de base radial (*spread*) igual a 1. Destaca-se que quanto maior o *spread* utilizado, mais suave será o resultado apresentado pela rede GRNN.

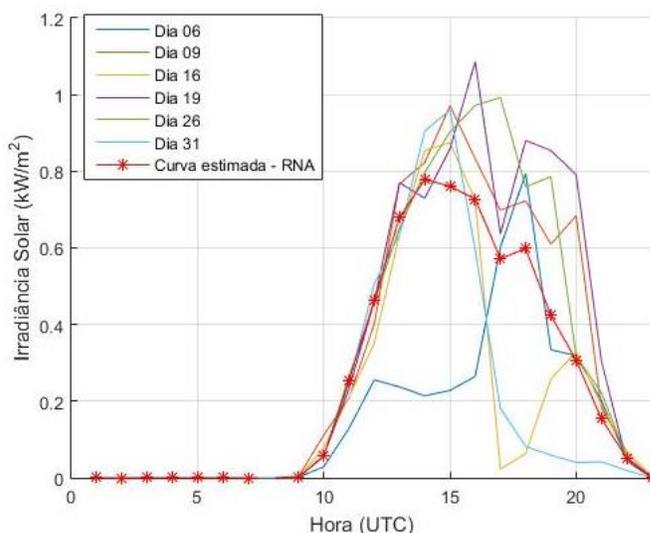


Fig. 4. Teste da MLP com 31 neurônios na camada oculta

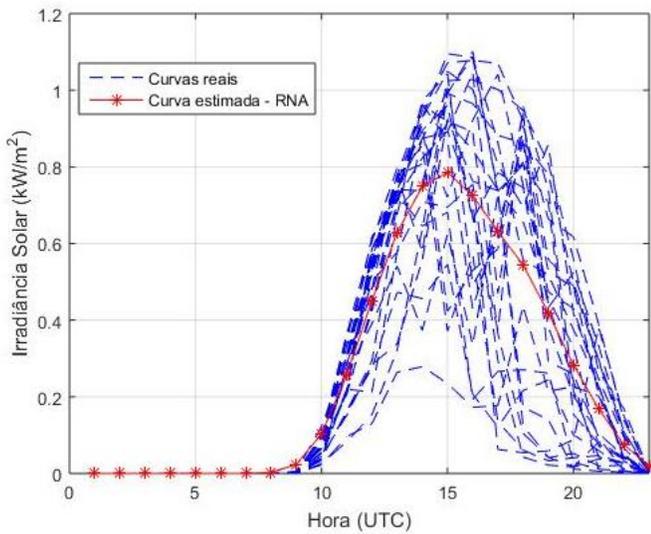


Fig. 5. Comparação entre Ψ_{tt} e a resposta estimada pela rede GRNN

Para o teste da rede GRNN foram utilizados os dados dos mesmos dias considerados para a MLP, a base Ψ_t . Os resultados podem ser observados na Fig. 6.

Para a GRNN também uma rede adicional foi desenvolvida, visando encontrar a melhor curva típica de irradiância solar de janeiro de 2019 da cidade de Curitiba-PR. Assim, a alteração de parâmetros nessa nova fase limitou-se à diminuição do *spread* da camada de base radial da GRNN, passando de 1 para 0,3. O resultado pode ser observado na Fig. 7.

A Fig. 8, para melhor entendimento, apresenta a comparação entre as curvas resultantes das quatro redes neurais analisadas.

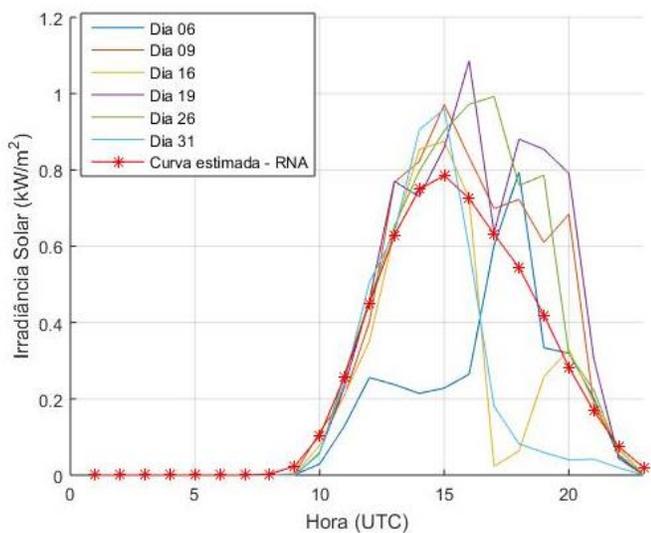


Fig. 6. Curva estimada pela rede GRNN e curvas da base de teste Ψ_t

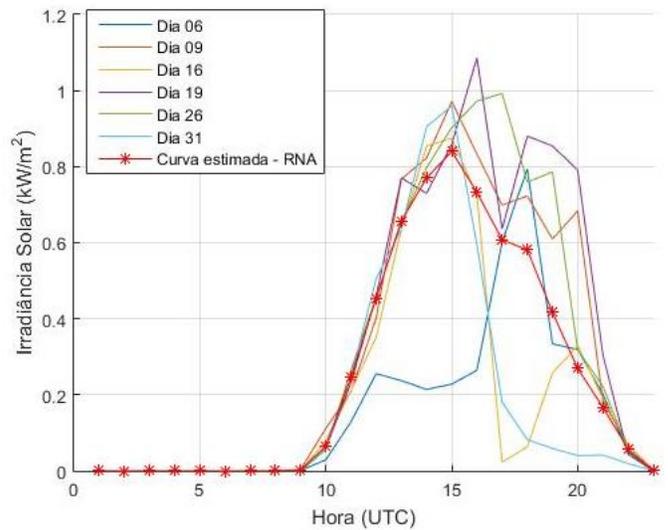


Fig. 7. Curva estimada pela rede GRNN com *spread* de 0,3 e curvas da base de teste Ψ_t

Além dos valores de MSE obtidos nos treinamentos de cada rede, uma análise estatística adicional foi realizada, utilizando ponto a ponto o valor estimado de irradiância horário \pm MSE. Os resultados desse cálculo sobre os pontos da base Ψ podem ser observados na Fig. 9. Para simplificação, as redes foram denominadas MLP25, MLP31, GRNN03 e GRNN1 para, respectivamente, MLP com 25 neurônios na camada oculta, rede MLP com 31 neurônios na camada oculta, GRNN com *spread* igual a 0,3 e GRNN com *spread* igual a 1.

Para uma análise quantitativa das redes, a Tabela 1 apresenta o valor do MSE total calculado para cada base utilizada no desenvolvimento da solução proposta. Convém destacar que a base de validação Ψ_v , assim como a base Ψ_t , foi composta por dados de irradiância solar dos dias 1, 7, 13, 21, 28 e 30, aleatoriamente escolhidos dentro dos dados de Ψ_{tt} .

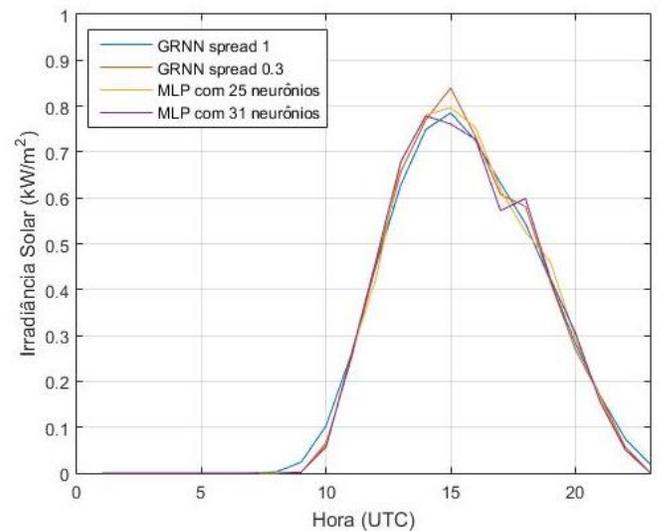


Fig. 8. Comparação entre os resultados das quatro RNA analisadas

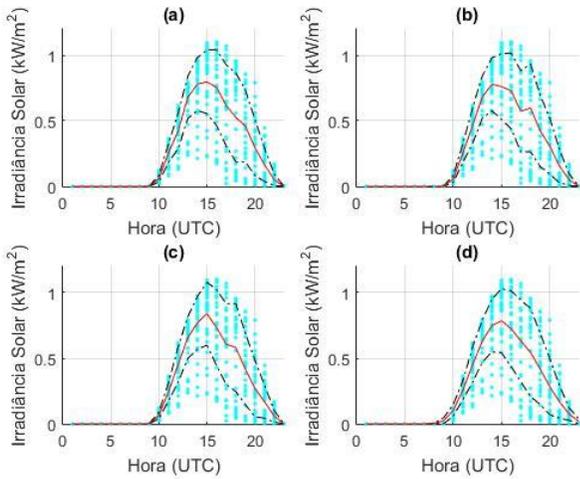


Fig. 9. Apresentação do resultado de cada rede (linha contínua em vermelho) e dos intervalos compostos pelo valor estimado de irradiância horário \pm MSE (linhas tracejadas em preto), calculados ponto a ponto para a base Ψ (linhas pontilhadas em azul claro). Resultados pertencentes às redes (a) MLP25, (b) MLP31, (c) GRNN03 e (d) GRNN1.

IV. DISCUSSÃO

Dois tipos de arquitetura de RNA e quatro algoritmos de treinamento foram desenvolvidos neste trabalho visando analisar a contribuição de cada um para a determinação de uma curva típica de irradiância solar para o mês de janeiro de 2019 na cidade de Curitiba-PR.

A análise dos resultados obtidos demonstrou que há uma dependência dos parâmetros da rede, como número de neurônios para a MLP e valor do *spread* para GRNN, mesmo quando apresentam MSE muito próximos ou idênticos. A Fig. 8 mostra que há pouca diferença entre os valores estimados pelas redes.

A Fig. 9 demonstra os intervalos (curvas em traços pretos) que contêm aproximadamente 68,3% de todos os pontos amostrais da base Ψ (em pontos azuis), calculados a partir dos valores de irradiância solar (em kW/m^2) estimados por cada rede.

Analisando os resultados da análise apresentada na Tabela 1, pode-se verificar que, para a base de dados de irradiância solar de janeiro de 2019 da cidade de Curitiba-PR, a RNA que apresenta menores MSE para as bases Ψ , Ψ_{tt} e Ψ_v foi a GRNN com *spread* igual 0,3, e para a base de teste Ψ_t foi a MLP com 25 neurônios na camada oculta. Assim, considerando-se o desempenho geral e que Ψ contém Ψ_t , pode-se considerar que a GRNN03 é a rede candidata à geração da curva típica para o problema aqui proposto.

Cabe destacar que, de forma geral, os desempenhos das redes MLP e GRNN, independentemente dos algoritmos e dos parâmetros de treinamento utilizados, foram muito próximos, o que confirma o grande uso dessas arquiteturas em problemas de aproximação de funções, como menciona a literatura da área.

TABELA I.

ANÁLISE ESTATÍSTICA DO DESEMPENHO DAS RNA

Rede	MSE TOTAL			
	Ψ	Ψ_{tt}	Ψ_v	Ψ_t
MLP25	0,7503	0,5893	0,1118	0,1610
MLP31	0,7511	0,5899	0,1151	0,1611
GRNN03	0,7424	0,5793	0,1077	0,1631
GRNN1	0,7517	0,5888	0,1188	0,1628

Entre as limitações presentes neste estudo incluem-se o tamanho da amostra de dados e os tipos de RNA. A amostra deste estudo foi restrita aos dados de irradiância solar do mês de janeiro de 2019 da cidade de Curitiba-PR coletados diretamente do site do INMET. Um trabalho usando uma base ampliada de dados contendo os meses do verão brasileiro entre os anos de 2018 e 2019 está em estudo assim como o uso de dados de irradiância solar de outros municípios do Paraná.

V. CONCLUSÃO

A estimação do valor de irradiância solar é um aspecto importante a ser explorado para o adequado planejamento operacional no setor de energia renovável. Nesse sentido, as redes neurais artificiais constituem ferramentas algorítmicas que estão sendo cada vez mais utilizadas para auxiliar na solução de problemas complexos, como o planejamento e operação de fontes renováveis de energia integradas às redes elétricas de distribuição, área de aplicação deste trabalho.

As curvas típicas de geração discretizadas em horas auxiliam no planejamento diário da operação pois são incorporadas como dados de entrada nos programas de fluxo de potência, que processam as informações e fornecem o ponto de operação da rede elétrica para aquele perfil horário de geração e de carga do sistema. Assim, quanto mais precisos forem as curvas típicas de irradiância em relação ao que seria verificado na prática, mais preciso será a estimativa do ponto de operação elétrica da rede de distribuição e da microrrede.

Este estudo demonstrou, com sucesso, a viabilidade do uso de RNA, particularmente das arquiteturas MLP e GRNN, para estimação de uma curva típica de irradiância solar de um mês típico de verão da cidade de Curitiba-PR. Mesmo possuindo apenas uma única base relativa ao mês de janeiro de 2019, os resultados obtidos tornam-se úteis para a operacionalização de análises de fluxo de potência de redes elétricas que fazem uso de fontes alternativas de energia, como a solar, integradas em sua composição.

Após validada a metodologia do uso de redes neurais artificiais para determinação da curva de irradiância solar para aplicação no planejamento eletro-energético de microrredes, a próxima fase deste projeto consistirá em utilizar como base Ψ os dados de irradiância da região de Ipiranga-PR onde concentram-se os estudos do projeto de pesquisa “Metodologia para Análise, Monitoramento e Gerenciamento da Geração Distribuída por Fontes Incentivadas” no qual este trabalho encontra-se inserido.

Outra abordagem muito útil para o setor é a utilização de RNA para predição de valores de irradiância solar e de demanda, que encontra-se em fase de estudos para uma possível continuidade deste trabalho, que contará também com dados advindos da região de Ipiranga-PR.

AGRADECIMENTOS

Agradecemos à Companhia Paranaense de Energia Elétrica (COPEL) pelo apoio e fomento no Projeto de Pesquisa ANEEL PD 2866-0464/2017 (Metodologia para Análise, Monitoramento e Gerenciamento da GD por Fontes Incentivadas) e ao Departamento Acadêmico de Eletrotécnica (DAELT) da Universidade Tecnológica Federal do Paraná (UTFPR).

REFERÊNCIAS

- [1] C. Voyant, G. Notton, S. Kalogirou, M. L. Nivet, C. Paoli, F. Motte, and A. Fouilloy, "Machine learning methods for solar radiation forecasting: A review," *Renewable Energy*, vol. 105, pp. 569-582, January 2017.
- [2] A. Chaouachi, R. M. Kamel, R. Andoulsi, and K. Nagasaka, "Multiobjective Intelligent Energy Management for a Microgrid," *IEEE Trans. Ind. Electron.*, vol. 60, pp. 1688-1699, April 2013.
- [3] A. A. Pérez, J. C. P. Salas, J. G. Rosa, and O. F. Oliveros, "Weather forecasts for microgrid energy management: Review, discussion and recommendations," *Applied Energy*, vol. 228, pp. 265-278, June 2018.
- [4] M. Farrokhhabadi, et al., "Microgrid Stability Definitions, Analysis, and Examples," *IEEE Trans. Power Syst.*, April 2019.
- [5] M. G. Giorgi, P. M. Congedo, and M. Malvoni, "Photovoltaic power forecasting using statistical methods: impact of weather data," *IET Sci. Meas. Technol.*, vol. 8, pp. 90-97, January 2014.
- [6] A. Mellit, and A. M. Pavan. "A 24-h forecast of solar irradiance using artificial neural network: Application for performance prediction of a grid-connected PV plant at Trieste, Italy." *Solar Energy* 84.5 (2010): 807-821.
- [7] D. F. Specht, "A general regression neural network," *IEEE transactions on neural networks*, vol. 2, n. 6, pp. 568-576, 1991.
- [8] Z. L. Kovács, *Redes neurais artificiais*, Livraria da Física, 2002.
- [9] H. K. Cigizoglu, "Generalized regression neural network in monthly flow forecasting," *Civil Engineering and Environmental Systems*, vol. 22, n. 2, pp. 71-81, 2005.
- [10] H. K. Cigizoglu, and M. ALP, "Generalized regression neural network in modelling river sediment yield," *Advances in Engineering Software*, vol. 37, n. 2, pp. 63-68, 2006.