

PREVISÃO DA RADIAÇÃO GLOBAL USANDO MODELOS DE REDES NEURAIIS ARTIFICIAIS

Aléxia Monteiro Valentim – alexiavalentim@isi-er.com.br

Emmanuel Bezerra Cavalcante da Silva

Universidade Federal do Rio Grande do Norte, Departamento de Ciências Atmosféricas e Climáticas, Campus Natal

Alexandre Torres Silva dos Santos

Instituto Senai de Inovação em Energias Renováveis, Natal, RN

Resumo. Estudos envolvendo a disponibilidade solar para empreendimentos renováveis ganham grande importância no cenário de mitigação das mudanças climáticas. Mediante a isso, visando o potencial que os empreendimentos podem gerar, é possível, através de vários horizontes preditivos, otimizar decisões no setor fotovoltaico. O Instituto Nacional de Pesquisas Espaciais (INPE) criou a Rede SONDA com o intuito de sistematizar e organizar dados de torres para estudos envolvendo as energias renováveis. Foram selecionadas as cidades de Joinville (SC) e Natal (RN) para previsões em diferentes escalas de tempo. Em relação à previsão, o modelo de Redes Neurais Artificiais foi implementado para realizar um diagnóstico da energia solar com base em períodos de menor insolação, com base no ciclo diurno. Através da análise de dados que foram criados para este fim, os resultados revelaram uma acurácia excelente com o erro percentual absoluto médio (MAPE) em 0,0032% na previsão de uma hora à frente para Natal (RN), e um valor de 0,55% para Joinville (SC). Desse modo, é possível usar a ferramenta como forma de otimizar a confiabilidade da prospecção de energia solar.

Palavras-chave: Radiação Global, Redes Neurais, Energia Solar

1. INTRODUÇÃO

A radiação global incidente na atmosfera é absorvida em parte, enquanto outra parcela é refletida pelas nuvens e pela superfície. Na meteorologia, a disponibilidade solar ao longo do dia é caracterizada pelo ciclo diurno, tal ciclo gera influência na quantidade de horas que o sol irradia e o quanto de radiação pode ser atingida. O ciclo diurno é o período no qual o sol irradia devido à rotação da Terra. A importância desse ciclo está na variação da temperatura ao longo do dia, sendo responsável pelo aquecimento tanto do solo quanto do ar (Moreira, 2015).

Os fatores meteorológicos que envolvem a disponibilidade solar, são tais como a latitude como cita Bedaque (2016) e a sua respectiva estação do ano. Desse modo, a prospecção energética envolve variáveis ambientais, tais como as energias limpas, tanto a eólica que utiliza a força dos ventos como a solar que utiliza a insolação direta do sol. De acordo com o balanço global de energia, a maior disponibilidade possível de radiação solar que incide à superfície é um requisito para empreendimentos renováveis e suas aplicações tanto na indústria, quanto na agricultura, entre outras demandas de relevância socioeconômica significativa. Nesse contexto, o despertar de interesse em cidades que já possuem empreendimento fotovoltaico mostra o comparativo na geração de energia de acordo com a quantidade obtida por dia. Em fontes de energia renováveis são geradas com uma maior sustentabilidade, necessária ao destaque para tais fontes devido às alterações climáticas em todo o globo.

Devido às mudanças climáticas globais, a urgência em investimentos e iniciativas voltados para energias limpas torna-se mais evidente. Isso abrange tanto os Objetivos de Desenvolvimento Sustentável (ODS), relacionados ao desenvolvimento de energias renováveis e acessíveis para combate às mudanças climáticas, quanto aos números 7 e 13, respectivamente.

O uso da radiação solar para geração de eletricidade teve início em 1839 por Antoine Henri Becquerel, impulsionando o desenvolvimento dos módulos fotovoltaicos ao longo do tempo, com a primeira célula de silício sendo realizada em 1941. A crescente necessidade de informações sobre a radiação solar na superfície desde a crise do petróleo em 1973, conforme ressaltado por Pereira e Colle (1997), destaca a importância contínua e significativa desse campo de pesquisa.

Partindo para energia solar, visto que ela é a fonte de energia que mais cresce no Brasil, sua utilização pode ser otimizada com a previsão de disponibilidade da irradiação. Em climas semiáridos, a disponibilidade é melhor, visto que o maior parque da América do Sul está localizado no Piauí. Para tanto, o estudo visa contemplar locais no Brasil com grande potencial segundo o atlas solar brasileiro (Pereira *et al.*, 2017) para previsão em diferentes escalas de tempo.

2. MATERIAL E MÉTODOS

2.1 Área de estudo e fonte de dados

Os dados escolhidos para conduzir o estudo preditivo foram obtidos da rede do Sistema de Organização Nacional de Dados Ambientais (SONDA) (Martins *et al.*, 2007). Esses dados foram coletados e instrumentalizados para a criação do Atlas Solar Brasileiro, uma iniciativa colaborativa do Instituto Nacional de Pesquisas Espaciais (INPE). Este projeto é fruto de um esforço conjunto para disponibilizar dados de forma gratuita e promover pesquisas no campo de energias

renováveis. Nesse contexto, a faixa temporal selecionada abrange os meses de dezembro de 2014 a dezembro de 2017, adotando um intervalo específico para a cidade de Natal, Rio Grande do Norte (5°48'45''S, 35°15'18''W), com uma frequência de amostragem a cada minuto.

Para Joinville, Santa Catarina (26°18'18''S, 48°50'46''O), foi escolhido outro período com base na disponibilidade de dados, compreendendo o intervalo de setembro de 2010 a setembro de 2014. A relevância do critério de *missing values* (dados ausentes) é evidenciada na Fig. 1. Pode-se observar que os meses marcados em verde apresentam uma menor quantidade de dados faltantes ou quantidade nula, enquanto os meses em vermelho possuem mais lacunas. O critério adotado para a seleção foi a continuidade dos dados, considerando que períodos consecutivos com uma quantidade mais significativa de informações foram considerados ideais para a utilização no estudo.

Anos	Dados Faltantes para Natal												
	2007			2008			2009			2010			
2007	40%												
2008	1%	1%	2%	2%	2%	1%	4%	0%	40%	20%	10%	5%	
2009	60%	10%											
2010										5%			
2011			2%	5%									
2012												90%	
2013													
2014											95%	0%	
2015													
2016													
2017	0%												
2018										20%			
2019				5%									
Meses	Janeiro	Fevereiro	Março	Abril	Maio	Junho	Julho	Agosto	Setembro	Outubro	Novembro	Dezembro	

Figura 1 – Disponibilidade de Dados de Radiação Global para Natal (RN). Fonte: Os autores.

Posteriormente, os dados foram processados pela média para estabelecer uma periodicidade por horas e dias, atendendo a determinados objetivos do estudo. O conjunto de dados disponíveis para Radiação Global (W/m²) totalizou 24.120 registros para a cidade de Natal (RN) e 35.781 para Joinville (SC). A comparação foi conduzida com o intuito de analisar as discrepâncias nos ciclos diurnos e na disponibilidade de irradiação solar entre as duas cidades.

Sob uma perspectiva meteorológica, os meses com menor disponibilidade de radiação, indicando maior cobertura de nuvens, abrangem o período entre maio e julho nas duas cidades, durante a análise realizada. Em Natal, a maior disponibilidade de radiação global ocorre nos meses de setembro a novembro, ao passo que em Joinville, esse período se estende de novembro a fevereiro, como é mostrado a seguir. De forma quantitativa, Natal apresenta, na Figura 2.b, uma superior disponibilidade quantitativa de radiação ao longo do ano. Através da Figura 2, é possível destacar menores valores de radiação global para os meses entre maio e julho durante o período analisado e os maiores valores entre novembro e março para as duas localidades. A escolha do horizonte preditivo para compor a metodologia do estudo seguiu diferentes passos para cada frequência de dados.

2.2 Modelo de redes neurais

Redes neurais artificiais (RNA) são métodos computacionais que têm como princípio de conduta a utilização de modelos matemáticos inspirados no funcionamento dos elementos que constituem a estrutura neural de organismos inteligentes, os quais obtêm conhecimento através de experiências às quais são expostos. Sua conduta provém das interações entre as unidades que fazem parte do processamento, partindo do ambiente, por meio de um processo de aprendizagem (Haykin, 1998). Torna-se interessante o uso das RNA devido à sua capacidade de aprendizado satisfatória.

Sendo popular e utilizada em diversos problemas, a técnica demonstrou ser muito útil no reconhecimento de padrões, classificação de padrões, modelagem de funções e previsão de modelos. No entanto, a definição de seus parâmetros desempenha um papel fundamental em seu desempenho, uma vez que a arquitetura definida pode influenciar significativamente o processo de treinamento. A escolha dos parâmetros da arquitetura de uma RNA não é um problema simples; é necessário um esforço por parte do especialista na hora de determinar alguns parâmetros. Normalmente, é utilizado o empirismo, ou seja, o especialista faz diversas configurações de redes, avalia cada uma e observa qual se adequa melhor à finalidade do seu estudo. Tendo em vista a popularidade do método empírico, nem sempre ele apresentará resultados verdadeiros, levando em consideração a confiabilidade na obtenção de uma arquitetura satisfatória (Prechelt *et al.*, 1994).

O processo de seleção de uma arquitetura adequada para um problema de RNA pode ser classificado em três etapas:

- (i) escolha dos parâmetros da arquitetura;
- (ii) treinamento da rede;
- (iii) teste da rede.

O tratamento de dados para a variável de Radiação Solar Global, como dado de entrada para o modelo *Neural Network Time Series Forecasts Autoregressive* (NNETAR) para previsão em diferentes tempos, considerou apenas dados positivos a partir das médias diárias, já que na ausência de radiação solar, os números computados são abaixo de zero e comprometem o cálculo da média. A previsão de radiação solar pode ser aplicada em diversos contextos, desde a agrometeorologia para reprodução de padrões aguardados para a safra e contribuir com os cultivos (Bocco *et al.*, 2006). O modelo NNAR possui um comportamento senoidal, que confere uma maior credibilidade para as informações previstas para irradiação solar, visto que confere ao ciclo diurno um comportamento semelhante.

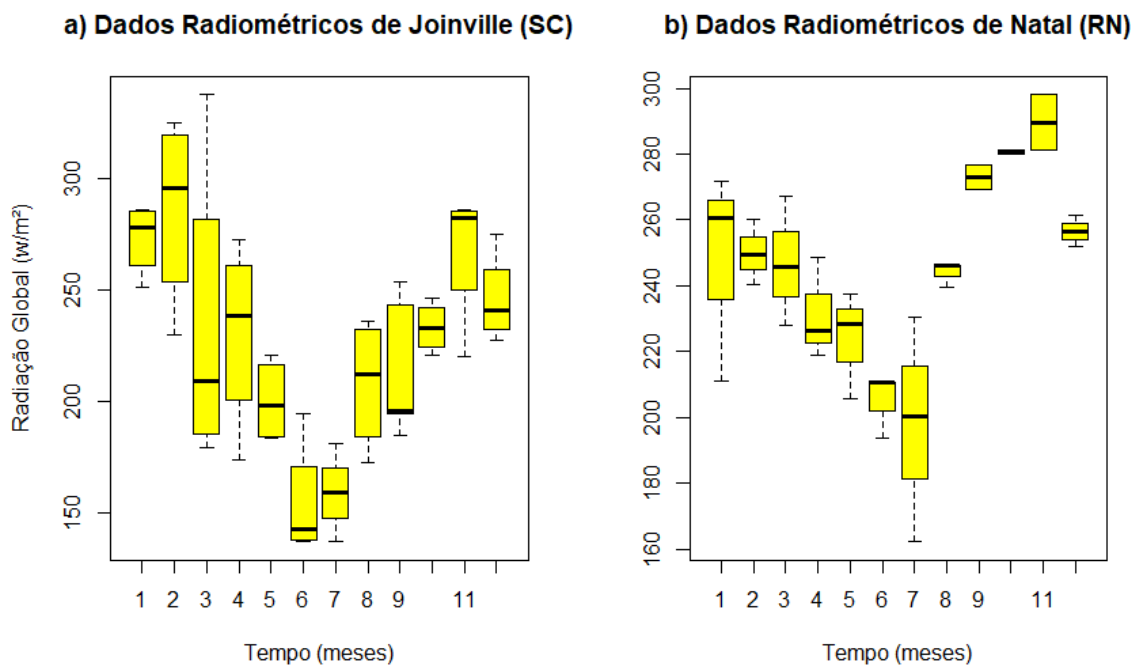


Figura 2 – Boxplot Mensal dos Dados de Radiação Global (W/m²).

2.3 Tratamento de dados

A validação dos dados na rede é conduzida por meio do controle de qualidade atualizado (Driemel *et al.* 2018) do *Baseline Surface Radiation Network*, inicialmente proposto por Ohmura *et al.* (1998), em conformidade com as práticas do *World Radiation Monitoring Center (WRMC)*. Adicionalmente, a metodologia adotada para estabelecer critérios de confiabilidade dos dados envolve percentuais e a realização de testes, conforme apresentado na Tab. 1. Os dados são submetidos a testes em dois algoritmos para confirmar a validade do fenômeno, demonstrando sua raridade ou viabilidade física com base em padrões estatísticos da variável. Posteriormente, os dados foram processados por meio de integração em periodicidades de horas e dias para atender a determinados objetivos do estudo.

Tabela 1 - Processo detalhado acerca do controle de qualidade de dados.

Variável: Global Horizontal (w/m²)		
Fisicamente possível (algoritmo 1)	Extremamente raro (algoritmo 2)	Comparação entre Sensores (algoritmo 3)
Desvio padrão diferente de zero	Valor mínimo de -2	Quociente entre Global e Sum deve estar entre $\pm 10\%$ de 1,0 para $AZS < 75^\circ$, $Sum > 50$ (Global) / (Sum)
Valor mínimo de -4 e máximo de: $(Sa \times 1,5 \times \mu_{01,2} + 100)$	Valor máximo de $Sa \times 1,2 \times \mu_{01,2} + 50$	Quociente entre Global e Sum deve estar entre $\pm 15\%$ de 1,0 para $93^\circ > AZS > 75^\circ$, $Sum > 50$

Disponível no endereço eletrônico: <<http://sonda.ccst.inpe.br/infos/validacao.html#critérios>>. Acesso em 14/11/2023. Nota: nas fórmulas acima, se $AZS > 90^\circ$, μ_0 é considerado 0,0. Para o terceiro algoritmo, este teste não é possível para $Sum < 50$.

Onde:

$Sa = S_0/UA_2$ é a constante solar ajustada para distância Terra-Sol

AZS = ângulo do zênite solar

$\mu_0 = \cos(AZS)$

$Sum = [Difusa + (Direta Normal) \times \mu_0]$

2.4 Imputação de dados

Para a preparação dos dados e sua utilização em modelos preditivos torna-se necessário completar suas falhas dentro do banco de dados, como também chamado: imputação de dados. As chamadas *missing values* que são lacunas dentro dos dados que estão ausentes e provavelmente não foram medidos e para tanto utilizam-se técnicas estatísticas que preenchem de forma a não modificar seus padrões. Um método proposto por Rubin, 1987 buscou realizar a imputação múltipla dos dados através de estimativas, chamada *Bootstrap Expectation Maximization* (Boot-EM), para cada valor estimado um grupo é criado e após isso, a média é realizada. Rodrigues (2023) utilizou a técnica para dados de precipitação, obteve excelentes resultados e por isso usamos o método para previsão da radiação global.

A técnica foi usada através do *Software Livre R* pela biblioteca *Amelia II* (Honaker *et al.*, 2011), ela funciona por *bootstrapping* e os dados são correlacionados entre os existentes no banco de dados, trata-se de um método de imputação de dados que foi implementado no presente estudo.

2.5 Horizonte preditivo

A seleção das previsões a serem realizadas demandou a definição de diversos horizontes para avaliar o desempenho do modelo em diferentes períodos. As flutuações na disposição da radiação solar interferem diretamente na produção de energia solar fotovoltaica, que são influenciada das condições meteorológicas diárias.

Para utilizar as previsões como forma de prospecção energética é necessário uma obtenção de dados de radiação solar e dessa forma, considerar a cobertura de nuvens de maneira visual, o modelo auxiliará o previsor e o consumidor final para geração de energia em curto, médio e longo prazo, conforme ilustra a Fig. 3, demonstrando horizontes preditivos selecionados para o estudo.

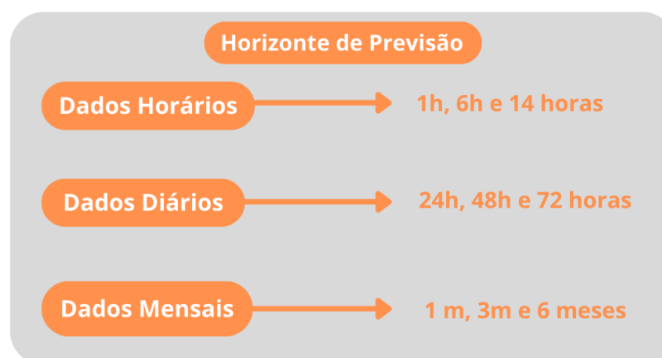


Figura 3 – Metodologia dos horizontes de previsão.

2.6 Métricas de erro

Modelos de previsão tornam-se úteis a partir de seu desempenho. Para avaliar o quão eficaz foi, algumas técnicas foram utilizadas. Dessa forma, alguns cálculos estatísticos foram empregados para mensurar os erros correspondentes. São eles: a raiz do erro quadrático médio (RMSE), o erro médio absoluto (MAE), o viés (BIAS) e, por último, o erro absoluto percentual médio (MAPE). Em termos gerais, os cálculos demonstram valores correlacionados, sendo o MAPE o indicador que expressa o erro em formato percentual. Desse modo, o cálculo foi realizado pela biblioteca **Metrics** no *Software Livre R*, que foi utilizada para realizar essas avaliações, dentro do mesmo ambiente onde as previsões foram conduzidas.

3. RESULTADOS

Os resultados mostram um excelente ajuste para o modelo NNAR em ambas as localidades, como pode ser visto na Fig. 4. O modelo nas duas localidades consegue se ajustar bem aos dados, levando em consideração a quantidade de dados disponíveis. Nos meses de menor radiação, o mês de março foi selecionado para Joinville (SC), e apenas a previsão de 48 horas mostrou um desempenho superior ao modelo. Por outro lado, no mês escolhido entre os de maior radiação, tanto a previsão de 48 horas quanto a de 72 horas foram favoráveis ao modelo.

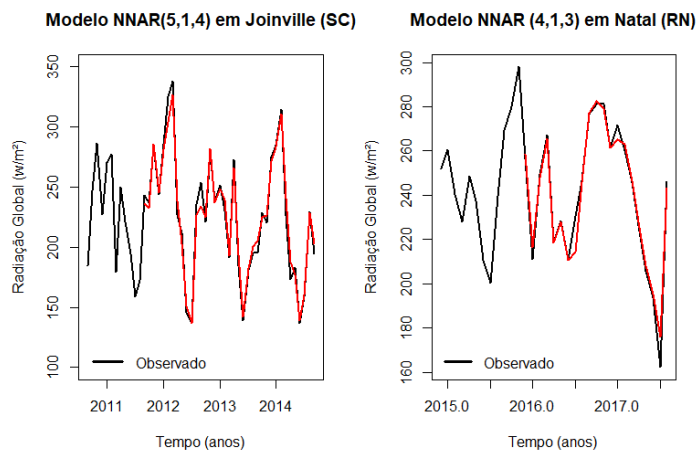


Figura 4 – Ajuste dos modelos NNAR para previsão em Joinville e Natal.

3.1 Resultados horários

O De acordo com a Fig. 5b, o melhor resultado no horizonte preditivo de 6 horas à frente foi o da cidade de Natal (RN) utilizando um modelo de Redes Neurais Autoregressivas Não Lineares (NNAR), pertencente à classe NNETAR. Foram empregadas 20 redes no modelo, cada uma com cinco nós na camada de entrada, três nós na camada oculta e um nó na camada de saída. Durante o treinamento da série temporal, 22 pesos foram ajustados. As unidades de saída foram configuradas como lineares, indicando uma previsão resultante da combinação linear das entradas ponderadas. A variância (sigma) foi estimada em 7.139, com uma defasagem de 4 e uma ordem de 3. A previsão apresentou um erro de 0,26 nas métricas de MAE, RMSE e BIAS, enquanto no MAPE o erro foi de 0,0032%, conforme pode ser observado na Tab. 2.

Tabela 2 – Acurácia da previsão horária em Natal (RN).

Natal (RN)	Horizonte e Modelo		
	1h	6h	14h
Métrica	NNAR (4,1,3)	NNAR (4,3)	NNAR (43,22)
MAE	6,57	0,26	10,48
MAPE	2,50%	0,03%	1,23%
BIAS	6,57	0,26	10,48
RMSE	6,57	0,26	10,48

De acordo com a Fig. 5a, o melhor resultado no horizonte preditivo de 5 horas à frente foi o da cidade de Joinville (SC). Foram empregadas 20 redes no modelo, cada uma com trinta nós na camada de entrada, dezesseis na camada oculta e um nó na camada de saída. Durante o treinamento, 513 pesos foram configurados. A variância (sigma) foi estimada em 7.481, com uma defasagem de 17 e uma ordem de 30. A previsão indicou um erro de 0,49 para o BIAS e o mesmo valor para o RMSE. Ao mesmo tempo, o MAPE apresentou um erro de 0,55%, enquanto o MAE atingiu o valor de -0,49.

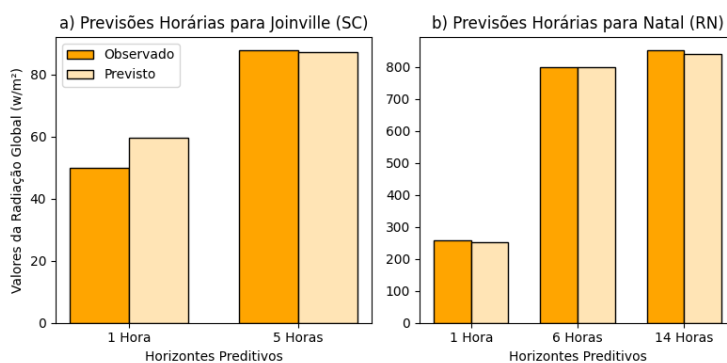


Figura 5 – Resultados das melhores previsões horárias para Joinville e Natal.

3.2 Resultados diários

Os resultados diários foram avaliados considerando meses de maiores e menores radiações globais, nas previsões de 24, 48 e 72 horas, conforme a Tab. 3, onde os dois meses foram escolhidos de acordo com a disponibilidade de radiação global. Nos diferentes meses, foram utilizadas as mesmas configurações dos modelos, mesmo que apresentem resultados diferentes. O mês de maior disponibilidade de radiação global para a localidade de Natal (RN) foi outubro, enquanto em Joinville (SC) corresponde ao mês de setembro. Já o mês de menor disponibilidade de radiação global para Natal (RN) foi julho, de acordo com a faixa temporal analisada, e para Joinville é o mês de março.

Tabela 3 – Acurácia da previsão diária em Natal (RN).

Horizonte	24h	48h	72h	24h	48h	72h
Mês e NNAR	Julho (4,3)			Outubro (4,3)		
MAE	139	20,62	7,94	15,21	74,22	82,65
MAPE	38,61%	5,14%	1,85%	2,97%	14,33%	16,22%
BIAS	-139	-20,62	-7,94	15,21	74,22	82,65
RMSE	139	20,62	7,94	15,21	74,22	85,65

Foram aplicadas 20 redes no modelo, totalizando dezoito nós na camada de entrada, dez na camada oculta e um nó na camada de saída. Ao longo do treinamento, foram implementados 201 pesos. A variância (sigma) é estimada em 4.844, com uma defasagem de 10 e ordem de 18. A previsão indica um erro de 5,81% para o mês de março no horizonte de 48 horas e um erro de 3,5% para um horizonte de 72 horas no mês de setembro. O melhor desempenho em Joinville (SC) ocorreu no horizonte preditivo de 2 dias à frente em março e de 3 dias à frente em setembro, conforme quantificado na Tab. 4.

Tabela 4 – Acurácia da previsão diária em Joinville (SC).

Horizonte	24h	48h	72h	48h	72h
Mês e NNAR	Mar (18,10)			Set (18,10)	
MAE	40,85	16,27	59,077	8,27	6,29
MAPE	17,85%	5,81%	2,33%	4,2%	3,5%
BIAS	40,85	16,27	-59,07	8,27	-6,29
RMSE	40,85	16,27	59,07	8,27	6,29

O modelo subestima nos horizontes de 1 e 2 dias na Fig. 6a e superestima no horizonte de 3 dias. Na Fig. 6c, o modelo subestima o horizonte de 48h e superestima o de 72 horas. Em Natal (RN), foram utilizadas as mesmas configurações dos modelos utilizados nas previsões horárias. A melhor previsão para outubro em Natal (RN) foi a de 24

horas, com um MAPE de 2,98% de erro, enquanto para julho, o previsto de 72 horas alcançou um valor de 1,85% de erro, conforme ilustra a Fig. 6b e 6d.

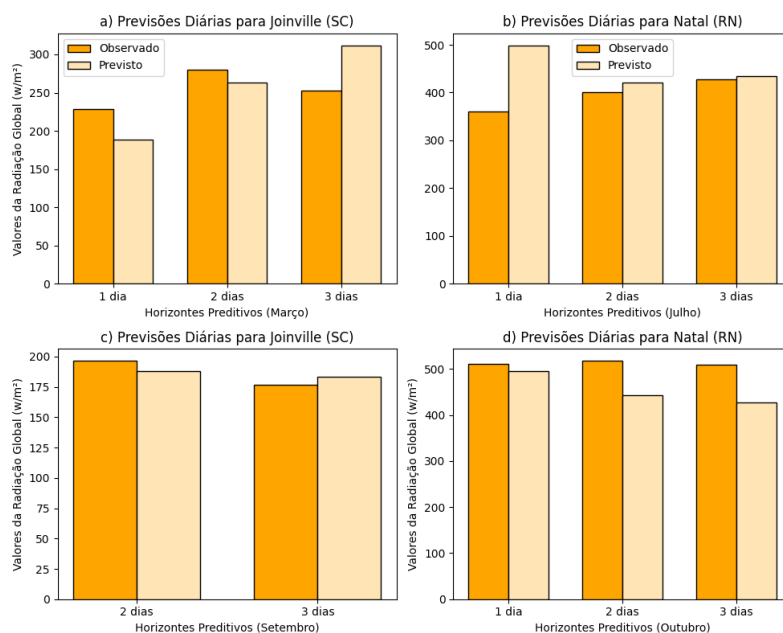


Figura 6 – Resultados das melhores previsões diárias para Joinville e Natal.

3.3 Resultados mensais

Para o modelo NNAR preditivo de Joinville (SC), a rede contou com cinco nós na camada de entrada, quatro na camada oculta e um na camada de saída. Obteve uma defasagem de 5 e ordem de 4, com sua variância estimada em 11,36. Seus pesos foram ajustados para 29. As previsões indicam erro de 0,86% em um mês à frente e 2,16% em seis meses à frente como pode ser visto na Tab. 5. O melhor resultado foi em 1 mês à frente, destacando-se com um MAE de 3,87 em Natal (RN) e 1,66 em Joinville (SC), conforme ilustrado na Fig. 7a e 7b com previsões mensais para o trimestre analisado. Quanto à previsão mensal, obteve o melhor desempenho para 1 mês à frente e um resultado excelente para 6 meses à frente na cidade de Joinville (SC), com acurácia superior à previsão trimestral.

Tabela 5 – Acurácia das previsões mensais nas duas localidades.

(RN) - Previsão Mensal NNAR (4,1,3)				(SC) - Previsão Mensal NNAR (5,4)		
Horizonte	1 m	3 m	6 m	1 m	3 m	6 m
MAE	3,87	39,18	20,75	1,66	87,26	5,00
MAPE	15,74%	19,04%	8,42%	0,86%	44,7%	2,16%
BIAS	-3,87	-39,18	20,75	1,66	-87,26	5,00
RMSE	3,87	39,18	20,75	1,66	87,26	5,00

Na construção do modelo NNAR para previsão mensal em Natal (RN), foram empregadas 20 redes, cada uma com quatro nós na camada de entrada, um nó na camada oculta e três na camada de saída. A estimativa da variância do erro (sigma) ficou em 4.417. O modelo apresentou uma defasagem de 1 e uma ordem de 4. As previsões mensais para cidade de Natal, como mostra a Fig. 7b, revelam uma superestimação na previsão do trimestre e uma subestimação na previsão de 6 meses à frente.

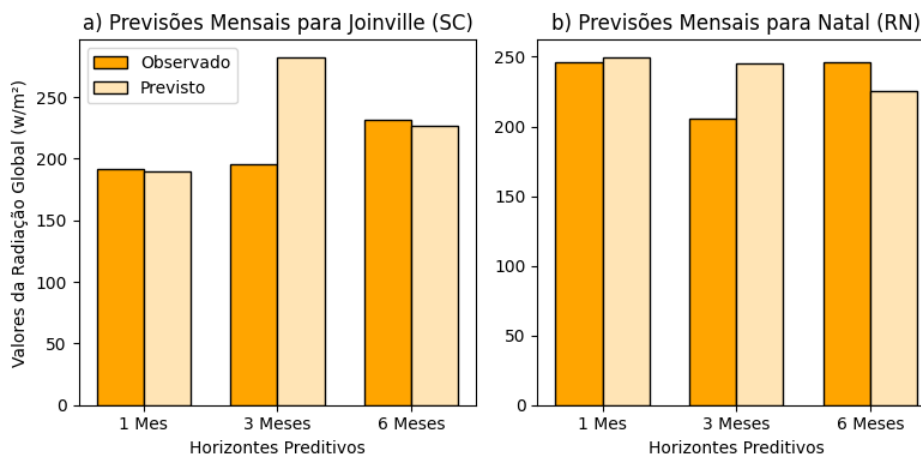


Figura 7 – Resultados das melhores previsões mensais para Joinville (7.a) e Natal (7.b).

4. CONCLUSÃO

Os melhores resultados ao utilizar o modelo NNAR do NNETAR na escala horária para dados de radiação global em ambas as cidades foram no horizonte entre 5 e 6 horas à frente, com erros abaixo de 1%, segundo a métrica MAPE. Em relação à previsão em escala diária, a disponibilidade de irradiação se altera ao longo do ano. O modelo foi testado para diferentes meses em Natal, que possui uma maior quantidade de radiação global. A previsão de 1 dia à frente em meses secos apresentou um excelente resultado, enquanto em meses mais chuvosos, a previsão de 3 dias à frente se mostrou ideal. Da mesma forma, para Joinville, em termos comparativos, em meses de menor disponibilidade solar, a previsão de 48 horas à frente se mostrou eficiente, enquanto em meses de maior disponibilidade, a previsão de 3 dias à frente é mais recomendada. Os resultados das previsões mensais se mostraram igualmente eficientes para o horizonte de um mês à frente.

Com base nas análises conduzidas neste estudo, há uma forte indicação de que o uso de redes neurais na modelagem de dados radiométricos se revelou uma excelente ferramenta, demonstrando métricas de erro consistentemente baixas numericamente. Os resultados obtidos foram excelentes, ao considerar que havia um pequeno período de tempo para análise. Ao avaliar duas localidades distintas, uma na região litorânea do Nordeste e outra na Região Sul, o estudo destacou que essas áreas apresentam disponibilidades de radiação de maneira distinta ao longo do ano.

Notavelmente, Joinville exibiu maior variabilidade na distribuição da radiação em comparação com a cidade de Natal. No entanto, ambos os locais compartilham meses com menor disponibilidade de radiação, indicando maior cobertura de nuvens durante o período entre maio e julho. Esses resultados oferecem uma compreensão valiosa para apoiar a tomada de decisões, seja na escolha da localidade para geração de energia ou na determinação do melhor período para utilizar fontes geradoras de energia solar. Essas considerações contribuem para a promoção da sustentabilidade energética na sociedade.

Agradecimentos

Gostaria de expressar um agradecimento especial ao Instituto Senai de Inovação em Energias Renováveis (ISI-ER) pelo financiamento essencial para a realização desta pesquisa, bem como ao Conselho Nacional de Pesquisa e Desenvolvimento (CNPq) pelo suporte proporcionado.

REFERÊNCIAS

- Bedaque, Paulo; Bretones, Paulo Sergio. Variação da posição de nascimento do Sol em função da latitude. *Revista Brasileira de Ensino de Física*, v. 38, 2016.
- Bocco, Mónica; Ovando, Gustavo; Sayago, Silvina. Desenvolvimento e avaliação de modelos de redes neurais para estimação da irradiação solar diária em Córdoba, Argentina. *Pesquisa Agropecuária Brasileira*, v. 41, n. 2, p. 179-184, 2006.
- Dike et al. 2018 Dike, H. U. *et al.* Unsupervised learning based on artificial neural network: A review. In: 2018 IEEE International Conference on Cyborg and Bionic Systems (CBS). [S.l.: s.n.], 2018. p. 322–327
- Driemel, Amelie et al. Baseline Surface Radiation Network (BSRN): structure and data description (1992–2017). *Earth System Science Data*, v. 10, n. 3, p. 1491-1501, 2018.
- Elminir, H. K., Areed, F. F., Elsayed, T. S. 2004. Estimation of solar radiation components incident on Helwan site using neural networks. *Solar Energy* 79. pp. 270–279.
- Haykin, S. *Neural networks principles and practices*. 2°. ed. Canada: Prentice Hall, 1998.
- Honaker, James; KING, Gary; BLACKWELL, Matthew. Amelia II: A program for missing data. *Journal of statistical software*, v. 45, p. 1-47, 2011.

- Martins, Fernando Ramos *et al.* Projeto SONDA–rede nacional de estações para coleta de dados meteorológicos aplicados ao setor de energia. In: Congresso Brasileiro de Energia Solar-CBENS. 2007.
- Moreira, Patricia Simone Palhana *et al.* Ciclo diário de variáveis meteorológicas nos biomas do estado de Mato Grosso. Revista Brasileira de Climatologia, v. 17, 2015.
- Nguyen, K.; Fookes, C.; Sridharan, S. Improving deep convolutional neural networks with unsupervised feature learning. 2015 IEEE International Conference on Image Processing (ICIP). Anais... Em: 2015 IEEE INTERNATIONAL CONFERENCE ON IMAGE PROCESSING (ICIP). set. 2015. Disponível em: <https://ieeexplore.ieee.org/document/7351206>. Acesso em: 20 nov. 2023
- Ohmura, Atsumu *et al.* Baseline Surface Radiation Network (BSRN/WCRP): New precision radiometry for climate research. Bulletin of the American Meteorological Society, v. 79, n. 10, p. 2115-2136, 1998.
- Pereira, E. B. *et al.*, Atlas brasileiro de energia solar. 2.ed. São José dos Campos: INPE, 2017. 80p. Disponível em: <http://doi.org/10.34024/978851700089>
- Pereira, Enio Bueno; Colle, S. A. A energia que vem do Sol. Ciência e Cultura, v. 22, n. 130, p. 24-35, 1997.
- J. Mubiru, E.J.K.B. Banda. 2007. Estimation of monthly average daily global solar irradiation using artificial neural networks. Solar Energy 82. pp. 181–187.
- Prechelt, L. *et al.* Proben1: A set of neural network benchmark problems and benchmarking rules. Citeseer Sivanandam e Deepa 2006 SIVANANDAM, S.; DEEPA, S. Introduction to neural networks using Matlab 6.0. [S.l.]: Tata McGraw-Hill Education, 2006.
- Silva, Enid Rocha Andrade da Coordenadora. Agenda 2030: ODS-Metas nacionais dos objetivos de desenvolvimento sustentável. 2018.
- Rodrigues, Daniele T. *et al.* Imputation of precipitation data in northeast Brazil. Anais da Academia Brasileira de Ciências, v. 95, p. e20210737, 2023.
- Sumer, Ö.; Dencker, T.; Ommer, B. Self-supervised Learning of Pose Embeddings from Spatiotemporal Relations in Videos. arXiv, , 7 ago. 2017. Disponível em: <http://arxiv.org/abs/1708.02179>. Acesso em: 20 nov. 2023.
- Ohmura, Atsumu *et al.* Baseline Surface Radiation Network (BSRN/WCRP): New precision radiometry for climate research. Bulletin of the American Meteorological Society, v. 79, n. 10, p. 2115-2136, 1998.

PREDICTING GLOBAL RADIATION USING ARTIFICIAL NEURAL NETWORK MODELS

Abstract. *Studies involving solar availability for renewable projects are becoming increasingly important. By looking at the potential that projects can generate, it is possible to optimize decisions in the photovoltaic sector through various horizons in the scenario of mitigating predictive climate change. The National Institute for Space Research (INPE) created the SONDA Network to systematize and organize tower data for renewable energy studies. The cities of Joinville (SC) and Natal (RN) were selected for forecasts at different time scales. With regard to forecasting, the Artificial Neural Networks model was implemented to carry out a diagnosis of solar energy based on periods of lower insolation, based on the diurnal cycle. By analyzing the data that was created for this purpose, the results revealed excellent accuracy with a mean absolute percentage error (MAPE) of 0.0032% in the one-hour ahead forecast for Natal (RN), and a value of 0.55% for Joinville (SC). The tool can therefore be used to optimize the reliability of solar energy forecasting.*

Keywords: *Global Radiation, Neural Networks, Solar Energy*