

Redes Neurais Artificiais Aplicadas à Previsão de Irradiância Global Horizontal no Contexto de Cidades Inteligentes

Frederico Pedro Bon

Centro de Ciências Exatas e de Tecnologia - CCET
Universidade Federal de São Carlos - UFSCar
São Carlos, Brasil
fredericoejr@gmail.com

Wanessa Caroline Maciel Carvalho

Centro de Ciências Exatas e de Tecnologia - CCET
Universidade Federal de São Carlos - UFSCar
São Carlos, Brasil
wanessacarvalho@gmail.com

Leonel Alejandro Laboissiere

Centro de Ciências Exatas e de Tecnologia - CCET
Universidade Federal de São Carlos - UFSCar
São Carlos, Brasil
leonel.laboissiere@gmail.com

Ricardo Augusto Souza Fernandes

Centro de Ciências Exatas e de Tecnologia - CCET
Universidade Federal de São Carlos - UFSCar
São Carlos, Brasil
ricardo.asf@gmail.com

Resumo — A disponibilidade do recurso solar deve ser aproveitada em uma Cidade Inteligente. Com o intuito de viabilizar e aperfeiçoar a aplicação dessa fonte renovável, na cidade de Araras, São Paulo, Brasil, aplicou-se um modelo de previsão de irradiância global horizontal baseado em Redes Neurais Artificiais para o horizonte de curto prazo. Com o objetivo de encontrar uma combinação de variáveis meteorológicas que possibilite obter a taxa de previsão do modelo, uma base de dados de quatro anos com coletas horárias foi utilizada no treinamento e validação. Foram realizados dois testes e seus resultados comparados ao estado da arte, sendo possível observar que a própria irradiância global horizontal, a temperatura média e a velocidade do vento média são variáveis que proporcionam a menor Raiz do Erro Quadrático Médio, com 0,20 MJ/m² e 13,3% quando normalizado.

Palavras-chave — irradiância global horizontal; previsão de séries temporais; cidades inteligentes; redes neurais artificiais.

I. INTRODUÇÃO

O Brasil concentra uma população de 210 milhões de pessoas em 2019 com previsão de atingir o ápice de 233 milhões em 2047 [1]. O rápido crescimento populacional, a deficiência ou até ausência de planejamento dos centros urbanos associado à sua rápida e extensa ocupação, entre outros fatores, originaram transtornos, antes nunca vistos ao cotidiano das cidades. Assim, a criação de Cidades Inteligentes surgiu como uma estratégia natural para mitigar os problemas provenientes da rápida urbanização e do rápido crescimento urbano [2]. Em uma Cidade Inteligente, infraestruturas, serviços e tecnologias se unem para moldar uma cidade projetada para as necessidades de seus habitantes, que exigem novos serviços de energia urbana, desde o ambiente doméstico até o transporte público e privado. O conceito de Cidade

Inteligente combina proteção ambiental, eficiência energética, progresso econômico e social em um único modelo urbano [3].

Tendo como viés a eficiência energética, o panorama atual vem destacando as fontes de energia renováveis nas cidades, como forma de atender novas demandas das populações e dos acordos internacionais por energia gerada, a partir de moldes menos poluentes e renováveis. De modo que, na atualidade, a sociedade está enfrentando a transição de sistemas de distribuição de energia centralizados e hierárquicos para sistemas distribuídos e cooperativos, o que se denomina por *Smart Grids* [4].

As Cidades Inteligentes dependem das *Smart Grids* para garantir o fornecimento de energia e suprir suas diversas funções, apresentar oportunidades de conservação, melhorar a eficiência e, mais importante, possibilitar a coordenação entre os sistemas públicos, as infraestruturas e a sociedade [5]. Assim, para aplicações que envolvem geração de energia é de fundamental importância o conhecimento acerca dos métodos para produzi-la da forma menos impactante possível [6].

Uma conversão e utilização eficientes de energia fotovoltaica demandam conhecimentos sobre os níveis de irradiância global horizontal (GHI, do inglês *Global Horizontal Irradiance*) que incidem no campo de geração, além de entender seu comportamento. A intermitência dessa energia, obriga os produtores a desenvolverem e buscarem métodos e ferramentas de previsão que moldem o comportamento dessas séries estocásticas com índices de precisão cada vez mais acurados. O intuito é que em uma eventual necessidade de geração suplementar, outras fontes estejam preparadas e o sistema não seja atingido com flutuações de tensão ou interrupção do fornecimento.

Vários modelos foram desenvolvidos para prever GHI e as abordagens não lineares como Redes Neurais Artificiais (RNA)

foram consideradas por muitos pesquisadores. No entanto, o uso de uma RNA para prever um fenômeno acaba por gerar um erro, o chamado erro de predição, que precisa ser reduzido por métodos de otimização [7].

Assim, o objetivo desta pesquisa é encontrar uma combinação de variáveis meteorológicas, entre as que estão disponíveis na base de dados, que possibilite através do uso de uma RNA do tipo *Multilayer Perceptron* (MLP), estimar a GHI para hora a frente ($h+1$) com ótima acurácia. A estimativa será possibilitada por uma análise comparativa entre as métricas de erro geradas na previsão e as obtidas por autores de referência na literatura. O local escolhido para a previsão é o *campus* da Universidade Federal de São Carlos (UFSCar) localizado na cidade de Araras, São Paulo, Brasil.

Na sequência, a Seção II irá apresentar o estado da arte na previsão de GHI, com enfoque principal aos modelos baseados em RNA. A Seção III apresenta, em detalhes, os aspectos da metodologia proposta. Na Seção IV são analisados e discutidos os resultados obtidos por modelos preditivos propostos nesse trabalho. Por fim, a Seção V apresenta as conclusões advindas dessa pesquisa.

II. ANÁLISE DO ESTADO DA ARTE

Nessa seção serão considerados os artigos científicos que compõem o estado da arte em termos de previsão de GHI.

A. Abordagens Gerais Visando a Previsão de GHI

Os painéis fotovoltaicos têm sua potencial geração estimada a partir de condições de teste padrão e são definidas a partir de uma temperatura operacional do painel (normalmente considerada igual a 25 °C) e GHI incidente de 1.000 W/m². Porém, dificilmente essas condições são recorrentes na operação cotidiana desses painéis [8]. Predizer as flutuações de GHI, independente se elas representam acréscimo ou decréscimo, é fundamental em função da manutenção da estabilidade da rede elétrica [9].

Em [10], os autores dividem as abordagens preditivas em dois grandes grupos: (i) métodos baseados em formalismo matemático de séries temporais; e (ii) modelos de Previsão Numérica do Tempo (NWP, do inglês *Numerical Weather Prediction*).

Os modelos mais clássicos e convencionais para prever GHI são os modelos Auto Regressivos de Média Móvel (ARMA, do inglês *Autoregressive Moving Average*), porém, as RNAs têm se mostrado como a alternativa mais promissora às abordagens convencionais [10], de modo que um considerável montante de pesquisadores tem comprovado em diferentes campos a capacidade e potencialidade dessas técnicas [10]-[11].

B. Redes Neurais Artificiais aplicadas à Previsão de GHI

A arquitetura MLP tem sido extensamente aplicada, devido a sua capacidade de aproximação universal de realizar regressões não lineares [12].

Em 1999, os autores de [13] propuseram reduzir o erro médio dos modelos preditivos mais aplicados na época, que

giravam em torno de 30%, com o uso de RNAs. Os autores desenvolveram uma RNA que foi segmentada em três estágios. No primeiro, dados meteorológicos de pressão atmosférica, temperatura e índice de clareza coletados no dia anterior foram utilizados com o intuito de prever pressão atmosférica no dia seguinte ($d+1$). O segundo estágio utilizava como entrada a pressão atmosférica prevista associada às mesmas variáveis do primeiro estágio, com a intenção de prever níveis de GHI (classificados em baixo, médio ou alto). O último estágio refinava a previsão, convertendo os níveis em um valor. O objetivo do foi atingido e os erros sofreram um decréscimo de 10% (de 30% para 20%). O campo de estudo foi Omaezaki, no Japão, no ano de 1994, utilizando dados coletados entre 1988 e 1993.

Com o objetivo de estabelecer o estado da arte em um panorama atual, o termo de pesquisa "*solar radiation AND (predict* OR forecast*)*" foi lançado na base indexada Scopus com o objetivo de recuperar artigos dos últimos 5 anos finalizados (2014, 2015, 2016, 2017 e 2018). No total, 1.994 publicações atenderam os critérios.

A busca retornou 6.513 autores associados ao termo de pesquisa e através do software VOSViewer identificou-se quais deles acumulam o maior número de citações e de artigos publicados, a saber: Shamshirband, S. com 806 citações e 22 artigos publicados; Petković, D. com 654 citações e 12 artigos publicados; Mohammadi, K. com 626 citações e 16 artigos publicados; Wang, L. com 307 citações e 17 artigos publicados e Voyant, C. com 278 citações e 8 artigos publicados. Esses autores, além de outros de destaque, foram considerados nessa análise do estado da arte.

Em 2014, os autores de [14] utilizaram duas arquiteturas MLP com algoritmo treinamento Levenberg-Marquardt, combinando pressão atmosférica e índice de precipitação para prever GHI em Ajjacio, na França. O horizonte da previsão foi de 24 horas a frente ($h+24$) e o menor nRMSE (*normalized Root Mean Square Error*) foi de 2,4%.

Também em 2014, os autores de [15] buscaram prever GHI pós-processando resultados de uma previsão por NWP com uma RNA do tipo MLP treinada por uma função de regressão linear, em Saint Pierre, na França. O horizonte foi de ($h+2$) e se empregou o ângulo de zênite do Sol e o índice de céu claro como variáveis de entrada, obtendo assim um nRMSE de 28,76%.

Em [16], no ano de 2015, os autores compararam 3 previsões de GHI baseadas em RNA, *Support Vector Machine* (SVM) e *Genetic Programming* (GP). A previsão abordava um horizonte mensal para a Nigéria. Os dados de entrada foram duração do pôr do Sol e temperaturas máximas e mínimas diárias, onde o RMSE (*Root Mean Square Error*) obtido foi de 0,55 MJ/m².

Os autores de [17] realizaram previsões de GHI em Bandar Abass, Irã. Comparou-se modelos preditivos de RNA, SVM, GP e ARMA com o objetivo de estimar índices médios de GHI diários. Os erros atingidos foram RMSE = 1,81 MJ/m²; MAPE = 8,68 MJ/m² e nRMSE = 10,01%, utilizando como entrada a duração do pôr do Sol, amplitude térmica, humidade relativa e irradiância extraterrestre.

Previsões médias diárias de GHI são feitas em [18], em que se considerou 4 modelos (RNA, SVM, GP e *Extreme Learning Machine* – ELM) para a cidade de Shiraz, no Irã. Os modelos utilizaram como dados de entrada a GHI diária, horário do pôr do Sol, máxima, mínima e média de temperatura e umidade relativa do ar. Todos os dados foram coletados entre janeiro de 1995 e dezembro de 2004. O erro foi de $0,43 \text{ MJ/m}^2$ (RMSE).

Em [19], os autores comparam 4 modelos preditivos (RNA, SVM, ARMA e Persistência) nas ilhas francesas de Corsica, Reunion e Guadeloupe. O horizonte da previsão variou entre $(h+1)$ e $(h+6)$. Utilizaram como dados de entrada latitude, longitude, fuso horário, elevação da região, pressão atmosférica, vapor d'água, entre outras variáveis calculadas. Os erros obtidos foram de $12,65\% \leq \text{rMAE} \leq 27,62\%$.

Na proposta de [20], 3 modelos preditivos de médias diárias de GHI baseados em RNAs foram comparados (MLP, *Generalized Regression Neural Network* – GRNN e *Radial Basis Neural Network* – RBNN). Os dados de entrada foram temperatura do ar, pressão atmosférica, umidade relativa, pressão de vapor d'água e duração do pôr do Sol. Todos estes dados foram coletados em 12 estações meteorológicas em diferentes zonas climáticas um intervalo que compreende os anos de 1961 e 2014. Os menores erros foram atingidos pela abordagem MLP com $1,53 \text{ MJ/m}^2 \text{ dia} \leq \text{RMSE} \leq 2,29 \text{ MJ/m}^2 \text{ dia}$.

Mais recentemente, em 2017, os autores de [21] buscaram prever a potência fotovoltaica em dois horizontes, $(h+24)$ e $(h+48)$, utilizando uma RNA MLP com treinamento por *backpropagation*. Utilizaram como entrada a GHI média e a velocidade máxima do vento. Atingiram nRMSE de 7,78% para $(h+24)$ e 7,86% para $(h+48)$. Por fim, em 2018, uma RNA do tipo MLP treinada pelo algoritmo do gradiente conjugado foi aplicada por [22] para prever GHI em Alberta, no Canadá. O horizonte considerado foi de $(h+2)$. Apenas uma variável foi utilizada como entrada na rede, a GHI aferida em intervalos de 30 minutos. O nRMSE obtido foi de 10,8%.

Por meio dessa revisão da literatura, foi possível identificar quais combinações de variáveis meteorológicas os autores têm utilizado em seus modelos de previsão, a fim de testar combinações semelhantes com os dados disponíveis. Além disso, buscou-se identificar os níveis de erro dos modelos para posterior comparação com os valores atingidos por este trabalho.

III. METODOLOGIA POPOSTA

De forma sintetizada, o trabalho consiste na obtenção dos dados e conformação da base, combinação das variáveis de acordo com o observado na literatura, treinamento e validação da RNAs e análise dos erros de predição, conforme diagrama da Fig. 1.

A. Coleta e Tratamento de Dados

Os dados foram coletados por uma Estação Meteorológica Automática (EMA) sob as coordenadas de latitude $22^\circ 18' \text{ S}$ e longitude $47^\circ 23' \text{ W}$, com altitude de 690 m. A estação pertence ao Grupo de Estudos em Tecnologia de Irrigação (GETI), do Departamento de Recursos Naturais e Proteção

Ambiental da Universidade Federal de São Carlos (UFSCar), *campus* Araras, estado de São Paulo, Brasil.



Fig. 1. Fluxograma da metodologia proposta.

Cada planilha corresponde a uma coleta diária e contém além da data e das informações de localização da estação, 24 instâncias horárias (0h – 23h) com os dados da coleta divididos em colunas. As colunas constantes em cada planilha são:

- Irradiância global horizontal [MJ/m^2];
- Irradiância líquida [MJ/m^2];
- Velocidade do vento média e máxima horária [m/s];
- Umidade relativa mínima, média e máxima horária [%];
- Temperatura mínima, média e máxima horária [$^\circ\text{C}$];
- Precipitação pluviométrica (chuva) [mm];
- Coeficiente do tanque de classe A (ECA) [mm];
- Evapotranspiração de referência realizada com o método de Penman-Monteith (EtoPm) [mm].

Foram utilizados quatro anos completos de medições (2015, 2016, 2017 e 2018). O mês de dezembro de 2018 não apresentou coleta devido à manutenção da estação, de modo que a última coleta corresponde à medição de 30/11/2018 às 23h. Aproximadamente 1.460 planilhas (correspondentes aos 365 dias dos 4 anos) foram obtidas. As instâncias que apresentaram dados incoerentes foram suprimidas no processo de *data cleaning*. É importante destacar que essa exclusão representou 0,1% do total de dados (apenas 40 instâncias em mais de 34 mil). Foram excluídos os seguintes dias:

- 20/03/2015 – apresentou instâncias sem dados;
- 21/03/2016 a 28/03/2016 – o atributo (coluna) referente à coleta de 0h estava vazia;
- 08/01/2017 – a tabela deste dia apresentava valores desordenados e não se mostrava confiável;

- 28/06/2017 e 29/06/2017 – a estação estava em manutenção e não houve coleta de dados;
- 01/12/2018 a 31/12/2018 – a estação estava em manutenção e não houve coleta de dados.

Para efeitos de geração de energia elétrica a partir da matriz fotovoltaica, foram considerados interessantes à previsão os horários em que a GHI ultrapassava a marca de 0,10 MJ/m² (0,03 kWh/m²), com o intuito de evitar que as RNAs realizassem previsões nos horários em que a irradiância é nula ou inferior ao estipulado.

As coletas compreendidas entre 20h de um dia e 5h do dia seguinte foram dispensadas primariamente, visto que apresentavam valores de GHI nulos. O horário das 6h não apresentou valores constantes, visto que das 1.427 coletas realizadas neste horário, 1.311 (92%) apresentaram valores nulos e 116 (8%) apresentaram valores de aproximadamente 0,10 MJ/m². Assim, a faixa horária interessante à previsão ficou compreendida entre 7h e 19h, enquanto o intervalo entre 20h de um dia e 6h do próximo foi dispensado.

Aplicou-se *lag* (atraso) na planilha de dados. Considerando o instante de previsão como h , os *lags* instituídos foram de $(h-1)$ e $(h-2)$.

B. Combinação das variáveis meteorológicas e aplicação das RNAs

Foram realizadas duas combinações de dados, denominadas por Teste 1 e Teste 2 na tentativa de prever GHI com ótimos índices de acurácia. A principal diferença entre os testes foi a combinação de variáveis meteorológicas. Buscou-se fazer combinações comuns a literatura em relação à disponibilidade de dados da base.

No Teste 1, utilizou-se GHI $(h-1)$, temperatura média $(h-1)$, velocidade do vento $(h-1)$ e chuva $(h-1)$, caracterizando uma combinação mais clássica. O Teste 2 combinou GHI $(h-1)$, GHI $(h-2)$, temperatura média $(h-1)$, temperatura média $(h-1)$, velocidade do vento média $(h-1)$ e velocidade do vento média $(h-2)$.

As RNAs utilizadas na previsão foram do tipo MLP com algoritmo de treinamento Levenberg-Marquardt. As funções de ativação empregadas foram logística (para as camadas ocultas) e linear (para a camada de saída). As arquiteturas empregadas foram com uma camada neural (variando de 3 a 30 neurônios) e duas camadas neurais (combinando variações de 3 a 15 neurônios na primeira camada e de 3 a 30 neurônios na segunda camada). Em ambos os casos, os neurônios foram incrementados de 3 em 3. Para o treinamento das redes foi utilizado 70% do conjunto de dados, enquanto os 30% restantes foram empregados na etapa de validação. Cada teste ainda foi executado 5 vezes.

IV. ANÁLISE DE RESULTADOS

Nesta seção serão apresentadas as métricas utilizadas para avaliação do desempenho das RNAs frente a tarefa de previsão da série temporal de irradiância. Ademais, ainda será

realizada uma discussão em torno da literatura que representa o estado da arte nessa área de pesquisa.

A. Métricas de Avaliação de Erro

Nas últimas décadas, as variações de modelagens que tentam descrever o clima e o ambiente natural se expandiram. Neste sentido, tais modelos buscam sempre previsões que se mostrem mais precisas [23]. Portanto, algumas métricas para averiguar o erro dessas previsões são comuns às séries temporais de irradiância.

As diversas metodologias existentes para estimar os erros e a acurácia dos modelos produzem resultados diferentes entre elas, de modo que, em certos casos, mais de uma metodologia é aplicada com o intuito de se obter um panorama mais completo do erro [24].

A Raiz do Erro Médio Quadrático (RMSE, do inglês *Root Mean Square Error*), apresentada na Equação (1) afere a significância média do erro preditivo de forma quadrática e tem sido amplamente utilizada para aferir o desempenho de modelos de cunho climático [24], em que V_i é o valor observado no ambiente e v_i o valor estimado pelo modelo.

$$RMSE = \sqrt{\sum_{i=1}^n \frac{|V_i - v_i|^2}{V_i}} \quad (1)$$

A forma normalizada do RMSE, denominada por nRMSE, apresentada por meio da Equação (2), tem sido vastamente empregada para efeitos de comparação entre modelos preditivos. Nessa equação, \bar{v}_i é a média dos valores estimados.

$$nRMSE = \frac{RMSE}{\bar{v}_i} \quad (2)$$

Apesar do uso extenso dessas métricas, não há consenso sobre qual a melhor forma de representar o erro do modelo preditivo [24].

B. Avaliação de Desempenho das RNAs

O melhor resultado de cada execução para os Testes 1 e 2 são apresentados na Fig. 2 e Fig. 3, respectivamente. Nelas, é possível identificar o teste que apresentou os erros menos significativos em cada execução, tanto para RMSE como para nRMSE. Os resultados obtidos na 2ª execução do Teste 1 (T.1 E.2) e na 3ª execução do Teste 2 (T.2 E.3) apresentam resultados mais acurados.

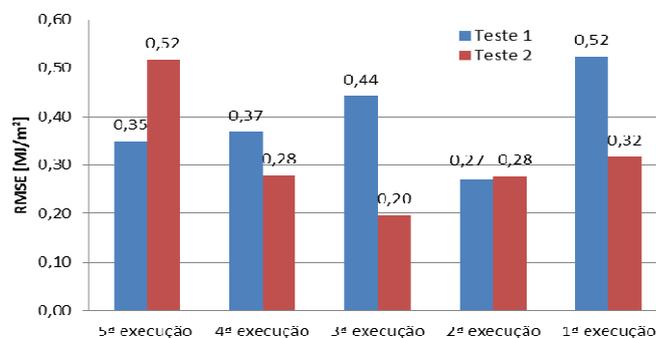


Fig. 2. Representação do erro preditivo através da métrica RMSE.

No Teste 1, a topologia que apresentou os menores índices de erro na 2ª execução consistiu em 2 camadas neurais ocultas com 6 e 6 neurônios, respectivamente. O Teste 2, por sua vez, na 3ª execução apresentou topologia de 2 camadas neurais ocultas com 3 e 27 neurônios, respectivamente.

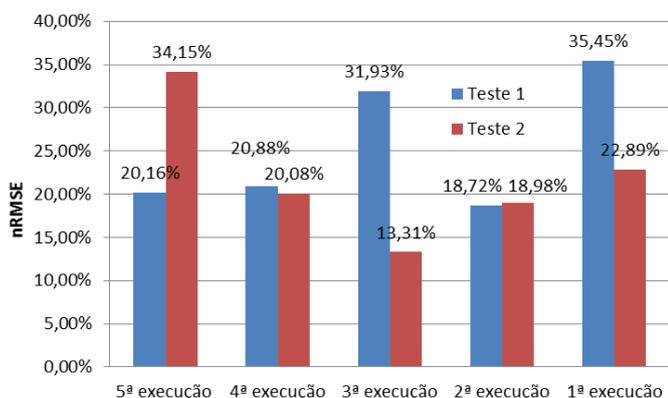


Fig. 3. Representação do erro preditivo através da métrica nRMSE.

Ainda assim, o resultado obtido no Teste 2 apresenta melhores índices de acurácia que os resultados obtidos no Teste 1. Em relação aos dados de entrada das redes, o Teste 2 apresentou *lags* maiores ($h-1$) e ($h-2$) do que o Teste 1, além de possuir uma variável a menos (chuva).

C. Discussões

Na literatura, alguns autores têm se destacado com resultados muito acurados e que descrevem com precisão a realidade de seus cenários de pesquisa. Esses autores foram recuperados na revisão deste trabalho. Assim, a Fig. 4 e Fig. 5 estabelecem um panorama geral, por meio das métricas RMSE e nRMSE, com o intuito de possibilitar uma visualização comparativa entre os resultados obtidos pela metodologia proposta e aqueles já publicados por outros autores.

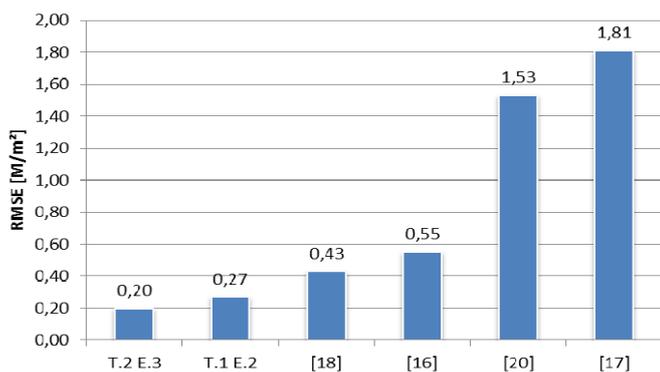


Fig. 4. Comparação dos resultados em termos de RMSE.

A partir da análise comparativa, observa-se que os resultados encontrados pela metodologia proposta são mais acurados para RMSE. Nessa métrica, considerando apenas o Teste 2, nota-se que esse se mostra como uma melhor proposta.

Entretanto, os resultados do Teste 1 ainda são muito superiores, quando comparados a outros quatro autores analisados.

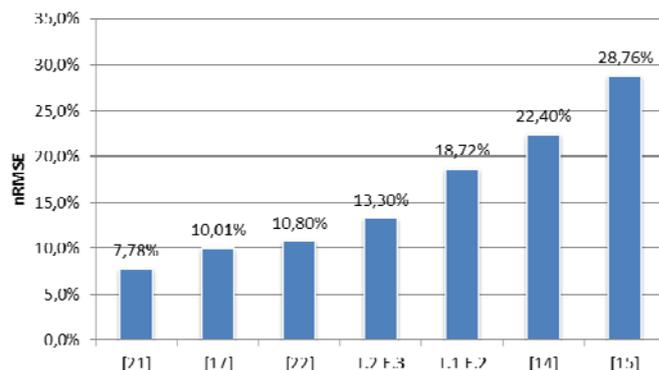


Fig. 5. Comparação dos resultados em termos de nRMSE.

Analisando nRMSE, nota-se que o Teste 2 se reafirma como mais acurado em relação ao Teste 1 e em relação a dois autores. Destaca-se que o autor de [21], que atingiu valores de erro muito menores que a metodologia proposta, estava prevendo uma variável diferente, potência fotovoltaica. Em [17] e [22] a previsão era GHI. Assim, o resultado de [17] ofereceu uma combinação de dados diferente da utilizada na metodologia e que pode ser testada, enquanto [22] provou a acurácia de uma rede treinada pelo algoritmo do gradiente conjugado e variáveis aferidas em intervalos mais curtos (30 minutos).

V. CONCLUSÃO

Este trabalho propôs usar dados climáticos diários e horários como entrada em modelos preditivos baseados em Redes Neurais Artificiais, com a intenção de prever a irradiância global horizontal. Por fim, compararam-se os resultados obtidos com a literatura previamente consultada. Percebeu-se que duas topologias se destacaram, obtendo resultados melhores que 6 dos 9 artigos comparados ao analisar os valores de RMSE e nRMSE. Os resultados alcançados foram satisfatórios devido ao erro de predição ser relativamente baixo (nRMSE entre 13% e 18%; e RMSE entre 0,20 e 0,27 MJ/m²). Ainda assim, pretende-se identificar nas publicações dos demais autores combinações de dados e arquiteturas de rede que, testados, talvez possam auxiliar na melhoria da acurácia da predição, atingindo assim erros cada vez mais baixos.

AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001 e também da Fundação de Amparo à Pesquisa ao Desenvolvimento Científico e Tecnológico do Maranhão (FAPEMA) – Processo nº BM-08469/17.

REFERÊNCIAS

- [1] Instituto brasileiro de geografia e estatística. População nos censos demográficos, segundo as grandes regiões e as unidades da federação - 1872/2010. 2010.

- [2] S. P. Mohanty, U. Choppali, E. Kougianos, "Everything you wanted to know about smart cities: the Internet of things is the backbone", *IEEE Consumer Electronics Magazine*, vol. 5, pp. 60–70, Julho 2016.
- [3] M. Curiale, "From smart grids to smart city", 2014 Saudi Arabia Smart Grid Conference (SASG), Jeddah, pp. 1-9, Dezembro 2014.
- [4] A. Aliberti, L. Bottaccioli, G. Cirrincione, E. Macii, A. Acquaviva e E. Patti, "Forecasting short-term solar radiation for photovoltaic energy predictions". *Proceedings of the 7th international conference on smart cities and green ict systems (SMARTGREENS 2018)*, pp. 44-53, Março 2018.
- [5] K. Geisler, "The relationship between smart grids and smart cities", Online: <http://smartgrid.ieee.org/newsletters/may-2013/the-relationship-between-smart-grids-and-smart-cities>.
- [6] R. Meenal, A. I. Selvakumar, "Assessment of solar energy potential of smart cities of tamil nadu using machine learning with big data", *Advances in Big Data and Cloud Computing*, vol. s.l., pp. 27–36, Dezembro 2018.
- [7] C. Voyant et al, "Machine learning methods for solar radiation forecasting: a review", *Renewable Energy*, vol. 105, pp. 569-582, Maio 2017.
- [8] D. Heim, "The simultaneous effect of the operating temperature and solar radiation on the efficiency of photovoltaic panels", *Archives of Civil Engineering*, vol. 57, pp. 261-274, Setembro 2011.
- [9] J. Antonanzas et al, "Review of photovoltaic power forecasting", *Solar Energy*, vol. 136, pp. 78-111, Outubro 2016.
- [10] C. Voyant, C. Paoli, M. Muselli, M.L. Nivet, "Multi-horizon solar radiation forecasting for mediterranean locations using time series models", *Renewable And Sustainable Energy Reviews*, vol. 28, pp. 44-52, Dezembro 2013.
- [11] M. Diagne, M. David, P. Lauret, J. Boland, N. Schmutz, "Review of solar irradiance forecasting methods and a proposition for small-scale insular grids". *Renewable and Sustainable Energy Reviews*, vol. 27, pp. 65-76, Novembro 2013.
- [12] C. Voyant et al, "Machine learning methods for solar radiation forecasting: a review". *Renewable Energy*, vol. 105, pp. 569-582, Maio 2017.
- [13] Y. Kemmoku, S. Orita, S. Nakagawa, T. Sakakibara, "Daily insolation forecasting using a multi-stage neural network". *Solar Energy*, vol. 66, pp. 193-199, Junho 1999.
- [14] C. Voyant, P. Randimbivololona, M. L. Nivet, C. Paoli, M. Muselli, "Twenty four hours ahead global irradiation forecasting using multi-layer perceptron". *Meteorological Applications*, vol. 21, pp. 644-655, Julho 2014.
- [15] P. Lauret, M. Diagne, M. David, "A neural network post-processing approach to improving nwp solar radiation forecasts". *Energy Procedia*, vol. 57, pp. 1044-1052, 2014.
- [16] L. Olatomiwa, S. Mekhilef, S. Shamshirband, K. Mohammadi, D. Petković e C. Sudheerf, "A support vector machine–firefly algorithm-based model for global solar radiation prediction", *Solar Energy*, vol. 115, pp. 632-644, 2015.
- [17] K. Mohammadi, S. Shamshirband, C. W. Tong, M. Arif, D. Petković, C. Sudheer, "A new hybrid support vector machine-wavelet transform approach for estimation of horizontal global solar radiation", *Energy Conversion and Management*, vol. 92, pp. 162-171, 2015.
- [18] S. Shamshirband, K. Mohammadi, P. L. Yee, D. Petković, A. Mostafaepour, "A comparative evaluation for identifying the suitability of extreme learning machine to predict horizontal global solar radiation", *Renewable and Sustainable Energy Reviews*, vol. 52, pp. 1031-1042, 2015.
- [19] P. Lauret, C. Voyant, T. Soubdhan, M. David, P. Poggi, "A benchmarking of machine learning techniques for solar radiation forecasting in an insular context", *Solar Energy*, vol. 112, pp. 446-457, 2015.
- [20] L. Wang, O. Kisi, M. Zounemat-Kermani, G. A. Salazar, Z. Zhu, W. Gong, "Solar radiation prediction using different techniques: model evaluation and comparison", *Renewable and Sustainable Energy Reviews*, vol. 61, pp. 384-397, 2016.
- [21] A. Romero, F. L. Quilumba, H. N. Arcos, "Short-term active power forecasting of a photovoltaic power plant using an artificial neural network". 2017 IEEE Second Ecuador Technical Chapters Meeting (ETCM), pp.[s.l.], Outubro. 2017.
- [22] G. Vanderstar, P. Musilek, A. Nassif, "Solar forecasting using remote solar monitoring stations and artificial neural networks". 2018 IEEE Canadian Conference On Electrical & Computer Engineering (CCECE), pp. 01-04, Maio 2018.
- [23] C. J. Willmott, K. Matsuura, "Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance". *Climate Research*, Oldendorf, vol. 30, pp. 79-82, Dezembro 2005.
- [24] T. Chai, R. R. Draxler, "Root mean square error (RMSE) or mean absolute error (MAE)? – Arguments against avoiding RMSE in the literature". *Geoscientific Model Development*, vol. 7, pp. 1247-1250, Junho 2014.