

# PREVISÃO DE TEMPERATURA AMBIENTE HORÁRIA VOLTADA PARA AUXILIAR PREVISÕES DE GERAÇÃO DE POTÊNCIA FOTOVOLTAICA

**Edson Ricardo Calado Sabino** – ricardocalado2@yahoo.com.br  
Universidade Federal de Pernambuco, Centro de Energias Renováveis – CER  
Instituto Federal de Pernambuco – *Campus* Pesqueira  
**Leonardo José de Petribú Brennand** – leojdpb@hotmail.com  
**Heitor Farias de Barros** – heitorfarias@live.com  
**Olga de Castro Vilela** – ocv.olga@gmail.com  
**Alexandre Carlos Araújo da Costa** – alexandre.acosta@ufpe.br  
Universidade Federal de Pernambuco, Centro de Energias Renováveis – CER

**Resumo.** A maioria dos métodos de previsão de potência de centrais fotovoltaicas (FV) utiliza como entrada previsões de temperatura ambiente ou de temperatura da célula. Este trabalho apresenta uma metodologia para previsão de temperatura ambiente com o time step horário e um horizonte máximo de previsão (H) de 24h. Trata-se de uma metodologia simples e univariada que utiliza modelos autorregressivos (AR). Foi realizado um estudo para definição da ordem dos modelos AR utilizando dentre outras coisas, função de autocorrelação parcial e o RMSE (Root Mean Square Error) dos modelos de diversas ordens. Duas bases de dados foram utilizadas para esse fim, a de Petrolina-PE (um ano de calibração e um de validação) e a de Remanso-BA (três anos de calibração e dois anos de validação). Os erros médios provocados pelos modelos AR obtiveram uma diminuição sutil na base de dados de Remanso em relação à de Petrolina. Em Petrolina, as previsões horárias para horizontes de até 24h à frente atingiram erros médios entre 0,6°C e 1,59°C, o que é considerado satisfatório quando comparado com modelos de outros autores. Os modelos AR também superaram o desempenho da Persistência em todos os horizontes testados. Após uma análise de sensibilidade, estimou-se que os erros médios da temperatura prevista pelos modelos AR provocariam um desvio médio nas previsões da saída da central FV de 1,17%, sendo por isso considerados adequados para este fim.

**Palavras-chave:** Previsão de Temperatura, Modelos Autorregressivos

## 1. INTRODUÇÃO

Dentre os fatores ambientais que influenciam na potência de saída de uma central fotovoltaica, as principais variáveis que influenciam a potência FV são a irradiância no plano do coletor ( $I_{col}$ ) e a temperatura das costas do painel ( $T_{cel}$ ) (Pelland et al., 2013). Devido a isto, além das previsões de irradiância, a previsão de temperatura ambiente é requerida na maioria das aplicações de energia solar (Chaabene e Ammar, 2008). De posse das temperaturas ambientes previstas, pode-se transformá-las em previsões de temperaturas do painel através de modelos que as correlacionam com a temperatura ambiente e a irradiância solar incidente no módulo FV (Green, 1982).

Previsões de energia fotovoltaica são geralmente feitas primeiramente pela previsão de irradiância. Só então se traduz irradiância em potência elétrica utilizando um modelo de desempenho fotovoltaico (Bartholomy et al., 2014). Existem vários modelos de desempenho de centrais fotovoltaicas. Um bastante utilizado devido sua simplicidade e acurácia é o modelo de Sandstrom (1967), o qual possui como entradas a irradiância e a temperatura do módulo FV.

Existem vários modelos de previsão de temperatura ambiente. A grande maioria provém de ferramentas de previsão de tempo numérica (NWP, *Numerical Weather Prediction*), as quais são calculadas para pontos específicos de uma malha que cobre uma vasta região, possuindo uma baixa resolução espacial. Além disso, para horizontes de curto prazo, modelos baseados em séries temporais tendem a ter melhores resultados comparados ao NWP. A maioria das ferramentas possuem apenas grandezas médias, máximas e mínimas diárias. Poucos modelos de previsão de temperatura ambiente oferecem saídas com intervalos de tempos horários.

Vários modelos de previsão de temperatura baseados em séries temporais de dados observacionais foram propostos na literatura. A Tab. 1 traz um resumo das principais características de alguns desses modelos.

Tasadduq et al. (2002) utilizaram um modelo baseado em redes neurais para previsão da temperatura média horária com um horizonte específico de 24h à frente, isto é, previsão da temperatura no dia seguinte e na mesma hora. A entrada do modelo é unicamente a temperatura da hora de interesse. O RMSE alcançado pela previsão foi de 1.75°C.

McCutchan (1976) utilizou expansão por série de Fourier para prever a variação diurna da temperatura em terras montanhosas do Sudeste da Califórnia. A expressão permite calcular a temperatura para qualquer instante de tempo do dia. Os valores de suas constantes dependem da insolação, da hora do dia, da classe de tempo sinótica e da altitude. Os resultados para horizontes de tempo de 2h a 11h em avanço alcançaram faixas de RMSE variando de 1,3°C a 4,7°C e coeficientes de correlação em torno de 0,90.

Em seu trabalho, Asamoah-Boaheng (2014) avaliou modelos para previsão da temperatura média mensal do ar da superfície. Foram usados dados do período de 1950 a 1994 do Serviço Meteorológico Estadual da Turquia. De acordo com sua análise, o modelo que melhor se ajustou aos dados foi o SARIMA(2,1,1)(1,1,2)(12). O modelo referido obteve previsões com um passo à frente e com RMSE de 0,51°C.

Hayati e Mohebi (2007) realizaram previsões de temperatura em curto prazo (um dia à frente com *time step* de 3h) utilizando redes neurais. Foram utilizados 10 anos de observações. As entradas do modelo são dados meteorológicos (temperatura de bulbo seco e temperatura de bulbo molhado, velocidade do vento, pressão, umidade relativa do ar, brilho solar e radiação solar). O trabalho obteve um MAE de 1,8°C.

Abdel-Aal (2004) propôs uma abordagem de previsão de temperatura baseado no conceito de redes abduativas, as quais são mais simples e mais automatizadas em relação aos demais métodos de entrada-saída. As entradas dos modelos eram: temperaturas horárias das 24 horas do dia (*d-1*), temperatura máxima e mínima do dia (*d-1*) e previsões da temperatura máxima e mínima do dia (*d*) ao qual se quer prever. As saídas do modelo são temperaturas horárias 24h à frente com *time step* horário. Foram testadas tanto estratégias diretas quanto recursivas. Os resultados obtiveram MAE médio ao longo dos 24 horizontes de previsão de 1,06 °C para previsões diretas sem a utilização de previsões de temperaturas máxima e mínima.

Smith et al. (2006) propuseram uma metodologia de previsão de temperatura do ar em intervalos horários de 1h a 12h à frente baseados em Redes Neurais (*Artificial Neural Networks, ANN*). As entradas do modelo são temperatura e variáveis sazonais determinísticas. Tal metodologia visa à melhoria da acurácia das previsões baseada em quatro ações: aumento do n° de padrões de inicialização de treinamento, inclusão das variáveis com informação sazonal, extensão da duração dos dados a priori e variação do número de camadas intermediárias. É mostrado que o mesmo modelo quando iniciado com diferentes pesos iniciais aleatórios produzem erros de previsão diferentes. Portanto, sugere-se que os desenvolvedores treinem suas redes com 30 diferentes pesos iniciais à fim de estabelecer os melhores parâmetros. Em relação à variação do tamanho do conjunto de dados para treinamento, não foi encontrada relação direta da mesma com o MAE. Já a inclusão de variáveis exógenas promoveu apenas discreta melhoria no MAE, que passou de 1,51°C para 1,48°C. O aumento da ordem do modelo provocou uma melhoria no MAE. Considerando uma janela de 24 observações passadas, obteve-se o melhor MAE (1,38°C). A última melhoria foi devido à variação de nós intermediários da ANN, a qual obteve melhor resultado com 120 nós e (já considerando as melhorias anteriores) alcançou um MAE de 1,35°C.

Chevalier et al. (2011) propuseram um método de previsão de temperatura baseado em SVR (*Support Vector Regression*). Com objetivo de reduzir o número de padrões (linhas de dados) de treinamento de um grandioso conjunto de dados e, conseqüentemente o tempo de treinamento do modelo, foi proposto um método para reduzir o conjunto de treinamento. A previsão foi realizada para horizontes de 1h a 12h, com MAE variando de 0,5°C a 2,3°C quando o conjunto de dados foram os dados apenas dos invernos e de 0,5°C a 1,9°C quando os dados usados foram do ano todo. Para dados apenas dos invernos, o método SVR foi discretamente melhor que a ANN (Smith et al., 2006). Já para dados de todo o ano, o método baseado em SVR superou a ANN em apenas 4 dos 20 horizontes.

Tabela 1 - Modelos de Previsão de Temperatura Ambiente Baseados em Séries Temporais

Assunto	Autor	Modelos usados	Horizontes	Erros	Quantidade de dados	Local	OBS
Previsão temperatura para H=24h	Tasadduq et al. (2002)	ANN	24h	1,75°C (RMSE)	1 ano (trein.) e 3 anos(valid.)	Arábia Saudita	Univariado
Previsão temperatura para H= 12h com time step horário.	Mccutchan (1976)	Expansão de Séries de Fourier	2-11h	1,3 a 4,7°C (RMSE)	131 dias	Montanhas do Sul da Califórnia	Univariado
Previsão de temperatura média mensal para H=1 mês	Asamoah-Boaheng (2014)	SARIMA	média mensal	0,51°C (RMSE)	33 anos	Ashanti, Gana. Clima equatorial	Univariado
Previsão de temperatura horária média para H=1dia com time step de 3h	Hayati e Mohebi (2007)	ANN, MLP	1-24h	1,8°C (MAE)	10 anos	Kermanshah, Iran	Multivariado. Entradas: temp, umid., pressão, vel. Vento, visibilidade,....
Previsão de temperatura horária média para H=24h com time step de 1h	Abdel-Aal (2004)	Redes Abduativas	1-24h	1,06 °C (MAE)	7 anos	Seattle, USA	Entradas: Temperatura, Tmax e Tmin e previsão de Max e Min
Previsão de temperatura H=12 com time step horário.	Chevalier et al. (2011)	Support Vector Regression	1h a 12h	0,5°C a 1,9°C (MAE)	de 1997 a 2005.	Geórgia, EUA	Univariado
Previsão de temperatura horária para H=12 com time step horário	Smith et al. (2006)	ANN	1h a 12h	1,35°C (MAE)	4 anos	Geórgia, EUA	Entradas: Temperatura e Variável Sazonal

O objetivo deste trabalho é de desenvolver uma ferramenta simples e univariada de previsão de temperatura ambiente baseada em séries temporais observacionais, às quais são quase sempre presentes nas estações meteorológicas. Essa ferramenta deve ser capaz de fornecer previsões de temperatura acuradas e de forma rápida, a fim de serem utilizadas nas ferramentas de previsão de potência gerada de centrais fotovoltaicas. Além disso, as previsões devem possuir *time step* horário e um horizonte final  $H$  de 24h à frente.

## 2. METODOLOGIA

### 2.1 Base de Dados

O modelo autorregressivo será testado em duas bases de dados, sendo uma em Petrolina- PE e outra em Remanso-BA, ambas com mesmas características climáticas, com altitudes semelhantes e pertencentes ao Vale do São Francisco, no Nordeste do Brasil, distantes entre si cerca de 200 km. A base de dados de Petrolina, contendo dois anos de medidas de temperatura, foi escolhida devido ao interesse relacionado à previsão de geração de energia elétrica de uma central fotovoltaica, a qual se encontra em fase de implantação. Já a base de dados de Remanso foi escolhida por ser de mesma climatologia, porém por dispor de um período maior de dados sem grandes lacunas, sendo utilizados cinco anos no total.

Os dados de temperatura de Petrolina são oriundos da estação meteorológica pertencente à rede SONDA, mantida pelo INPE, cuja localização está descrita na Tab. 2. Trata-se de uma estação meteorológica com medidas de temperatura minuto a minuto. Por conveniência, os dados foram transformados para a base horária. Já os dados de Remanso são provenientes da estação meteorológica pertencente ao INMET, na qual os dados já são disponibilizados na base horária.

Os algoritmos aqui utilizados em modelos autorregressivos não funcionam em séries temporais com dados faltantes. Por isso, adotou-se a seguinte estratégia:

- Para um dado horário faltante único, este foi estimado a partir de interpolação simples, através da média aritmética entre as duas medidas vizinhas.
- Para um dado horário faltante não isolado, isto é, com outros dados faltantes vizinhos, o dia associado a tais dados foi sacado da série.

O treinamento e a validação dos modelos aqui testados seguem a filosofia da validação cruzada, onde o conjunto de dados é subdividido em dois conjuntos mutuamente exclusivos (Michaelsen, 1987).

Tabela 2 - Características dos sítios dos quais foram utilizados dados de temperatura.

Bases de dados	Altitude (m)	Latitude	Longitude	Clima (Köppen-Geiger)	Dados de Calibração	Dados de Validação
Petrolina-PE	387	-9,0689	-40,3197	Semiárido BSh	01/01/2014 a 31/12/2014	01/01/2015 a 31/12/2015
Remanso-BA	397	-9,6257	-42,0772	Semiárido BSh	01/04/2008 a 31/03/2011	01/11/2011 a 31/10/2013

### 2.2 Obtenção do Modelo de Previsão

De modo a conseguir uma ferramenta de previsão de simples operação e que pudesse ser calibrada para a maioria dos sítios onde se encontram as centrais fotovoltaicas, optou-se por desenvolver um modelo univariado, tendo como entrada apenas a série observacional de temperatura. Tendo em vista sua simplicidade e sua vasta utilização em previsão de séries temporais, o modelo autorregressivo (AR) foi escolhido para esta tarefa.

Os modelos autorregressivos são constituídos por uma abordagem fundada em análise de séries temporais através da extrapolação a um futuro próximo por meio de uma regressão linear utilizando uma estreita janela (composta pelos valores do presente e do passado recente) de tamanho  $p$ , tamanho este chamado de ordem do modelo. Esta janela é então deslocada ao longo de toda a série temporal com o objetivo de que os parâmetros da regressão linear sejam ajustados de forma adaptativa de modo a seguir a dinâmica da variável amostrada (Costa, 2005). A classe de métodos autorregressivos abrange as variantes AR (Autorregressivo), ARX (Autorregressivo com entradas exógenas), MA (Média Móvel), ARMA (junção do AR e MA), ARIMA (Autorregressivo Integrado de Médias Móveis, aplicáveis em séries temporais com evidência de não estacionariedade), entre outras (Box et al., 2015).

A seleção da ordem do modelo AR foi realizada baseada na análise da função de autocorrelação parcial da série de temperatura, a qual indica quais *lags*  $k$  carregam em si uma quantidade de correlação significativa entre a amostra no instante de tempo  $t$  e a amostra no instante de tempo  $t-k$ . Além disso, foram considerados os conhecimentos físicos a respeito da periodicidade diária da temperatura. Para tornar a análise ainda mais substancial, foram testados modelos AR variando da ordem  $p=2$  até a ordem  $p=30$ , conforme mostrado na Fig. 3. Portanto, a seleção final da ordem  $p$  dos modelos AR levou em consideração a função de autocorrelação parcial, a periodicidade diária da temperatura, o RMSE dos diversos modelos testados e a minimização da quantidade de variáveis de entrada.

Realizada a seleção da ordem do modelo, os parâmetros do modelo AR foram então estimados através da regressão baseada no método dos mínimos quadrados (Montgomery et al., 2012). Para cada horizonte de tempo foi calibrado um modelo AR, isto é, trata-se de modelos de previsão não recursivos.

### 2.3 Análise de Sensibilidade da Potência Fotovoltaica em Função do Erro de Previsão de Temperatura

A fim de analisar os impactos provocados por um erro de previsão de temperatura na geração fotovoltaica, foi proposta uma análise de sensibilidade da potência gerada com relação às variações da temperatura ambiente. Para isso, foi aplicado o modelo proposto por Green (1982) para o cálculo da curva I-V em condições padrão (1000W/m<sup>2</sup> e temperatura da célula de 25°C), utilizando-se dos parâmetros do módulo *Quartech CS6P – 255P* da *Canadian Solar*. Para o cálculo da potência do módulo em condições mais genéricas de irradiância e de temperatura da célula, a curva encontrada nas condições mencionadas foi transladada utilizando o método de Sandstrom (1967). O cálculo da temperatura da célula foi feito adicionando 2% da irradiância à temperatura ambiente associada, conforme realizada no trabalho de Green (1982). Dessa forma, o modelo final pode ser esquematizado de acordo com a Fig. 1.



Figura 1 - Modelo determinístico para estimação da potência de saída de um módulo fotovoltaico.

Tendo em mãos a série temporal de potência fotovoltaica gerada ( $P_{fv}$ ), a análise de sensibilidade pode ser executada. Para isso, variações constantes são atribuídas à série temporal de temperatura ambiente, mantendo a série de  $I_{col}$  inalterável, para analisar a resposta na série de potência obtida. As variações são definidas por uma progressão aritmética iniciando em zero, com razão  $r = 0,5 \text{ } ^\circ\text{C}$  e terminando em duas vezes o desvio padrão da série de temperatura ambiente. A forma de mensurar a sensibilidade se deu através da análise da raiz do erro quadrático médio (RMSE) entre a série inicial de potência e a nova série de potência obtida como resposta à série de temperatura com variação inclusa.

## 3. ANÁLISE DOS RESULTADOS

### 3.1 Definição da Ordem do Modelo Autorregressivo

A primeira ação destinada à escolha da ordem do AR foi a análise da função de autocorrelação parcial, ilustrada na Fig. 2. Os valores que se encontram fora da faixa entre as linhas azuis são considerados significativamente diferentes de zero. Nota-se a presença de vários *lags* significativos nas proximidades do *lag* 24.

Para dar maior suporte ao processo, foram testados modelos AR de várias ordens a fim de identificar qual a ordem com melhor desempenho nos diversos horizontes de tempo. A Fig. 3 mostra que modelos com ordens elevadas obtiveram melhor desempenho para a base de dados de Petrolina. Porém, para valores de  $p > 20$ , as reduções no RMSE foram discretas. Com base na minimização da quantidade de parâmetros, no conhecimento físico da periodicidade diária da temperatura, nos valores da função de autocorrelação parcial (Fig. 2) e nos erros provenientes de cada modelo (Fig. 3), conclui-se que a ordem do modelo AR a ser escolhida é de  $p=24$ .

A princípio, a alta ordem do modelo autorregressivo causou surpresa, já que outras variáveis, como por exemplo, velocidade de vento e irradiância, tipicamente são descritas por processos autorregressivos de ordem 2 (Brown et al., 1984; Nfaoui et al., 1996). Uma possível explicação para tal característica reside no fato de que a temperatura é uma variável relativamente bem comportada, com alta inércia e que possui um comportamento periódico bem definido, diferentemente do vento, por exemplo.

Em seu trabalho, Smith et al. (2006) testou, dentre outras coisas, o tamanho (ordem do modelo) da janela de valores passados da variável que pudesse produzir melhor desempenho de suas previsões de temperatura via ANN e obteve o melhor tamanho de 24 observações passadas. Chevalier et al. (2011) também utilizou o mesmo tamanho de janela.




Figura 2 - Função de Autocorrelação Parcial para a série horária de temperatura de Petrolina de 2014.




Figura 3 - Erro dos diversos modelos autorregressivos de ordens variando entre 2 e 30 para dados de Petrolina.

Para realizar uma melhor investigação a respeito do desempenho do modelo AR na previsão de temperatura, a mesma metodologia foi aplicada a uma série de temperatura horária com cinco anos (três anos para calibração e dois anos para validação) de dados, a qual é oriunda da estação do INMET em Remanso na Bahia. Pode-se notar através da Fig. 5 que à medida que  $p$  cresce, o RMSE das previsões tende a diminuir. Porém, a partir de  $p=20$ , a melhoria do RMSE com o aumento de  $p$  tende a ser discreta, ratificando o comportamento observado na base de dados de Petrolina.




Figura 4 - Função de autocorrelação parcial da série horária de temperatura correspondente ao período de Abr/2008 a Mar/2011 em Remanso-BA.

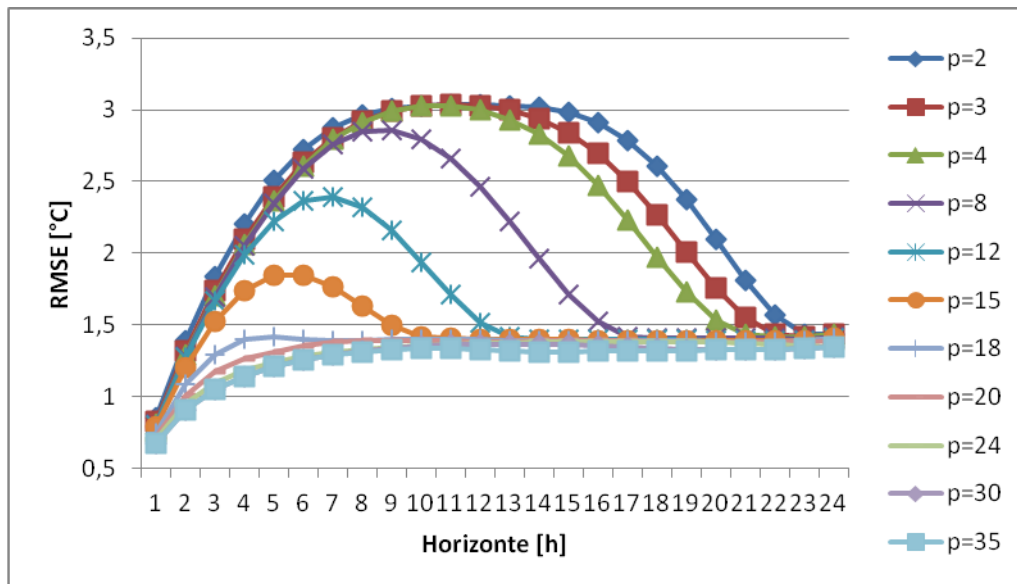


Figura 5 - Erro médio da previsão de temperatura horária em Remanso-BA via modelo AR(p) para as mais diversas ordens p. As previsões são realizadas para um horizonte de 24h à frente com um *time step* horário.

### 3.2 Desempenho do Modelo Selecionado

Para se avaliar o desempenho de um modelo de previsão, é comum entre muitos autores (Costa, 2005; Montgomery et al., 2012) a utilização de um modelo de referência, para assim comparar os resultados de ambos os modelos com as observações. O modelo de referência comumente utilizado é o Modelo de Persistência, devido a sua simplicidade na implementação, o qual é definido como:

$$\hat{y}_{t+k} = \hat{y}_t \quad (1)$$

onde  $\hat{y}_{t+k}$  representa a previsão  $k$  passos à frente. A comparação por persistência se justifica pelo fato de quando se compara, por exemplo, o RMSE encontrado por um autor com o RMSE encontrado nos trabalhos de outro autor, tal comparação não é adequada devido aos experimentos terem sido realizados sob condições (local, época do ano, altitude, variabilidade do recurso, entre outras) diferentes (Inman et al., 2013). Um dos estatísticos mais utilizados para quantificar a melhoria do modelo em estudo em relação ao modelo de Persistência é o *Forecasting Skill*, o qual é descrito na Eq. (2),

$$FS = 1 - \frac{RMSE_m}{RMSE_{pe}} \quad (2)$$

onde os índices  $m$  e  $pe$  são relativos ao modelo em questão e à Persistência, respectivamente.

A melhoria das previsões do AR(24) para Petrolina comparadas ao modelo de Persistência estão descritas na Fig. 6. Nela é possível constatar uma elevada melhoria para os 20 primeiros horizontes, algo em torno de 50% a 77% comparado aos erros de previsão da Persistência. Nos horizontes próximos a 24h, a melhoria do modelo tende a diminuir com relação à Persistência. Isso pode estar ligado à periodicidade diária da temperatura (alta correlação entre a temperatura na hora  $t$  e na hora  $t+24h$ ) e também a já esperada degradação da qualidade das previsões com o aumento da extrapolação temporal (Inman et al., 2013).




Figura 6 - Valores percentuais (FS x 100) da melhoria do modelo AR(24) sobre a Persistência em Petrolina.

Analisando os resultados (Fig. 3) dos modelos AR(24) treinados para Petrolina, vê-se que o erro (RMSE) das previsões temperatura variou ao longo dos horizontes de previsão entre  $0,6^{\circ}\text{C}$  e  $1,59^{\circ}\text{C}$ . Já para o caso dos modelos AR(24) treinados para Remanso, cuja base de dados é maior, o RMSE das previsões variou ao longo dos horizontes de previsão de  $0,7^{\circ}\text{C}$  a  $1,38^{\circ}\text{C}$  (Fig. 5). Embora no primeiro horizonte de previsão (uma hora à frente) o modelo treinado com apenas um ano de dados foi melhor do que o modelo treinado com três anos de dados, o segundo apresentou no geral melhor RMSE para os demais horizontes de previsão. Entretanto tais melhorias não foram substanciais a ponto de justificar a utilização de uma base de dados de tamanho maior do que a de Petrolina. Porém cabe neste aspecto uma investigação mais aprofundada. Existem divergências na literatura a esse respeito. De acordo com Ramos et al. (2011), o tamanho do conjunto de observações usado para calibração de um modelo de estimação de temperatura horária é de fundamental importância. Já Smith et al. (2006) discordaram dessa hipótese, tendo testado e não encontrado relação entre o tamanho do conjunto de dados para treinamento e o MAE das previsões resultantes.

Finalizando, os modelos de previsão de temperatura aqui obtidos podem ser considerados de boa acurácia quando comparados com outros modelos já propostos, conforme erros mostrados na Tab. 1.

### 3.3 Análise de Sensibilidade da Variação de Potência de Saída da Central FV com relação à Temperatura

A análise de sensibilidade foi conduzida segundo metodologia explicada na Seção 2.3 com o objetivo de se obter uma equação que quantificasse a variação de  $P_{fv}$  com relação à variação de temperatura ambiente, sendo mantidas estáveis as demais variáveis. A Fig. 7 traz a equação da reta ajustada aos pontos juntamente com o coeficiente de determinação  $R^2$ . O comportamento linear dos pontos é explicado pelo fato do modelo de Sandstrom ser linear com relação à temperatura.

O desvio padrão da série de temperatura, o qual nos dá um bom indicativo de sua variabilidade, corresponde a cerca de  $4,5^{\circ}\text{C}$ . Assim, o gráfico foi avaliado para variações de temperatura de até  $9^{\circ}\text{C}$  (dois desvios padrão).



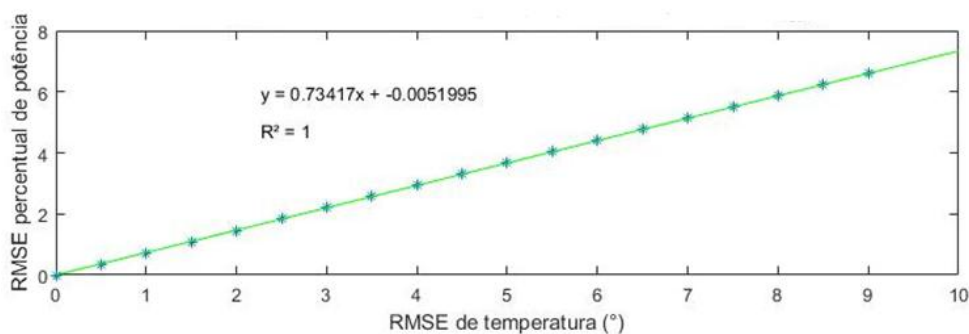


Figura 7 - Relação obtida pela análise de sensibilidade que fornece a variação percentual da potência de saída do gerador fotovoltaico em relação à variação de temperatura.

Pela relação resultante dessa análise, os erros das previsões de temperatura para Petrolina, que variaram de 0,6°C a 1,59°C para os 24 horizontes de previsão, provocariam um erro médio na  $P_{fv}$  de 0,44% a 1,17%, erros baixíssimos, o que faz concluir que os modelos de previsão de temperatura propostos neste trabalho são adequados ao uso em aplicações de previsão de potência de centrais fotovoltaicas.

#### 4. CONCLUSÃO

Este trabalho se propôs a desenvolver uma ferramenta simples e univariada de previsão de temperatura, a fim de que esta possa ser utilizada em previsões de potência gerada por centrais fotovoltaicas. Para esta tarefa, foi escolhido o modelo autorregressivo, devido sua simplicidade e ampla utilização em previsão baseada em séries temporais. Para cada horizonte de previsão, desde 1h até 24h à frente, foi treinado um modelo AR específico. A ordem  $p$  do modelo AR( $p$ ) foi 24 e foi definida com base na autocorrelação parcial, na periodicidade diária da temperatura e no desempenho dos modelos em relação à sua ordem.

Foram treinados ainda modelos AR para uma base de dados maior (5 anos), de Remanso, na Bahia. Notou-se uma diminuição sutil no RMSE das previsões, de forma que não justifica o uso de uma base de dados maior, embora essa seja uma conclusão preliminar, necessitando de estudos mais aprofundados. Os modelos treinados para Petrolina produziram previsões com RMSE que variavam de 0,6°C a 1,59°C. Foram realizadas estimativas dos impactos desses erros em previsões de  $P_{fv}$ . Concluiu-se que tais erros de temperatura contribuiriam no pior caso com 1,17% de erro médio de previsão de  $P_{fv}$ , o que comprova que tais modelos de temperatura são ferramentas adequadas para auxiliar as previsões de  $P_{fv}$ , se mostrando acuradas e práticas. Os modelos AR aqui treinados obtiveram bons resultados comparados à Persistência e aos modelos de outros autores.

Por serem alimentados por medidas observacionais, os modelos AR aqui propostos tendem a produzir no curto prazo melhores resultados quando comparados a modelos NWP. Como em locais onde estão as Centrais FV existem também estações meteorológicas e, conseqüentemente, medidas observacionais de temperatura, esta abordagem torna-se bastante propícia de ser empregada.

#### REFERÊNCIAS

- Abdel-Aal, R. (2004). Hourly temperature forecasting using abductive networks. *Engineering Applications of Artificial Intelligence* 17(5): 543-556.
- Asamoah-Boaheng, M. (2014). Using SARIMA to Forecast Monthly Mean Surface Air Temperature in the Ashanti Region of Ghana. *International Journal of Statistics and Applications* 4(6): 292-298.
- Bartholomy, O., Vargas, T., Simone, M., Hansen, C., Fitchett, S. e Pohl, A. (2014). Benchmarking solar power and irradiance forecasting accuracy at Sacramento Municipal Utility District. *Photovoltaic Specialist Conference (PVSC), 2014 IEEE 40th, IEEE*.
- Brown, B. G., Katz, R. W. e Murphy, A. H. (1984). Time series models to simulate and forecast wind speed and wind power. *Journal of climate and applied meteorology* 23(8): 1184-1195.
- Chaabene, M. e Ammar, M. B. (2008). Neuro-fuzzy dynamic model with Kalman filter to forecast irradiance and temperature for solar energy systems. *Renewable Energy* 33(7): 1435-1443.
- Chevalier, R. F., Hoogenboom, G., McClendon, R. W. e Paz, J. A. (2011). Support vector regression with reduced training sets for air temperature prediction: a comparison with artificial neural networks. *Neural Computing and Applications* 20(1): 151-159.
- Green, M. A. (1982). *Solar cells: operating principles, technology, and system applications*.
- Hayati, M. e Mohebi, Z. (2007). Application of artificial neural networks for temperature forecasting. *World Academy of Science, Engineering and Technology* 28(2): 275-279.
- Inman, R. H., Pedro, H. T. C. e Coimbra, C. F. M. (2013). Solar forecasting methods for renewable energy integration. *Progress in Energy and Combustion Science* 39(6): 535-576.



- McCutchan, M. H. (1976). Diagnosing and predicting surface temperature in mountainous terrain. *Monthly Weather Review* 104(8): 1044-1051.
- Michaelsen, J. (1987). Cross-validation in statistical climate forecast models. *Journal of Climate and Applied Meteorology* 26(11): 1589-1600.
- Montgomery, D. C., Peck, E. A. e Vining, G. G. (2012). *Introduction to linear regression analysis*, John Wiley & Sons.
- Nfaoui, H., Buret, J. e Sayigh, A. (1996). Stochastic simulation of hourly average wind speed sequences in Tangiers (Morocco). *Solar Energy* 56(3): 301-314.
- Pelland, S., Remund, J., Kleissl, J., Oozeki, T. e De Brabandere, K. (2013). Photovoltaic and solar forecasting: state of the art. *IEA PVPS, Task 14*: 1-36.
- Ramos, C., da Silva, A. F., Sartori, A. A. d. C., Zimback, C. R. L. e Bassoi, L. H. (2011). Modelagem da variação horária da temperatura do ar em Petrolina, PE, e Botucatu, SP. *Revista Brasileira de Engenharia Agrícola e Ambiental*: 959-965.
- Sandstrom, J. D. (1967). A method for predicting solar cell current-voltage curve characteristics as a function of incident solar intensity and cell temperature. *IEEE VOL. II* 199.
- Smith, B. A., McClendon, R. W. e Hoogenboom, G. (2006). Improving air temperature prediction with artificial neural networks. *International Journal of Computational Intelligence* 3(3): 179-186.
- Tasadduq, I., Rehman, S. e Bubshait, K. (2002). Application of neural networks for the prediction of hourly mean surface temperatures in Saudi Arabia. *Renewable Energy* 25(4): 545-554.

## HOURLY ENVIRONMENT TEMPERATURE FORECASTING TO AID PHOTOVOLTAIC POWER GENERATION FORECASTS

**Abstract.** *Most of the photovoltaic power forecasting methods use as input the ambient temperature or cell temperature forecasts. This work presents a methodology for ambient temperature forecast with an hourly time step and a maximum forecast horizon (H) of 24h. It is a simple and univariate methodology that uses autoregressive models (AR). A study was carried out to define the order of the AR models using, among other things, partial autocorrelation function and the RMSE (Root Mean Square Error) of the models of several orders. Two databases were used for this purpose, Petrolina-PE (1 year of calibration and 1 of validation) and Remanso-BA (3 years of calibration and 2 years of validation). The average errors caused by the AR models got a subtle decrease in the database of Remanso in relation to that of Petrolina. In Petrolina, the hourly forecasts for horizons of up to 24 hours ahead reached average errors between 0.6 °C and 1.59 °C, which is considered satisfactory when compared with models of other authors. AR models also outperformed Persistence performance across all horizons tested. After a sensitivity analysis, it was estimated that the average temperature errors predicted by the AR models would cause an average deviation in the predictions of the output of the PV plant of 1.17% and are therefore considered adequate for this purpose.*

**Key words:** *Temperature Forecasting, Autoregressive Models*