

Previsão da produção de eletricidade em instalações de energia solar fotovoltaica usando métodos diretos

Forecast of electricity production in photovoltaic solar energy facilities using direct methods

DOI:10.34117/bjdv7n12-217

Recebimento dos originais: 12/11/2021

Aceitação para publicação: 01/12/2021

Jorday Arostegui Morell

Engenheiro Eletricista, pela Universidade do Camagüey "Ignacio Agramonte Loynaz"
Empresa Eléctrica do Camagüey
Rodoanel Norte km 4 ^{1/2}, Camagüey, Cuba, CEP: 74650
E-mail: jarostegui@nauta.cu

Eduardo Sierra Gil

Doutorado em Engenharia Elétrica, pela Universidade do Camagüey "Ignacio Agramonte Loynaz"
Universidade do Camagüey "Ignacio Agramonte Loynaz"
Rodoanel Norte km 5 ^{1/2}, Camagüey, Cuba, CEP: 74650
E-mail: eduardo.sierra@reduc.edu.cu

Israel Gondres Torné

Doutorado em Engenharia Elétrica, pela Universidade de Camagüey "Ignacio Agramonte Loynaz".
Universidade do Estado do Amazonas, Escola Superior de Tecnologia. HUB/LSE.
Av. Darcy Vargas, 1.200 - Parque Dez, Manaus - AM, CEP: 69050-020
E-mail: itorne@uea.edu.br

Fábio de Sousa Cardoso

Doutorado em Engenharia Mecânica pela Universidade Federal do Rio de Janeiro.
Universidade do Estado do Amazonas, Escola Superior de Tecnologia. HUB/LSE.
Av. Darcy Vargas, 1.200 - Parque Dez, Manaus - AM, CEP: 69050-020
E-mail: fcardoso@uea.edu.br

Angilberto Muniz Ferreira Sobrinho

Doutorado em Engenharia Elétrica pela Universidade Federal de Campina Grande.
Universidade do Estado do Amazonas, Escola Superior de Tecnologia. HUB/LSE.
Av. Darcy Vargas, 1.200 - Parque Dez, Manaus - AM, CEP: 69050-020
E-mail: asobrinho@uea.edu.br

RESUMO

O trabalho apresenta uma comparação entre os resultados obtidos para a previsão da produção de eletricidade em instalações de energia solar fotovoltaica, usando diferentes métodos diretos. Devido à natureza intermitente e incerta da energia solar, associada à influência de múltiplos fatores meteorológicos, a geração de energia fotovoltaica necessita de ferramentas de previsão cada vez mais precisas para garantir o funcionamento eficiente e confiável do sistema. Nesse estudo, as previsões para cada hora

analisada são calculadas por três dos métodos mais usuais e são comparadas usando o erro percentual absoluto médio como referência. Os resultados são testados com os dados de geração de energia obtidos do Parque Solar Fotovoltaico Imías, que tem uma capacidade instalada de 2,2 MWp. Independentemente dos métodos mostrarem que garantem uma previsão com alta precisão, existem diferenças na eficácia de cada previsão, nas mesmas condições.

Palavras-chave: Geração de energia, métodos diretos, previsão de eletricidade, solar fotovoltaica.

ABSTRACT

This work shows a comparison between the results obtained by different direct methods for the prediction of electricity production in photovoltaic solar energy installations. Photovoltaic energy generation requires increasingly accurate forecasting tools, due to the intermittent and uncertain nature of solar energy, associated with the influence of multiple meteorological factors, to ensure the efficient and reliable operation of the system. In this study, hourly forecasts analyzed by direct methods, three of the most used, are calculated and compared using the mean absolute percentage error as a reference. The results are tested with energy generation data obtained from the Imías Photovoltaic Solar Park, which has an installed capacity of 2.2 MWp. Regardless of whether the results show that the evaluated methods guarantee a prediction with high accuracy, there are differences in the effectiveness of each prediction under the same conditions.

Keywords: Power generation, direct methods, electricity forecasting, solar photovoltaics.

1 INTRODUÇÃO

A previsão da geração fotovoltaica pode ser classificada em diferentes categorias e levando em consideração diversos fatores, sem que haja, no entanto, um único critério de classificação. A maioria dos pesquisadores classifica a previsão da geração fotovoltaica de acordo com o horizonte de previsão, dados históricos de irradiância solar ou outros padrões de dados meteorológicos e os métodos usados para a previsão (DAS et al., 2018) (Oliveira & Belchior, 2021).

Para os fins deste artigo, é útil classificar os métodos usados para previsão. Os métodos convencionais disponíveis na literatura científica para calcular a potência que um módulo fotovoltaico pode fornecer podem ser divididos em dois grandes grupos:

- i) Aqueles que primeiro estimam a curva característica I-V do módulo, da qual obtêm a potência.
- ii) Métodos que calculam diretamente a potência.

A maioria desses métodos é baseada em abordagens clássicas, em que a potência é obtida diretamente de equações baseadas em alguns parâmetros atmosféricos e nas informações fornecidas pelos fabricantes nas fichas técnicas.

Além disso, esses métodos convencionais podem ser subdivididos, pela abordagem que usam, em métodos físicos e métodos estatísticos.

O método de previsão física consiste no conjunto de equações matemáticas que descrevem o estado físico e o movimento dinâmico da atmosfera (MONTEIRO et al., 2013). Os modelos físicos são projetados com base nas características da usina fotovoltaica, como localização, diferentes variáveis meteorológicas e dados históricos de orientação. Esses modelos podem ser consideravelmente simples (quando baseados exclusivamente na irradiância solar global) ou complicados (se incluem parâmetros adicionais) (DOLARA et al., 2015). A precisão do modelo de previsão física é maior quando as condições meteorológicas são estáveis (SOMAN et al., 2010). No entanto, o desempenho das previsões é afetado em grande parte devido às mudanças abruptas nas variáveis meteorológicas. Diferentes estudos relataram que o método de previsão física foi combinado com os diferentes métodos estatísticos e inteligência artificial para projetar um modelo de previsão híbrido para melhor precisão de previsão (DOLARA et al., 2015; GANDELLI et al., 2014).

Por outro lado, o método de regressão é um método estatístico utilizado para estabelecer uma relação entre as variáveis explicativas e dependentes. Neste modelo, a variável dependente é predita conhecendo as variáveis explicativas. No caso da previsão de energia fotovoltaica, a energia fotovoltaica prevista é considerada uma variável dependente e as variáveis meteorológicas são consideradas variáveis explicativas (DAS et al., 2018). São utilizados dois modelos de regressão distintos: regressão linear simples e regressão linear múltipla, obtendo-se melhores resultados com o modelo de regressão linear múltipla (HAMID OUDJANA; HELLAL; HADJ MAHAMED, 2012).

Os métodos que obtêm a potência máxima por uma única expressão matemática baseada nas relações semi-empíricas determinam diferentes coeficientes a partir de dados experimentais e a potência é estimada por uma expressão matemática que relaciona a potência com os parâmetros elétricos, irradiância, temperatura e os coeficientes propostos. Os coeficientes são frequentemente dados para uma tecnologia particular ou para certos níveis de irradiância. Alguns desses métodos de obtenção de potência são baseados em equações de regressão multivariada linear. Todos eles tentam prever o comportamento dos módulos fotovoltaicos sob a influência do sol usando uma única

equação (CACHIPUENDO AMAGUA, 2016). Em geral, os melhores resultados são obtidos para uma faixa de temperatura de célula de 10-70 °C e irradiância maior que 500 W/m².

O método simples: O método simples (modelo linear simples) é o menos preciso. A potência das células é calculada levando em consideração uma variação linear com a irradiância. O efeito da temperatura da célula não é considerado, então a potência do dispositivo é superestimada. Modelos deste tipo são reduzidos à sua forma mais simples considerando apenas a irradiação incidente nos módulos fotovoltaicos. Conforme mencionado, a única vantagem deste modelo é sua extrema simplicidade, mas pode ser útil como uma primeira aproximação.

Método PVUSA (Photovoltaics for Utility Scale Applications): Na década de 1990 o projeto PVUSA (Photovoltaics for Utility Scale Applications) ou Photovoltaic Applications for Useful Scale Applications, desenvolveu uma metodologia para obter uma expressão matemática que permite obter a potência de um módulo fotovoltaico de determinadas entradas. O método é baseado na coleta de dados de irradiação, dados meteorológicos, e dados de potência de saída do sistema fotovoltaico por um período de tempo, e na regressão da saída do sistema P em (W ou kW), considerando como entradas em um combinação de irradiância, H em (W/m² ou kW/m²), velocidade do vento, W em (m/s) e temperatura ambiente, Ta em (°C). O modelo inclui quatro termos de irradiância (um dos quais é ao quadrado) e apenas um de cada um dos termos relacionados velocidade, temperatura e vento. Esse fato leva a algumas conclusões interessantes sobre a precisão do modelo. Geralmente, dados de irradiação maiores que 500 W/m² (700 W/m² é recomendado) são usados para determinar os coeficientes de regressão c1, c2, c3 e c4.

A partir da observação, as seguintes características do modelo podem ser notadas: a incerteza na irradiância carrega significativamente mais peso do que a incerteza nas outras variáveis, a temperatura ambiente está altamente correlacionada positivamente com a irradiância solar (SMITH et al., 1989).

Método ENRA (Energy Ratings): Gianolli-Rossi e Krebs desenvolveram este método que também usa análise de regressão para determinar a saída de energia do módulo usando todos os três parâmetros. O modelo ENRA tem a desvantagem de ser útil apenas com dados de irradiação maiores que 500 W/m² para o cálculo dos coeficientes de regressão (GIANOLI-ROSSI; KREBS, 1988).

Método de Mayer. O último modelo selecionado é o modelo de Mayer baseado em métodos de regressão multivariada. O modelo consiste em um ajuste polinomial dos

dados operacionais, onde a potência produzida pelo sistema é função da irradiação incidente e do módulo de temperatura do painel fotovoltaico. O procedimento consiste, em primeiro lugar, em calibrar o modelo ao módulo em estudo para obter as constantes polinomiais que melhor representam o comportamento do sistema (MAYER et al., [s.d.]).

2 ANÁLISE COMPARATIVA DE MODELOS DE PREVISÃO DE ENERGIA FOTOVOLTAICA

2.1 DESCRIÇÃO MATEMÁTICA DOS MODELOS

2.1.1 Modelo simples

A potência elétrica produzida pelo sistema fotovoltaico é calculada como:

$$(1) \quad P = A * f * H * \eta * \eta_{\text{investidor}}$$

Onde:

A: É a área da matriz fotovoltaica.

f: É a fração da área da matriz com células solares ativas.

H: É a irradiação incidente no painel fotovoltaico.

η : É a eficiência de conversão do módulo PV.

η_{inversor} : É a eficiência do conversor DC / AC.

$$(2) \quad P = c_1 * H$$

2.1.2 Modelo PVUSA

A variável dependente está relacionada às variáveis explicativas pela seguinte equação:

$$(3) \quad P = c_1 H + c_2 H^2 + c_3 w H + c_4 T H$$

Onde:

H: É a irradiação incidente no painel fotovoltaico.

T: É a temperatura ambiente no painel fotovoltaico.

w: É a velocidade do vento incidente no painel fotovoltaico.

c_1, c_2, c_3, c_4 : Coeficientes de regressão.

2.1.3 Modelo ENRA

A potência de saída do módulo é descrita abaixo, usando a equação:

$$(4) \quad P = c_1 H + c_2 H^2 + c_3 H \ln(H)$$

Onde:

P: É a potência de saída em kW.

H: É a irradiação incidente no painel fotovoltaico.

c_1, c_2, c_3 : Coeficientes de regressão.

2.1.4 Modelo do Mayer

A potência de saída do módulo é descrita abaixo, usando a equação:

$$(5) \quad P = c_1H + c_2TH + c_3H + c_34H^2$$

Onde:

H: É a irradiação incidente no painel fotovoltaico.

T: É a temperatura ambiente no painel fotovoltaico.

c_1, c_2, c_3, c_4 : Coeficientes de regressão.

2.2 CÁLCULOS DOS COEFICIENTES.

Esses métodos requerem formulação empírica para determinar os coeficientes. Por esse motivo, foi selecionada uma amostra probabilística, com a mesma possibilidade de seleção (KOTHARI, 2004).

O tamanho da amostra é selecionado a partir de:

$$(6) \quad n' = \frac{S^2}{V^2}$$

Onde:

n' : Tamanho de amostra não ajustado.

S^2 : Variância da população. Sua definição (S^2) ao quadrado do erro padrão.

V^2 : Variância da amostra expressa como a probabilidade de ocorrência de \bar{y}

Em seguida, é corrigido com outros dados, ajustando se o tamanho do população.

$$(7) \quad n = \frac{n'}{1 + \frac{n'}{N}}$$

Onde:

N = Tamanho da população de 477 estudos de caso.

Para a probabilidade de \bar{y} igual a 90%, e um erro padrão de 0,011, um tamanho de amostra igual a 290 é obtido.

A figura a seguir mostra um fragmento da programação utilizada no Matlab para obter os coeficientes de cada um dos modelos.

Figura 1: Obtenção dos coeficientes.

```
% Obtención de los coeficientes del modelo
H=H1';T=T1';P=P1';
TMComp=length(P);
%Modelo Simple
X=[H];
MS=X\P
% Modelo ENRA
E=[H H.^2 H.*log(H)];
MENRA=E\P
%Modelo De Mayer
Y=[ones(size(H)) T.*H H H.^2];
MMAYER=Y\P
```

Fonte: Autoria Própria

Os coeficientes obtidos para os diferentes modelos são os seguintes:

Modelo Simples: $c_1 = 0.0022$;

Modelo ENRA: $c_1 = 0.0033$ $c_2 = 0$ $c_3 = -0.0002$;

Modelo do MAYER: $c_1 = 0.0205$; $c_2 = 0$; $c_3 = 0.0021$; $c_4 = 0$

2.3 AVALIAÇÃO DA PRECISÃO DOS MODELOS

Diversas matrizes de avaliação têm sido propostas e aplicadas para medir a precisão dos modelos de predição da geração fotovoltaica. Indicadores de desempenho, como o erro quadrático médio RMSE (HUANG et al., 2018; PEDRO; COIMBRA, 2012), o erro quadrático médio relativo RMSE (HUANG et al., 2018; PEDRO; COIMBRA, 2012), o erro médio absoluto MAE (HUANG et al., 2018), o erro médio relativo MRE (RANA; KOPRINSKA; AGELIDIS, 2015), o erro médio de viés BEM (PEDRO; COIMBRA, 2012) e o erro percentual absoluto médio MAPE (LIN; PAI, 2016; LIU et al., 2017), têm sido comumente usados para avaliar a precisão dos modelos de previsão de geração de PV.

O indicador estatístico erro percentual absoluto médio (MAPE), aqui selecionado para medir a precisão da predição dos modelos avaliados neste trabalho, é uma medida da acurácia da predição de um método em estatística (RUIZ TEIXIDOR, 2018) e é dado pela expressão:

$$(8) \quad MAPE = \frac{1}{N} \sum_{t=1}^N \left(\left| \frac{P_r(t) - P_p(t)}{P_r(t)} \right| * 100\% \right)$$

Um valor MAPE baixo indica uma baixa porcentagem de erro de predição do modelo. A interpretação dos valores MAPE (%) é a seguinte (LEWIS, 1982): menos de 10%

é uma previsão de alta precisão; entre 10% e 20% a previsão é boa; entre 20% e 50% a previsão é razoável; e maior que 50% a previsão está incorreta.

Após o cálculo do indicador estatístico MAPE para cada método, são obtidos os seguintes resultados:

MAPE do Método simples: 8.2531 %

MAPE do método ENRA: 9.0364%

MAPE do método do Mayer: 8.3985%

3 CONCLUSÕES

A presente investigação utilizou os métodos que calculam diretamente a potência da célula fotovoltaica para estimar o comportamento em quaisquer condições de funcionamento.

A comparação das usinas fotovoltaicas foi facilitada a partir dos parâmetros fornecidos pelo fabricante e constitui uma ferramenta para avaliar o desempenho desses sistemas na fase de projeto, possibilitando a realização de estudos posteriores de impacto na rede dessas usinas.

A exploração de modelos diretos, em operação, requer uma previsão meteorológica o mais acurada possível das variáveis envolvidas.

Foram obtidos resultados positivos do indicador estatístico MAPE que garantem uma previsão de alta precisão nas condições do parque fotovoltaico avaliado.

REFERÊNCIAS

CACHIPUENDO AMAGUA, L. F. **Estimación de la potencia producida por módulos fotovoltaicos en base a Redes Neuronales Artificiales y comparación con metodologías basadas en Regresiones Múltiples.** Quito. 11 jan. 2016.

DAS, U. K. et al. **Forecasting of photovoltaic power generation and model optimization: A review.** *Renewable and Sustainable Energy Reviews*, v. 81, p. 912–928, 1 jan. 2018.

DOLARA, A. et al. **A Physical Hybrid Artificial Neural Network for Short Term Forecasting of PV Plant Power Output.** *Energies*, v. 8, n. 2, p. 1138–1153, fev. 2015.

GANDELLI, A. et al. **Hybrid model analysis and validation for PV energy production forecasting.** 2014 International Joint Conference on Neural Networks (IJCNN). *Anais...* In: 2014 INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS (IJCNN). jul. 2014.

GIANOLI-ROSSI, E.; KREBS, K. **Energy rating of PV modules by outdoor response analysis.** . In: EC PHOTOVOLTAIC SOLAR CONFERENCE. 8. 1988. Disponível em: <<http://pascal-francis.inist.fr/vibad/index.php?action=getRecordDetail&idt=6637262>>. Acesso em: 13 out. 2021

HAMID OUDJANA, S.; HELLAL, A.; HADJ MAHAMED, I. **Short term photovoltaic power generation forecasting using neural network.** 2012 11th International Conference on Environment and Electrical Engineering. *Anais...* In: 2012 11TH INTERNATIONAL CONFERENCE ON ENVIRONMENT AND ELECTRICAL ENGINEERING. maio 2012.

HUANG, C. et al. Day-Ahead Forecasting of Hourly Photovoltaic Power Based on Robust Multilayer Perception. *Sustainability*, v. 10, n. 12, p. 4863, dez. 2018.

KOTHARI, C. R. **Research methodology: Methods and techniques.** [s.l.] New Age International, 2004.

LEWIS, C. D. **Industrial and business forecasting methods: A practical guide to exponential smoothing and curve fitting.** [s.l.] Butterworth-Heinemann, 1982.

LIN, K.-P.; PAI, P.-F. Solar power output forecasting using evolutionary seasonal decomposition least-square support vector regression. *Journal of Cleaner Production*, Special Volume: Green and Sustainable Innovation for Cleaner Production in the Asia-Pacific Region. v. 134, p. 456–462, 15 out. 2016.

LIU, L. et al. Forecasting Power Output of Photovoltaic System Using A BP Network Method. **Energy Procedia**, Proceedings of the 9th International Conference on Applied Energy. v. 142, p. 780–786, 1 dez. 2017.

MAYER, D. et al. Performance Prediction of Grid-Connected Photovoltaic Systems Using Remote Sensing. p. 48, [s.d.].

MONTEIRO, C. et al. Short-Term Forecasting Models for Photovoltaic Plants: Analytical versus Soft-Computing Techniques. **Mathematical Problems in Engineering**, v. 2013, p. e767284, 21 nov. 2013.

OLIVEIRA, J. C.; BELCHIOR, F. N. Energia elétrica produzida por um sistema fotovoltaico versus dados meteorológicos – uma aplicação da correlação de pearson. **Brazilian Journal of Development**. Vol. 7, Núm. 5 (2021). DOI:10.34117/bjdv7n5-551

PEDRO, H. T. C.; COIMBRA, C. F. M. Assessment of forecasting techniques for solar power production with no exogenous inputs. **Solar Energy**, v. 86, n. 7, p. 2017–2028, 1 jul. 2012.

RANA, M.; KOPRINSKA, I.; AGELIDIS, V. G. **Forecasting solar power generated by grid connected PV systems using ensembles of neural networks**. 2015 International Joint Conference on Neural Networks (IJCNN). **Anais...** In: 2015 INTERNATIONAL JOINT CONFERENCE ON NEURAL NETWORKS (IJCNN). jul. 2015.

RUIZ TEIXIDOR, M. **Comparación de dos modelos de series temporales multivariantes para la predicción de la demanda eléctrica**. info:eu-repo/semantics/bachelorThesis. Disponível em: <<https://oa.upm.es/50274/>>. Acesso em: 13 out. 2021.

SMITH, S. et al. Photovoltaics for utility-scale applications: project overview and data analysis. **Solar Cells**, v. 27, n. 1, p. 259–266, 1 out. 1989.

SOMAN, S. S. et al. **A review of wind power and wind speed forecasting methods with different time horizons**. North American Power Symposium 2010. **Anais...** In: NORTH AMERICAN POWER SYMPOSIUM 2010. set. 2010.