

Avaliação de Topologias de Redes Neurais Artificiais para Previsão de Potência e Energia Fotovoltaica

Gustavo Henrique de Paula Santos,* Paul Junior Zapana Vargas,*
Elmer Pablo Tito Cari,* Moisés Carlos Tanca Villanueva**

* Departamento de Engenharia Elétrica e Computação,
Universidade de São Paulo - USP, São Carlos, Brasil
(e-mails: gustavohenriquesantos@usp.br, paulvargas0894@usp.br, elmerpab@sc.usp.br)

** Departamento de Ingeniería Eléctrica,
Universidad Nacional de San Agustín de Arequipa - UNSA, Arequipa, Peru
(e-mail: mtanca@unsa.edu.pe)

Abstract: Renewable energy sources such as solar photovoltaic have grown every year. Although beneficial, the integration of photovoltaic solar generation systems can cause problems due to meteorological variations that lead to uncertainties in energy production. In this sense, this work evaluated three artificial neural networks topologies to improve the forecasting of photovoltaic power and energy. The results show that the topology with 5 neurons in the hidden layer was able to predict the photovoltaic energy with an error of less than 1.3% in relation to the measured energy.

Resumo: As fontes renováveis de energia como a solar fotovoltaica têm crescido a cada ano. Embora benéfica, a integração de sistemas de geração solar fotovoltaica pode causar problemas devido às variações meteorológicas que levam à incertezas na produção de energia. Nesse sentido, este trabalho avaliou três topologias de redes neurais artificiais para melhorar a previsão de potência e energia fotovoltaica. Os resultados mostram que a topologia com 5 neurônios na camada escondida conseguiu prever a energia fotovoltaica com erro inferior à 1,3% em relação a energia medida.

Keywords: Renewable sources; Photovoltaic power; Photovoltaic energy; Power forecasting; PV system; Artificial neural networks.

Palavras-chaves: Fontes renováveis; Potência fotovoltaica; Energia fotovoltaica; Previsão de potência; Sistema fotovoltaico; Redes neurais artificiais.

1. INTRODUÇÃO

A energia solar se tornou uma das fontes de energia renovável mais populares devido às vantagens de ser um recurso abundante, gratuito, limpo e sem transporte (Wang et al., 2019). Em consonância com estas vantagens, a diminuição dos custos dos sistemas solares fotovoltaicos aumentaram sua competitividade em relação a outras tecnologias de geração de energia que resultou, nos últimos anos, em aumento da capacidade global instalada (Visser et al., 2022). A natureza intermitente da energia solar desafia a capacidade de integração e confiabilidade da rede necessitando de técnicas e soluções complexas, pois a disponibilidade e intermitência do recurso solar depende do perfil meteorológico específico do local de instalação do sistema e essa irregularidade na geração causa impactos na rede elétrica (Pazikadin et al., 2020).

O fator que mais impacta na geração de energia fotovoltaica é a irradiação solar, entretanto temperatura e umi-

dade do ar também são relevantes, e, devido à influência dessas variáveis, a potência fotovoltaica pode alterar de um local para outro sendo necessário analisar usinas instaladas em diferentes localizações geográficas, o que torna estes parâmetros com características flutuantes e a configuração de um modelo único de previsão bastante complexa (Radicioni et al., 2021). A previsão fotovoltaica tem recebido destaque especial para as condições reais de operação dos sistemas de energia que são caracterizados pelas oscilações dos recursos energéticos e mudanças comportamentais dos consumidores (Oprea and Bâra, 2020). Como a eletricidade ainda não pode ser armazenada massivamente usando as tecnologias atuais os operadores da rede devem equilibrar a oferta e a demanda a cada momento (Bot et al., 2021), desta forma existe a necessidade de prever a produção de energia a fim de atender determinada demanda, desvios entre o que foi previsto e o que foi gerado causam problemas técnicos e econômicos.

Neste contexto, a previsão de energia para geração fotovoltaica tornou-se uma das principais ferramentas tecnológicas para melhorar a qualidade da programação operacional e reduzir as reservas de capacidade ociosa (Wang

* Agradecimentos à FAPESP pelo financiamento parcial deste trabalho, processo 2017/09208-4 e 2017/50389-2 e à UNSA pelo apoio de pesquisa aplicada, processo IBA-0043-2017 UNSA.

et al., 2019). Várias técnicas têm sido utilizadas para o desenvolvimento de sistemas de previsão fotovoltaicos como modelos físicos, estatísticos, inteligência artificial e modelos híbridos (Ahmed et al., 2020). Antonanzas et al. (2016) cita em sua revisão sobre o tema, que Redes Neurais Artificiais (RNA), do inglês *Artificial Neural Network (ANN)*, é a técnica mais utilizada para este fim atingindo boa performance e precisão. A Figura 1 relaciona algumas técnicas de previsão aventadas no trabalho de Antonanzas et al. (2016) e seus respectivos percentuais de utilização.

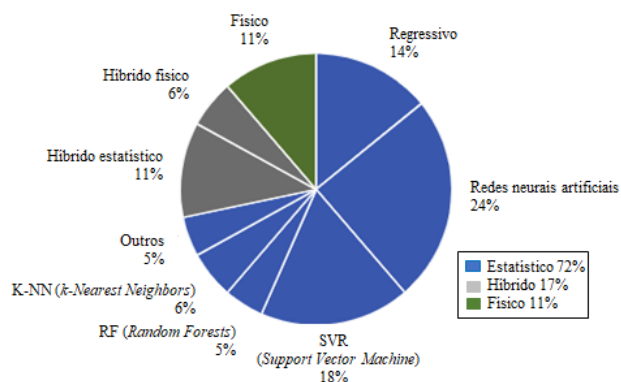


Figura 1. Exemplos de técnicas de previsão fotovoltaica e percentual de utilização (Antonanzas et al., 2016).

Corroborando com Antonanzas et al. (2016), Das et al. (2018) citam que a aplicação de RNA tem sido usada em diferentes aplicações de previsão, incluindo, com sucesso, a previsão de geração de energia fotovoltaica devido à não linearidade dos dados meteorológicos utilizados no processo de previsão.

As previsões de geração de energia fotovoltaica são classificadas de acordo com o horizonte de tempo, que é o período de tempo futuro em que a previsão de potência é feita (Antonanzas et al., 2016; Ahmed et al., 2020). Na literatura não há valores padronizados, desta forma os horizontes de tempo podem ser classificados conforme citam Antonanzas et al. (2016) e Ahmed et al. (2020):

- *Intra-hour*: Horizontes de tempo estabelecidos dentro do período de uma hora que cobre previsões de poucos segundos à 1 hora à frente.
- *Intra-day*: Horizontes de tempo estabelecidos dentro do período de um dia que cobre previsões de 1 à 6 horas à frente.
- *Six-hours to day ahead*: Horizontes de tempo estabelecidos dentro do período de 48 horas que cobre previsões de 6 à 48 horas à frente.
- *Two days ahead or longer*: Horizontes de tempo estabelecidos para períodos maiores de 48 horas.

Cada horizonte de tempo atende a um fim operacional específico. Dralus, Grzegorz et al. (2018) relatam que as previsões no horizonte de 24 horas são realizadas para as necessidades de controle e planejamento de fontes renováveis de energia subsidiando os operadores de compra e venda de energia com as previsões do volume diário da produção de energia que são suficientes para realizar a comercialização.

No Brasil a geração de energia fotovoltaica está em franca expansão. A capacidade instalada da micro e minigeração distribuída aumentou significativamente após a resolução normativa nº 482/2012 partindo de 21,9 MW em 2015 para 10 GW em 2022 (Martins et al., 2022) (ABSOLAR, 2022). Leilões de energia foram realizados a fim de aumentar o portfólio de energias renováveis como o leilão de Energia Nova A-5, em 2021, que viabilizou 40 usinas fotovoltaicas com potência total de 860 MW (ANEEL, 2022).

A estrutura brasileira para comercialização de energia está dividida em duas categorias, mercado cativo e mercado livre. Os consumidores do mercado cativo adquirem obrigatoriamente energia da distribuidora local sendo as tarifas reguladas pela Agência Nacional de Energia Elétrica (ANEEL) sem a possibilidade de negociação. Os consumidores do mercado livre podem escolher e contratar livremente seus fornecedores além de negociar as tarifas de energia. Neste último mercado, os consumidores são classificados como (i) consumidores livres que podem contratar energia de qualquer fonte e, (ii) consumidores especiais que obrigatoriamente devem contratar energia de fontes incentivadas, como a solar fotovoltaica (ABRACEEL, 2019).

No mercado livre as contratações de compra e venda de energia são efetuadas pela Câmara de Comercialização de Energia Elétrica (CCEE) que também é responsável por aferir os montantes gerados e consumidos. Neste cenário pode ocorrer do produtor gerar mais ou menos do que previsto em contrato, ou ainda, do consumidor demandar uma quantidade de energia diferente da contratada. Nestes casos as diferenças são liquidadas no Mercado de Curto-Prazo (MCP) e os valores revertidos em créditos ou débitos. No MCP a energia é negociada no Preço da Liquidação das Diferenças (PLD) calculado pela CCEE diariamente para cada hora do dia seguinte (CCEE, 2022). Por este motivo, torna-se fundamental o desenvolvimento de métodos precisos para previsão de potência e energia fotovoltaica.

Neste trabalho foi realizado o desenvolvimento de um algoritmo para previsão de potência e energia elétrica de sistemas fotovoltaicos com horizonte de tempo *intra-hour* utilizando Redes Neurais Artificiais a partir de medidas de uma microssina na cidade de São Carlos/SP. Foram avaliadas topologias com 2, 5 e 10 neurônios na camada escondida. A estrutura deste trabalho está dividida da seguinte forma: na Seção 2 e 3 são apresentadas as características e configurações da RNA. Na Seção 4 são apresentados os dados para implementação e as informações da microssina fotovoltaica onde foram obtidas as amostras. A Seção 5 traz os resultados das implementações e por fim a Seção 6 conclui o trabalho.

2. REDES NEURAIIS ARTIFICIAIS (RNA)

As RNAs têm sido empregadas com sucesso por muitos pesquisadores como uma técnica de Inteligência Artificial popular na resolução de problemas não lineares complexos provando sua eficácia como ferramenta estimativa para prever saídas desejadas por meio de entradas sem relação reconhecível (Ehsan et al., 2017). A RNA é um sistema distribuído em paralelo que tenta replicar o modelo de conectividade e processamento biológico de um neurônio do cérebro (Pazikadin et al., 2020). A arquitetura de uma

RNA genérica consiste em camada de entrada, camada neural escondida e camada de saída que são compostas por um conjunto de neurônios artificiais conectados entre si por meio de pesos ajustáveis (Radicioni et al., 2021). Dentre as diversas arquiteturas disponíveis em RNA destacam-se, para os sistemas fotovoltaicos, as redes Perceptron Multicamadas (PMC) como pode ser visto nos trabalhos de Mellit and Pavan (2010), Ehsan et al. (2017), Cortés et al. (2020), Lopes et al. (2021) e Silva et al. (2022).

A rede PMC é uma RNA composta por uma camada de entrada, camadas ocultas e uma camada de saída. Esta rede ajusta seus parâmetros internos para criar um modelo que represente o comportamento do sistema. Quando as respostas da rede, em relação às entradas recebidas, são as mesmas esperadas, considera-se que ela aprendeu, ou seja, alcançou um bom grau de generalização para o problema. A etapa de aprendizado da RNA é conhecida como processo de treinamento, durante o qual os pesos sinápticos da rede são alterados para ajustar sua saída a fim de aproximar a resposta esperada pelo sistema. *Backpropagation* e *Levenberg-Maquardt* são os algoritmos mais comumente utilizados na fase de treinamento e permitem a aplicação do aprendizado supervisionado a qual, um conjunto de dados, com amostras de entradas e saídas desejadas, são fornecidos à rede (Lopes et al., 2021).

A RNA utilizada neste trabalho é a PMC com entradas atrasadas no tempo (do inglês *TDNN - Time Delay Neural Network*) cujos detalhes da aplicação podem ser vistos a partir do item 3. Os conceitos gerais da rede PMC e seus detalhes práticos podem ser vistos em Silva et al. (2016).

3. CONFIGURAÇÃO DA REDE PMC

As configurações da rede PMC, para previsão de potência e energia deste trabalho, foram baseadas na investigação de 3 topologias candidatas, todas com apenas 1 camada neural escondida que varia em número de neurônios, 5 variáveis de entrada e 1 variável de saída conforme mostra a Tabela 1. A escolha da quantidade de neurônios, em cada topologia candidata, foi baseada nos trabalhos de Bot et al. (2021), Lopes et al. (2021) e Radicioni et al. (2021).

Tabela 1. Topologia candidatas.

Topologia	Camada de entrada	Camada neural escondida	Camada neural de saída
1	5 variáveis de entrada (x_1, x_2, x_3, x_4, x_5)	2 neurônios (n_1)	1 neurônio (y_1)
2	5 variáveis de entrada (x_1, x_2, x_3, x_4, x_5)	5 neurônios (n_1)	1 neurônio (y_1)
3	5 variáveis de entrada (x_1, x_2, x_3, x_4, x_5)	10 neurônios (n_1)	1 neurônio (y_1)

Para cada topologia foram executados 3 treinamentos para buscar entre eles o que obtiver os melhores resultados em relação ao erro quadrático médio (E_M) e ao desvio entre a energia prevista e a medida, pois as matrizes de pesos sinápticos iniciam com valores aleatórios entre 0 e 1 a cada novo treinamento, permitindo assim resultados diferentes. Os parâmetros utilizados no treinamento das topologias

candidatas da rede PMC estão relacionados na Tabela 2. O algoritmo converge exclusivamente em função do alcance da precisão (ε) entre duas épocas consecutivas, de modo que não foram limitados o número de épocas.

Tabela 2. Parâmetros da rede PMC.

Parâmetro	Valor / Função
Taxa de aprendizagem (n)	0,1
Precisão (ε)	10^{-7}
Limiar de ativação (θ)	-1
Função de ativação	$g(u) = 1/(1 + e^{-b.u})$
Ordem de predição (n_p)	3

3.1 Topologia da rede

A estrutura final das topologias candidatas da rede PMC proposta neste trabalho é ilustrada na Figura 2 considerando *TDNN* com $n_p = 3$ e 5 variáveis de entrada (x_1, x_2, x_3, x_4 e x_5) que totalizam 15 entradas e 1 saída (y_1).




Figura 2. Topologia da rede PMC *TDNN*.

3.2 Conjunto de dados

O conjunto de dados é composto por 7.080 amostras de cada variável sendo 120 amostras por dia obtidas em 59 dias correspondente aos meses de Fevereiro e Março de 2022. A montagem do conjunto de dados de treinamento e validação foi executada considerando $n_p = 3$. Para o processo de treinamento, o número de amostras (N) de cada variável é de 6.720 que corresponde a 95% do conjunto de dados, ou seja, 56 dias. Para validação o número de amostras (N) é de 360 que corresponde a 5% do conjunto de dados, ou seja, 3 dias. Embora seja recomendado uma relação próxima de 70% para treinamento e 30% para validação, as amostras foram divididas desta forma para atender o horizonte de tempo *Intra-hour* aplicável no MCP com previsão 15 minutos a frente ($n_p = 3$ e amostras

coletadas a cada 5 minutos = $3 \times 5 = 15$) validados em 3 dias. A Tabela 3 mostra a montagem dos conjuntos de dados em *TDNN* onde x_n representa a n -ésima variável.

3.3 Sequência metodológica

A sequência do desenvolvimento das etapas das fases de treinamento e validação podem ser vistas na Figura 3 que foram baseadas em Silva et al. (2016).

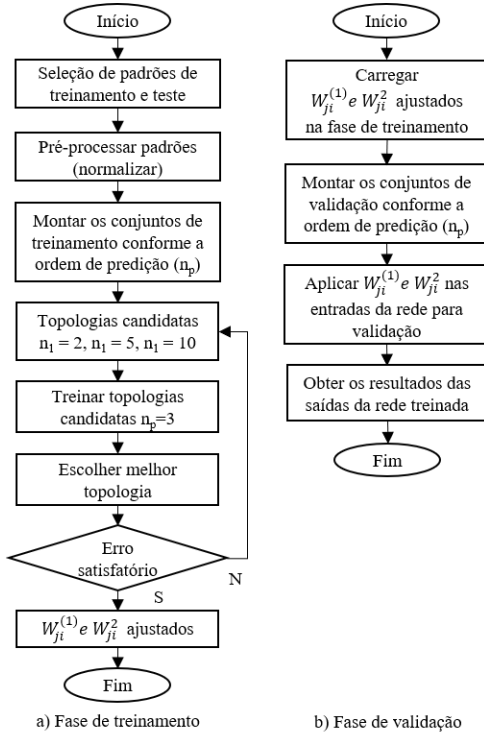


Figura 3. Fluxograma para a sequência metodológica de treinamento e validação da rede PMC *TDNN*.

Na fase de treinamento (Fig.3a) o processo inicia-se com a seleção dos padrões (entradas) de treinamento conforme descrito no item 4.2. Em seguida é feita a normalização destes dados para um domínio proporcional, delimitado pelos respectivos valores máximos e mínimos conforme Equação (1), onde x_{norm} é o valor normalizado da variável, x é a variável que será normalizada, x_{max} é o maior valor da variável dentro do conjunto de amostras e x_{min} é o menor valor da variável dentro do conjunto de amostras.

$$x_{norm} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (1)$$

Após a normalização, são montados os conjuntos de padrões de amostra para treinamento conforme a ordem de predição adotada (n_p) e Tabela 3, para que em seguida os dados sejam submetidos ao treinamento considerando as 3 topologias descritas na Tabela 1. O processo finaliza com a escolha da topologia que melhor satisfaz a precisão (ε) frente ao erro calculado. O treinamento da rede PMC é composto por duas fases respectivamente *Forward* e *Backward*. A fase *Forward* tem por objetivo obter as respostas da rede, a fase *Backward* tem por objetivo ajustar

os pesos e limiares dos neurônios (Silva et al., 2016). Considerando as matrizes de pesos sinápticos $W_{ji}^{(1)}$ e $W_{ji}^{(2)}$ de cada camada (ilustrada na Figura 2) iniciada com valores aleatório entre 0 e 1 temos na fase *Forward* a seguinte modelagem matemática conforme Equações de (2) à (5).

- Vetores de entrada:

$$I_j^{(1)} = \sum_{i=0}^{15} W_{ji}^{(1)} \cdot x_i \quad (2)$$

$$I_j^{(2)} = \sum_{i=0}^{n_1} W_{ji}^{(2)} \cdot Y_i^{(1)} \quad (3)$$

- Vetores de Saída:

$$Y_j^{(1)} = g(I_j^{(1)}) \quad (4)$$

$$Y_j^{(2)} = g(I_j^{(2)}) \quad (5)$$

O funcional g representa a função de ativação logística relacionada na Tabela 2. Os desvios entre a saída desejada d e a saída calculada y são obtidos por meio do erro quadrático $E(k)$ e erro quadrático médio E_M conforme Equações (6) e (7) a seguir, sendo k a k -ésima amostra de treinamento.

$$E(k) = \frac{1}{2} (d_j(k) - Y_j^{(2)}(k))^2 \quad (6)$$

$$E_M = \frac{1}{N} \sum_{k=1}^N E(k) \quad (7)$$

Na fase *Backward* temos a atualização das matrizes de pesos sinápticos $W_{ji}^{(1)}$ e $W_{ji}^{(2)}$ frente aos erros, baseado no Método do Gradiente Descendente e Regra da Diferenciação em Cadeia conforme as Equações de (8) à (11).

- Atualização de $W_{ji}^{(2)}$:

$$\delta_j^{(2)} = (d_j - Y_j^{(2)}) \cdot g'(I_j^{(2)}) \quad (8)$$

$$W_{ji}^{(2)} = W_{ji}^{(2)} + \eta \cdot \delta_j^{(2)} \cdot Y_i^{(1)} \quad (9)$$

- Atualização de $W_{ji}^{(1)}$:

$$\delta_j^{(1)} = \sum_{k=1}^{n_1} \delta_j^{(2)} \cdot W_{ji}^{(2)} \cdot g'(I_j^{(1)}) \quad (10)$$

$$W_{ji}^{(1)} = W_{ji}^{(1)} + \eta \cdot \delta_j^{(1)} \cdot x_i \quad (11)$$

Na fase de validação, conforme Figura 3b, o processo inicia-se com a apresentação das matrizes de pesos sinápticos de $W_{ji}^{(1)}$ e $W_{ji}^{(2)}$ que foram ajustadas na fase de treinamento. Em seguida são montados os conjuntos dos padrões de amostras (entradas) para validação conforme a ordem de predição adotada (n_p). Logo depois as entradas são submetidas a rede treinada, e por fim são obtidas as

Tabela 3. Montagem do conjunto de dados.

Amostras	Entradas									Saída
	$x_1^{(t-1)}$	$x_1^{(t-2)}$	$x_1^{(t-3)}$	$x_2^{(t-1)}$	$x_2^{(t-2)}$	$x_2^{(t-3)}$	$x_n^{(t-1)}$	$x_n^{(t-2)}$	$x_n^{(t-3)}$	y_1^t
$t=4$	x_1^3	x_1^2	x_1^1	x_2^3	x_2^2	x_2^1	x_n^3	x_n^2	x_n^1	y_1^4
$t=5$	x_1^4	x_1^3	x_1^2	x_2^4	x_2^3	x_2^2	x_n^4	x_n^3	x_n^2	y_1^5
$t=6$	x_1^5	x_1^4	x_1^3	x_2^5	x_2^4	x_2^3	x_n^5	x_n^4	x_n^3	y_1^6
...
$t=N$	$x_1^{(N-1)}$	$x_1^{(N-2)}$	$x_1^{(N-3)}$	$x_2^{(N-1)}$	$x_2^{(N-2)}$	$x_2^{(N-3)}$	$x_n^{(N-1)}$	$x_n^{(N-2)}$	$x_n^{(N-3)}$	y_1^N

saídas da rede. No processo de validação tem-se apenas a fase *Forward* por meio das Equações de (2) à (5).

4. DADOS PARA IMPLEMENTAÇÃO

4.1 Microssistema e estação meteorológica

Os dados¹ utilizados para o processo de treinamento e validação da rede supracitada foram obtidos da planta de microgeração fotovoltaica denominada Garagem Solar (latitude -22.006639, longitude -47.897514) cujos módulos cobrem duas vagas do estacionamento da USP São Carlos que possui uma estação de monitoramento meteorológico anexo ao sistema de geração. O sistema de microgeração tem 4,5 kWp de potência sendo composto por 12 módulos fotovoltaicos policristalinos de 375 Wp, da fabricante AstroSemi, divididos em 2 circuitos com 6 módulos cada. Os módulos estão conectados a um inversor DC/AC da WEG de 4 kW. A estação de monitoramento meteorológico é composta por um piranômetro modelo CS300 do fabricante Campbell Scientific e dois sensores de temperatura, modelo SA2C-RTD 3 100 B 200 do fabricante Ômega interligados a um *Data Logger* modelo CR300-wifi do fabricante Campbell Scientific. As informações do *Data Logger* são enviadas a um computador via *Wifi* e rede ethernet. As informações do inversor são obtidas na internet, na página de monitoramento da *Fusion Solar*. A Figura 4 mostra o esquema do sistema de microgeração e de monitoramento meteorológico da Garagem Solar na USP São Carlos.

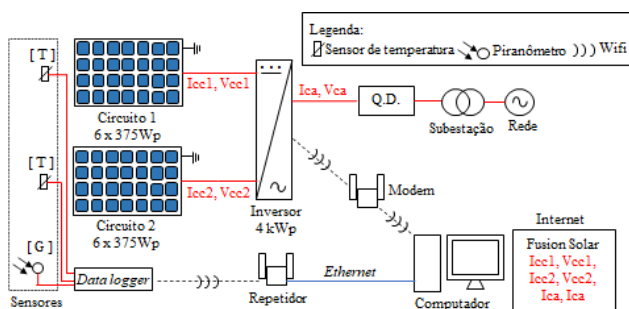


Figura 4. Sistema de microgeração e monitoramento meteorológico da Garagem Solar na USP São Carlos.

4.2 Dados de entrada e saída

As entradas para os modelos de previsão têm influência direta na sua precisão sendo fator chave na determinação

¹ Disponível em: www.sel.eesc.usp.br/cursosolar/?page_id=3028.

do desempenho do modelo. As entradas para sistemas fotovoltaicos são principalmente parâmetros meteorológicos como radiação solar, temperatura atmosférica, temperatura do módulo, velocidade do vento, umidade, pressão barométrica entre outros (Ahmed et al., 2020). Em Bot et al. (2021), por exemplo, foram utilizadas 4 variáveis para o processo de treinamento da RNA sendo irradiância, temperatura do módulo, temperatura atmosférica do ar e potência c.c., em Radicioni et al. (2021) as variáveis utilizadas foram hora, irradiância, umidade, temperatura e potência, em Lopes et al. (2021) as variáveis utilizadas foram temperatura, irradiância, umidade, velocidade do vento, ponto de orvalho e potência. Tomando os trabalhos acima descritos como referência, pode-se observar que os parâmetros meteorológicos (irradiação solar e temperatura) são as entradas mais utilizadas em estudos de previsão de potência. Poucos trabalhos utilizam parâmetros elétricos nas entradas do modelo de previsão, desta forma, este trabalho pretende preencher esta lacuna, utilizando parâmetros elétricos (tensão e corrente) disponibilizados pelo inversor de frequência. Os dados de entrada e saída para o processo de treinamento e validação da rede deste estudo são referentes ao circuito 1, da garagem solar, ilustrado na Figura 4 e relacionados na Tabela 4.

Tabela 4. Dados de entrada e saída.

Descrição	Unidade	Variável	Tipo de dado
Hora da medição	h	x_1	Entrada
Temperatura dos módulos	$^{\circ}C$	x_2	Entrada
Irradiância solar	W/m^2	x_3	Entrada
Corrente circuito 1 (c.c.)	A	x_4	Entrada
Tensão circuito 1 (c.c.)	V	x_5	Entrada
Potência circuito 1 (c.c.)	W	y_1	Saída

Os dados de treinamento e validação são de todos os dias dos meses de Fevereiro (28 dias) e Março (31 dias) de 2022, que são meses tipicamente chuvosos na região de instalação do sistema fotovoltaico, caracterizados por precipitações de curta-duração e movimento intenso de nuvens. Foram coletadas amostras de 5 em 5 minutos para cada variável de entrada e saída, totalizando 120 amostras por dia por variável, sendo a primeira amostra obtida às 7h05 e à última amostra às 17h.

5. RESULTADOS DA IMPLEMENTAÇÃO

Os resultados do processo de treinamento e validação são apresentados na Tabela 5. Na topologia 1 os 3 treinamentos produziram o mesmo valor de $E_M = 0,0120$ sendo que a

menor quantidade de épocas foi alcançada no 2º treinamento e o menor desvio entre a energia prevista e a medida foi aferida na validação do 3º treinamento. Na topologia 2 o melhor resultado foi obtido no 3º treinamento efetuado, com valor de $E_M = 0,0116$ em 149 épocas, entretanto o menor desvio foi alcançado na validação do 2º treinamento. Na topologia 3 o melhor resultado foi obtido no 1º e 2º treinamento, com valor de $E_M = 0,0121$, entretanto o 2º treinamento atingiu a menor quantidade de épocas e o menor desvio na validação.

Tabela 5. Resultados da fase de treinamento e validação.

Top.	Trein.	E_M	Épocas	Energia prevista (PU)	Energia medida (PU)	Desvio (%)
1	1	0,0120	522	3,4739	3,5500	-2,14
	2	0,0120	488	3,4645	3,5500	-2,41
	3	0,0120	562	3,4754	3,5500	-2,10
2	1	0,0117	170	3,4974	3,5500	-1,48
	2	0,0117	143	3,5068	3,5500	-1,22
	3	0,0116	149	3,4861	3,5500	-1,80
3	1	0,0121	18	3,6715	3,5500	+3,42
	2	0,0121	14	3,6386	3,5500	+2,50
	3	0,0122	16	3,6972	3,5500	+4,15

A Figura 5 mostra, na fase de treinamento, o comportamento do E_M em relação ao número de épocas dos melhores resultados de cada topologia. A topologia 1 apresenta o menor E_M inicial em comparação com as outras topologias e durante a evolução do treinamento a rede performa a maior quantidade de épocas para convergir frente à precisão (ϵ) requerida. A topologia 2 têm o E_M inicial e a quantidade de épocas com valores intermediários entre as topologias 1 e 3, percebe-se que uma diminuição acentuada de E_M acontece em poucas épocas no início do processamento, entretanto, a convergência, após esta diminuição, despende mais épocas. A topologia 3 têm o maior E_M inicial e a menor quantidade de épocas até a convergência, percebe-se, nesta topologia, que uma queda acentuada de E_M também acontece nas primeiras épocas de treinamento.

A quantidade de épocas é proporcional ao tempo de processamento do algoritmo. A topologia 3 apresenta a menor quantidade de épocas até a convergência com tempo de processamento de 1,911 s, seguida da topologia 2 com 13,6549 s e por fim a topologia 1 com 40,6262 s, utilizando computador Intel Core i5-7400 3 GHz com 8 GB de RAM. Dentre todas as topologias investigadas o melhor resultado foi obtido com a topologia 2 (3 camadas: camada de entrada com 15 variáveis; camada neural escondida com 5 neurônios e camada neural de saída com 1 neurônio) que alcançou, no treinamento, os menores valores de E_M , e na validação, os menores desvios entre a energia prevista e a energia medida conforme pode ser visto na Tabela 5. A previsão de energia feita pela RNA na topologia 2 é menor que a energia medida com desvios de -1,22 à -1,8 %. A topologia 1 obteve o segundo melhor resultado, apresentando desvios de -2,1 à -2,41 %. A topologia 3 obteve o pior resultado de modo que a energia prevista pela RNA é maior que a energia medida apresentando desvios de 2,5 à 4,15 %. Embora exista diferenças entre

as topologias todas elas apresentaram desvios menores que 5% entre a energia prevista e a medida.




Figura 5. Melhores treinamentos: E_M x Épocas.

A Figura 6 mostra o perfil de potência medido no sistema e o perfil previsto pela RNA no 2º treinamento da topologia 2 para os 3 dias de validação no intervalo das 7h05 às 17h. Nota-se que apesar das oscilações, a RNA consegue acompanhar o perfil de geração imposto pela intermitência climática que provoca picos e declínios de potência, entretanto nos picos de geração a RNA não consegue atingir os valores próximos dos reais.

As Figuras 7 e 8 mostram, para intervalo das 7h05 às 17h nos 3 dias de validação, o perfil de potência previsto e medido para o 2º treinamento das topologia 1 e 3 respectivamente. Nota-se, em ambas figuras, que também há variação entre a geração prevista e medida devido às intermitências climáticas. Na topologia 1, Figura 7, é possível perceber que a RNA não consegue acompanhar o declínio de potência do dia 2 e 3 em torno das 13h em comparação com as outras topologias. Nesta duas topologias a RNA também não consegue prever os picos de potência. Pressupõe-se, para os picos de potência, que as entradas utilizadas nas 3 topologias não são suficientes para fornecer à RNA as informações necessárias para prever oscilações abruptas na geração de energia causada pelo sombreamento que as nuvens fazem nos módulos, deste modo, a RNA não consegue um grau de generalização adequado para os picos de potência pois não possui a inércia necessária para a previsão.

Nas Figuras 6, 7 e 8 a energia elétrica é calculada pela área abaixo da curva de potência tanto para a previsão realizada pela RNA quanto para a medida. É possível observar, em todas as topologias, que há uma compensação entre o previsto pela RNA e o medido, de modo que a previsão ora extrapola ora fica abaixo dos valores reais de geração permitindo então, entre ganhos e perdas, atingir os desvios máximos abaixo de 5 % independente dos picos de potência. Apesar desta boa performance a rede não seria adequada para previsão de potência instantânea, mas é capaz de realizar satisfatoriamente a previsão de energia com horizonte *intra-hour*.




Figura 6. Topologia 2 - Validação do treinamento 2: perfil de potência previsto e medido x horas (dias 1, 2 e 3).

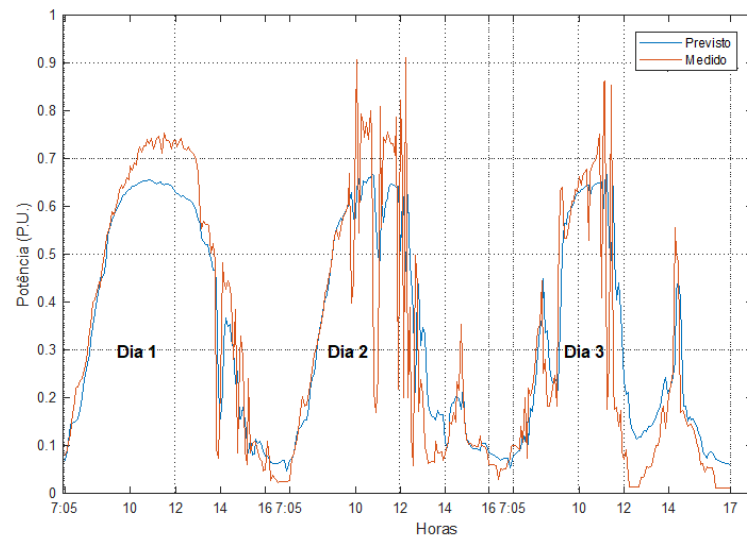


Figura 7. Topologia 1 - Validação do treinamento 2: perfil de potência previsto e medido x horas (dias 1, 2 e 3).




Figura 8. Topologia 3 - Validação do treinamento 2: perfil de potência previsto e medido x horas (dias 1, 2 e 3).

6. CONCLUSÕES

O uso da rede PMC em TDNN se mostrou adequada para previsões de potência e energia em sistemas fotovoltaicos, entretanto nenhuma das topologias candidatas conseguiu prever satisfatoriamente picos acentuados de potência. A topologia com apenas 1 camada escondida é eficiente e com rápido processamento atingindo na fase de validação desvio entre a energia prevista e medida inferior à 5 % além de apresentar bom ajuste da curva de potência exceto por seus picos. O trabalho indica que resultados satisfatórios são alcançados utilizando quantidade apropriada de neurônios na camada escondida. A topologia 2, em que foi arbitrado 5 neurônios na camada neural escondida, alcançou os melhores resultados e poderia subsidiar, inicialmente, agentes do mercado de energia para as tomadas de decisões quanto a produção e venda de energia futura.

TRABALHOS FUTUROS

Espera-se adicionar, como entrada candidata à RNA, sensores para detecção de nuvens como em Bin Mohd Rashid et al. (2021), pressupondo melhora na previsão dos picos de potência pois o sensor sinalizaria antecipadamente provável aumento ou declínio abrupto de potência em função da diminuição da irradiância causada pelo sombreamento de nuvens nos módulos fotovoltaicos. Além disso o método desenvolvido será testado em usinas de maior porte tanto da USP-São Carlos/Brasil como da UNSA-Arequipa/Peru.

REFERÊNCIAS

- ABRACEEL (2019). *Cartilha Mercado Livre de Energia Elétrica*. Abraceel. [Online; accessed 08-08-2022].
- ABSOLAR (2022). Panorama da solar fotovoltaica no Brasil e no mundo. <https://www.absolar.org.br/mercado/infografico/>. [Online; accessed 20-04-2022].
- Ahmed, R., Sreeram, V., Mishra, Y., and Arif, M. (2020). A review and evaluation of the state-of-the-art in pv solar power forecasting: Techniques and optimization. *Renewable and Sustainable Energy Reviews*, 124, 109792.
- ANEEL (2022). Leilão: ANEEL homologa resultado do leilão de geração A-5 de setembro de 2021. <http://encurtador.com.br/pu0VY>. [Online; accessed 29-03-2022].
- Antonanzas, J., Osorio, N., Escobar, R., Urraca, R., Martinez-de Pison, F.J., and Antonanzas-Torres, F. (2016). Review of photovoltaic power forecasting. *Solar Energy*, 136, 78–111.
- Bin Mohd Rashid, M.S.R., Zheng, J., Sng, E., Rajendhiran, K.M., Ye, Z., and Lim, L.H.I. (2021). An enhanced cloud segmentation algorithm for accurate irradiance forecasting. *Solar Energy*, 221, 218–231. doi:<https://doi.org/10.1016/j.solener.2021.03.061>. URL <https://www.sciencedirect.com/science/article/pii/S0038092X21002498>.
- Bot, K., Ruano, A., and Ruano, M.d.G. (2021). Short-term forecasting photovoltaic solar power for home energy management systems. *Inventions*, 6(1).
- CCEE (2022). Conceito de preços. <https://www.ccee.org.br/web/guest/precos/conceitos-precos>. [Online; accessed 29-03-2022].
- Cortés, B., Tapia Sánchez, R., and Flores, J.J. (2020). Characterization of a polycrystalline photovoltaic cell using artificial neural networks. *Solar Energy*, 196, 157–167.
- Das, U.K., Tey, K.S., Seyedmahmoudian, M., Mekhilef, S., Idris, M.Y.I., Van Deventer, W., Horan, B., and Stojcevski, A. (2018). Forecasting of photovoltaic power generation and model optimization: A review. *Renewable & Sustainable Energy Reviews*, 81(1), 912–928.
- Dralus, Grzegorz, Dec, Grzegorz, and Mazur, Damian (2018). One day ahead forecasting of energy generating in photovoltaic systems. *ITM Web Conference*, 21, 00023.
- Ehsan, R.M., Simon, S.P., and Venkateswaran, P.R. (2017). Day-ahead forecasting of solar photovoltaic output power using multilayer perceptron. *Neural Computing & Applications*, 28(12), 3981–3992.
- Lopes, S.M.A., Cari, E.P.T., and Hajimirza, S. (2021). A Comparative Analysis of Artificial Neural Networks for Photovoltaic Power Forecast Using Remotes and Local Measurements. *Journal of Solar Energy Engineering*, 144(2).
- Martins, V.A., Branco, D.A.C., and Hallack, M.C.M. (2022). Economic effects of micro- and mini-distributed photovoltaic generation for the brazilian distribution system. *Energies*, 15(3).
- Mellit, A. and Pavan, A.M. (2010). 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), 807–821.
- Oprea, S.V. and Bâra, A. (2020). Ultra-short-term forecasting for photovoltaic power plants and real-time key performance indicators analysis with big data solutions. two case studies - pv agiea and pv giurgiu located in romania. *Computers in Industry*, 120, 103230.
- Pazikadin, A.R., Rifai, D., Ali, K., Malik, M.Z., Abdalla, A.N., and Faraj, M.A. (2020). Solar irradiance measurement instrumentation and power solar generation forecasting based on artificial neural networks (ann): A review of five years research trend. *Science of The Total Environment*, 715, 136848.
- Radicioni, M., Lucaferri, V., De Lia, F., Laudani, A., Lo Presti, R., Lozito, G.M., Fulginei, F.R., Schioppa, R., and Tucci, M. (2021). Power forecasting of a photovoltaic plant located in enea casaccia research center. *Energies*, 14(3).
- Silva, A.W.B., Freitas, B.B., Filho, C.L.A., Freitas, C., Junior, E.A.S., Castro, E.S., Araujo, E.M., Correia, F.I.F., Silva, F.R.P., Souza, J.J.S., Martins, L.L.P., Coutinho, L.R.R., Ces, N.P.L., Castelo, R., Carvalho, P.C.M., and Carneiro, T.C. (2022). Methodology based on artificial neural networks for hourly forecasting of pv plants generation. *IEEE Latin America Transactions*, 20(4), 659–668.
- Silva, I.N.d., H., S.D., and A., F.R. (2016). *Redes neurais artificiais: para engenharia e ciências aplicadas*. Artliber, 2nd edition.
- Visser, L., AlSkaif, T., and van Sark, W. (2022). Operational day-ahead solar power forecasting for aggregated pv systems with a varying spatial distribution. *Renewable Energy*, 183, 267–282.
- Wang, K., Qi, X., and Liu, H. (2019). A comparison of day-ahead photovoltaic power forecasting models based on deep learning neural network. *Applied Energy*, 251, 113315.