

ESTADO DA ARTE PARA PREVISÃO DA RADIAÇÃO SOLAR

Samira Fontes Domingos (UFMG) - samirafisica@yahoo.com.br

Luís Guilherme Monteiro (PUC Minas / UFMG) - luis.monteiro@gmail.com

Wallace do Couto Boaventura (Instituição - a informar) - wventura@cpdee.ufmg.br

Resumo:

Com o importante crescimento da utilização de fontes renováveis de energia no mundo e no Brasil, torna-se cada vez mais eminente a obtenção de uma boa precisão na previsão de tais fontes de energia, principalmente para as energias solar e eólica, as quais apresentam alta intermitência. Este avanço possibilitaria o aumento do uso das fontes renováveis de energia, permitindo, por exemplo, sua inclusão no sistema de despacho pelo operador de sistema elétrico. O trabalho proposto apresenta os fatores, parâmetros e critérios fundamentais para a escolha de um método de previsão que seja adequado a um determinado conjunto de critérios. A partir desta visão, o trabalho é organizado na forma de uma revisão bibliográfica (estado da arte) com os principais métodos utilizados para a previsão da radiação solar e da geração para sistemas fotovoltaicos.

Palavras-chave: *Previsão da Radiação Solar, Métodos de Previsão, Sistemas fotovoltaicos.*

Área temática: *Radiação Solar*

Subárea temática: *Recursos Solares e Meteorologia da Radiação Solar*

ESTADO DA ARTE PARA PREVISÃO DA RADIAÇÃO SOLAR

Samira Fontes Domingos – samirafisica@yahoo.com.br

Universidade Federal de Minas Gerais, Programa de Pós-Graduação em Engenharia Elétrica

Luís Guilherme Monteiro Oliveira – luiz.monteiro@gmail.com

Pontifícia Universidade Católica de Minas Gerais, Curso de Engenharia de Energia

Wallace do Couto Boaventura – wventura@cpdee.ufmg.br

Universidade Federal de Minas Gerais, Programa de Pós-Graduação em Engenharia Elétrica

Área: 1. Radiação Solar. Subárea: 1.1. Recursos solares e meteorologia da radiação solar

Resumo. Com o importante crescimento da utilização de fontes renováveis de energia no mundo e no Brasil, torna-se cada vez mais eminente a obtenção de uma boa precisão na previsão de tais fontes de energia, principalmente para as energias solar e eólica, as quais apresentam alta intermitência. Este avanço possibilitaria o aumento do uso das fontes renováveis de energia, permitindo, por exemplo, sua inclusão no sistema de despacho pelo operador de sistema elétrico. O trabalho proposto apresenta os fatores, parâmetros e critérios fundamentais para a escolha de um método de previsão que seja adequado a um determinado conjunto de critérios. A partir desta visão, o trabalho é organizado na forma de uma revisão bibliográfica (estado da arte) com os principais métodos utilizados para a previsão da radiação solar e da geração para sistemas fotovoltaicos.

Palavras-chave: Previsão da Radiação Solar, Métodos de Previsão, Sistemas fotovoltaicos.

1. INTRODUÇÃO

Entre as fontes renováveis de energia, atualmente, as energias eólica e solar estão entre as mais promissoras pelos seus potenciais, aplicações e disponibilidade. O Sol, sendo uma fonte de energia, atua próximo a um corpo negro com uma temperatura de superfície de 5800 K e provê, constantemente, em média, 1367 W/m² de irradiância fora da atmosfera terrestre. Estudo realizado por Shaw (2015) aponta que o planeta Terra recebe 1.8×10^{11} MW de potência (Ahmad Syahiman Bin Mohd Shah, 2015) apud (Utpal Kumar Das, 2018). A utilização da energia solar fotovoltaica tem crescido exponencialmente no mundo. No Brasil, nos últimos anos, o setor fotovoltaico também vem acompanhando a tendência mundial e, portanto, tem tido um crescimento muito expressivo. A geração centralizada, juntamente com a micro e mini geração distribuída fotovoltaica, somam forças para o crescimento da potência instalada total de energia fotovoltaica no país. A queda dos preços dos equipamentos (conversores estáticos / módulos fotovoltaicos), melhora nas políticas públicas (Resoluções Normativas / incentivos fiscais) e avanços na tecnologia ajudam a impulsionar a energia solar. (Utpal Kumar Das, 2018)

Um dos principais obstáculos dessa tecnologia é que a sua geração é variável ao longo do tempo, ou seja, é totalmente dependente das condições climáticas e nebulosidade da região. Essa situação é recorrente, principalmente, em climas tropicais, que apesar de terem alto índices de radiação solar, possuem também, altos índices de nebulosidade. Essa instabilidade, recebida pelos módulos fotovoltaicos instalados nas usinas solares, pode ocasionar flutuações na tensão gerada e também na frequência, tornando-se um dos obstáculos para o crescimento da tecnologia (Nobre, 2015).

A geração fotovoltaica, como já mencionado, possui natureza estocástica e está relacionada com variáveis climáticas tais como: temperatura ambiente, vapor de água, níveis de aerossol e, em particular, movimento / velocidade, altura e formas geométricas das nuvens (Gokhan Mert Yagli, 2019).

De acordo com o instituto global CCS (Global CCS Institute, 2017), a intermitência na capacidade de geração da energia fotovoltaica, no entanto, é diferente de várias maneiras. Primeiro, a variação em grande escala na geração fotovoltaica é, geralmente, na forma da função senoidal clássica aumentando de um mínimo da manhã para um máximo ao meio-dia, e depois uma redução no pôr-do-sol. Isso contrasta com as cargas residenciais que tendem a terem picos de energia no início do período noturno. Entretanto, a carga total do sistema elétrico, se correlaciona melhor com o padrão senoidal clássico associado à geração solar. Em segundo lugar, a variação na geração fotovoltaica é causada por nuvens e não é facilmente previsível. Embora os esforços de pesquisa estejam sendo feitos nesta área, ainda não está suficientemente claro / definido quais métodos de previsão são os mais adequados. Em terceiro lugar, as empresas de energia do setor elétrico precisam de mais experiência, no que se trata de energias renováveis, para conseguir manter um fornecimento de energia confiável.

De acordo com a Empresa de Pesquisas Energéticas (EPE, 2016) estudos apontam algumas soluções para lidar com a variabilidade das fontes renováveis não despacháveis e, assegurar a estabilidade do sistema garantindo assim, a segurança de suprimento energético. Cabe salientar que entre as principais soluções, destacam-se a previsão da geração de energia elétrica de um sistema fotovoltaico / eólico.

Um estudo realizado por (Yagli, Yang e Dipti, 2019) concluiu que 25% na melhoria da previsão da radiação solar pode economizar 1,56% (US\$ 46,5 milhões) nos custos de geração de energia. (Gokhan Mert Yagli, 2019).

Este artigo tem por objetivo realizar uma revisão bibliográfica sistemática de métodos para a previsão da radiação solar aplicada, em especial, na geração de energia solar fotovoltaica e também, definir os fatores e parâmetros para a definição de um método adequado a ser utilizado.

2.1 Radiação Solar

O estudo da radiação solar é fundamental para a utilização apropriada de tecnologias solares. Para a utilização e conversão da energia solar, precisão, exatidão e contínuos dados e séries históricas de dados solarimétricos são essencialmente importantes. Contudo, estabelecer um método de previsão, preciso e eficiente, desempenha um papel vital para o desenvolvimento da energia solar, principalmente, na geração em grandes usinas solares (He Jiang, 2017).

Muitos pesquisadores no mundo têm trabalhado em diferentes métodos para resolver esse importante problema. Para (Yang, Kleissl, Gueymardc, Pedro, & Coimbra, 2018) o domínio da previsão da intermitência solar e eólica representa o maior desafio para a mudança da base de combustíveis fósseis na produção de energia para uma base 100% de fontes renováveis de energia. Em sua pesquisa realizada no “Google Acadêmico”, (Yang, Kleissl, Gueymardc, Pedro, & Coimbra, 2018) verificou que para os termos *solar irradiance forecasting* e *PV power forecasting* retornam-se 15.700 e 6.340 resultados respectivamente apenas para o ano de 2016.

Existem regiões onde realizar o estudo da radiação solar torna-se complicado, portanto, é necessário um estudo de previsão da radiação solar (Markvart, Fragaki, & Ross, 2006).

De acordo com o (Operador Nacional do Sistema Elétrico (ONS), 2017) “No âmbito da Programação da Operação Eletroenergética é desenvolvida a avaliação, de curto prazo, das condições de suprimento. São estabelecidas diretrizes para a operação elétrica nos horizontes quadrimestral e mensal, e definido o Programa Mensal de Operação (PMO) e suas revisões semanais, com as diretrizes para a operação energética: intercâmbios de energia inter-regionais, geração térmica e metas de níveis de armazenamento dos reservatórios, em função das condições previstas de carga e afluentes. Na programação diária da operação, são estabelecidos os despachos de geração, intercâmbios e intervenções previstas nos equipamentos do sistema para o dia seguinte. No caso das grandes centrais de geração fotovoltaicas como contribuintes para a energia do país, para uma boa programação do despacho de energia, é importantíssimo ter uma boa previsão da radiação solar e assim, uma boa previsão de geração do sistema.”

As usinas Termelétricas e Hidrelétricas são utilizadas para absorver as flutuações de energia elétrica. Para compensar a variabilidade e pouca previsibilidade de fontes renováveis de energia como a solar e eólica, as termelétricas necessitam estar em modo de espera em uma operação sem carga, resultando em largas perdas econômicas para as empresas. Uma boa previsão da radiação solar para sistemas fotovoltaicos pode reduzir esse modo de espera. (Inage, 2017).

De acordo com o FERC (*United States Federal Energy Regulatory Commission*) para geradores intermitentes renováveis, para um desequilíbrio maior que 7,5% ou 10 MW são liquidados a um custo extra de 125% ou um custo decrescente de 75% para fornecer a energia desse desequilíbrio (Amanpreet Kaur, 2016).

2. FATORES DETERMINANTES PARA A ESCOLHA DE UM MÉTODO DE PREVISÃO

Para iniciar uma previsão, é importante definir três parâmetros: Horizonte de previsão, Intervalo e Resolução da previsão (ou resolução espacial) (Amanpreet Kaur, 2016).

De acordo com (Eurostat Statistics Explained, 2019) o Horizonte de previsão é o comprimento do tempo no futuro para que a previsão será preparada. A definição de Resolução espacial para (Meteogroup, 2019) é a densidade de grades geográficas que estão sendo usadas para rastrear as condições atmosféricas. Pequenas grades oferecem alta resolução espacial, e resultados com maior precisão, mas exigem um esforço computacional elevado.

O trabalho de (Maimouna Diagne, 2013) define três Horizontes de previsão: intra-hora (*intra-hour*), intra-dia (*intra-day*) e dia seguinte (*day ahead*) relacionado com as atividades do operador da rede elétrica. O trabalho de (Utpal Kumar Das, 2018) define as faixas para o Horizonte de previsão. Horizonte de previsão de muito curto prazo (*Very short-term forecast horizon*) é a previsão desde poucos segundos até muitos minutos (<1h). Esse tipo de previsão é usado para suavização de energia, despacho de eletricidade em tempo real e reservas ideais. (Yang, Ye, Lim, & Dong, 2015) indica a previsão de muito curto prazo para aplicações em grandes instalações fotovoltaicas. Previsão de curto prazo (*Short-term forecasting*) é usado para previsão entre 1h a 7 dias e garante a programação e despacho de energia elétrica sendo assim, útil para projetar a gestão de um sistema de energia. O trabalho de (M.Nobre, et al., 2016) aborda diferentes métodos de previsão para curto prazo. Previsão de Médio prazo (*Medium-term forecasting*) é realizada entre uma semana e um mês. Esse tipo de previsão facilita o planejamento do sistema de energia e o cronograma de manutenção, prevenindo a disponibilidade da energia elétrica no futuro. Previsão de Longo prazo (*Long-term forecasting*) é feito de um mês até um ano sendo útil para planejar a geração, transmissão e distribuição de energia e sua operação de segurança.

Para (Carlos F.M. Coimbra, 2013) o Horizonte de previsão é uma função da altura e velocidade da nuvem. Para baixas alturas e velocidades, o máximo horizonte de previsão será entre 5–25 min para evitar erros de deformação da nuvem e perspectiva.

“De um modo geral, a previsão pode ser determinística, previsão de ponto central (*point forecasting*) ou probabilística. A previsão determinística destina-se à previsão de um valor de produção fotovoltaica (FV) por cada

instante de tempo t , enquanto que a previsão probabilística, normalmente usada para previsão de incertezas associadas à previsão, gera uma banda probabilística que indica a probabilidade de ocorrência de determinados valores de produção. Os métodos determinísticos para previsão de produção podem ainda dividir-se, segundo (João Gari da Silva Fonseca Jr., 2011) apud (Lima S. D., 2014), em métodos diretos e métodos indiretos:

- Métodos diretos ou métodos com introdução de variáveis endógenas – quando as variáveis usadas no modelo dizem apenas respeito àquilo que os módulos FVs conseguem captar. Normalmente, apenas são usadas informações relativas à produção em instantes anteriores (horas ou dias) e acrescentam metodologias semelhantes à usada para o modelo de céu limpo;
- Métodos indiretos ou métodos com introdução de variáveis exógenas – utilizam informação de fontes exteriores aos módulos FVs. Essas fontes correspondem, frequentemente, a sistemas de previsão meteorológica, como é o caso dos sistemas que utilizam, por exemplo, o método de Previsão Numérica do Tempo (*Numerical Weather Prediction* – NWP). Podem ainda acrescentar informação sobre a produção de energia de sistema fotovoltaicos em instantes anteriores. (Lima S. D., 2014)

O trabalho de (Neves, 2010) indica modelos regionais/ locais que facilitam o entendimento de detalhes do comportamento da atmosfera sobre uma região específica e assim, é possível identificar fenômenos meteorológicos de pequena escala.

3. MERCADO DE ENERGIA E PREVISÃO

O sistema elétrico está se tornando bem diversificado devido à entrada de pequenos, médios e grandes sistemas de geração, principalmente oriundos da geração distribuída e centrais FVs, e assim, apresentam questões referentes à acomodação da energia injetada na rede elétrica, ao planejamento para a compra de energia nos leilões e aos investimentos que precisam ou não ser realizados. Dessa forma, tem acontecido um crescimento significativo das fontes renováveis de energia na composição do setor elétrico nacional. E com esse crescimento, surge a demanda de uma melhoria na estimação do montante de energia proveniente das fontes renováveis de energia (solar/eólica). “Essa estimação é requerida por planejadores e concessionárias para fazerem o balanço correto da geração baseada em alternativas, hídricas e fósseis. Uma estimativa correta, poupa gastos desnecessários com combustíveis, evita emergência na compra de energia e é útil para a manutenção, armazenamento de energia e sua comercialização.” (Paixão, 2019) Apud (Bhola & Bhardwaj, 2016)

A ONS utiliza diferentes modelos para o cálculo da previsão de cargas no sistema elétrico nacional. O modelo matemático DESSEM é utilizado na programação diária, para médio prazo, é usado o modelo *Newave* e para curto prazo, é utilizado o modelo *Decomp*. O *Newave* utiliza cenários hidrológicos de cinco anos, O DESSEM auxilia na definição do despacho de usinas térmicas a cada 30 minutos, enquanto o *Decomp* é usado no Programa Mensal de Operação. As mudanças nesses modelos, decorrentes do crescimento da energia solar FV e eólica serão aplicadas a partir de 2020. (Canal Energia, 2019)

4. MÉTODOS DE PREVISÃO SOLAR

Na atualidade, existem diversas e distintas metodologias para previsão do recurso solar dentre os quais é possível destacar os métodos empíricos, os estatísticos e os numéricos ou modelos físicos de previsão da radiação solar, de acordo com (C. Renno, 2016). Além disso, há também alguns métodos consolidados sendo que os principais pontos que os diferem é o tempo que se conseguem realizar a previsão e sua resolução.

De acordo com (Nobre, 2015), dentro do método estocástico há uma enorme variação de tempo, dependendo da junção das técnicas selecionadas. (Kaur, Nonnenmacher, Pedro, & Coimbra, 2016). Já o autor (Maimouna Diagne, 2013) separa em duas grandes áreas com os diversos métodos, ou seja, a Previsão Numérica do Tempo (*Numerical Weather Prediction* – NWP) e a estatística além de separar as técnicas que utilizam, como exemplo, as imagens de satélite e o imageador (*Sky imager*). No entanto, atualmente, existem muitas publicações sobre distintas metodologias de previsão do recurso solar, o que dificulta a separação entre os métodos é a enorme variedade de nomenclaturas utilizadas na comunidade científica (Yang, Kleissl, Gueymard, Pedro, & Coimbra, 2018). Ou seja, um mesmo método pode apresentar diferentes nomenclaturas e assim a dificuldade em evoluir o método aumenta.

Diferentes autores organizam os métodos distintamente também, pois cada um considera características diferentes para agrupar e separar os modelos. A seguir serão apresentados diversos autores com experiências distintas para cada método. O trabalho de (Utpal Kumar Das, 2018), por exemplo, define quatro grandes grupos metodológicos baseados no uso de dados históricos de potência de saída de um sistema fotovoltaico e relacionados com variáveis meteorológicas.

A Fig. 1 apresenta diversos métodos em relação às resoluções espacial e temporal e a Fig. 2, gerada por (Yang, Kleissl, Gueymard, Pedro, & Coimbra, 2018), ilustra a separação entre os diversos métodos de previsão utilizados, através de um Dendograma, considerando as publicações nas mais importantes revistas científicas da área. Além disso, essa figura apresenta também a frequência de uso de cada método e agrupa diversos métodos em cada grupo e assim, expõe uma variedade de nomenclaturas.




Figura 1: Diferentes métodos de previsão em relação à resolução espacial e resolução temporal.
Fonte adaptada: (Maimouna Diagne, 2013)




Figura 2 Dendograma ilustrando a variedade de nomenclaturas para a previsão de radiação solar – adaptado de (Yang, Kleissl, Gueymardc, Pedro, & Coimbra, 2018).

Na Fig 2, são agrupados diferentes métodos em basicamente 5 grandes grupos: Séries temporais (*Times Series*), Regressão (*Regression*), Previsão numérica do tempo ou NWP (*Numerical weather prediction*), Aprendizado de máquina (*Machine Learning*) e Previsão por base de imagem (*Image bases Forecasting*). Porém, um outro método que não aparece na Fig. 2, mas que é considerado relevante e muito utilizado é a metodologia da Persistência (*Persistence*). Todos os 5 grandes grupos de métodos serão detalhados a seguir.

4.1 Método da Persistência (*Persistence Method*)

O método da Persistência supõe que o próximo horizonte de tempo seja a mesma condição que a condição anterior. É frequentemente usada como um padrão de comparação para medir o grau de habilidades das previsões de outros métodos, especialmente para projeções (Meteorology glossary, 2019).

Dessa forma, Persistência é um método elementar, mas amplamente utilizado. Ele é considerado como um padrão de referência para a validação de um novo método. É mais utilizado em Previsão de curto prazo (*Short-term forecasting*), para uma resolução temporal de até 1h. Se a condição climática do local não muda muito, Persistência pode ter um pequeno erro e funciona bem para locais cuja a temperatura ambiente é elevada.

Continuamente surgem novas evoluções do método persistência usado como padrão de comparação em relação a outros métodos de previsão, como o método “*stochastic persistence*” (Voyant & Notton, 2018) e uma junção entre o método persistência e climatologia resultado no método “*naïve forecasting*” de acordo com (Yang D. , 2019).

4.2 Método Séries Temporais (*Times series Method*)

De acordo com (Stefan Achleitner, 2014), as séries temporais têm sido aplicadas com sucesso para um grande espectro de horizonte temporal, de 1 a 24 horas.

Um método é classificado como um método de série temporal se o mesmo se identificar em uma das três famílias de modelos, ou seja, ARIMA ou GARCH, Heteroscedasticidade condicional auto-regressiva generalizada ou GARCH (*generalized autoregressive conditional heteroskedasticity*) sendo este último mais aplicável para séries temporais financeiras.

O trabalho de (Utpal Kumar Das, 2018) define os grupos Série temporal e Regressão juntos em uma abordagem estatística. Nesse grupo, inclui o modelo Auto-regressivo de médias móveis ou ARMA (*Autoregressive moving average*) que tem a capacidade de extrair propriedades estatísticas. Para o autor, uma evolução desse primeiro método é o Modelo auto-regressivo integrado de médias móveis ou ARIMA (*autoregressive integrated moving average*), onde a parte integrável remove qualquer não estacionariedade dos dados e é um dos métodos mais utilizados, por ser um método de referência também. A Eq. (1) demonstra o processo ARIMA, de acordo com (Nelson, 1973) apud (Lemes, 2014):

$$\hat{Y}_t = \mu + (\phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p}) - (\theta_1 e_{t-1} + \dots + \theta_q e_{t-q}), \text{ sendo: } \hat{Y}_t = Y_t - Y_{t-d} \quad (1)$$

Onde: μ é a constante, p é o número de termos autorregressivos (AR), q é o número de médias móveis (MA), ϕ_p e θ_q representam os parâmetros dos processos AR e MA de ordem p e q , e_t corresponde ao erro de eventos aleatórios que não podem ser explicados pelo modelo, d equivale ao grau de homogeneidade não-estacionária, $(\phi_1 Y_{t-1} + \dots + \phi_p Y_{t-p})$ são os termos AR (valores de *lagged* de y , ou seja, valores atrasados de y) e $(\theta_1 e_{t-1} + \dots + \theta_q e_{t-q})$ são os termos MA (valores de *lagged* dos erros, ou seja, valores atrasados dos erros).

A principal desvantagem dos modelos de séries temporais na previsão solar é talvez a falta de modelagem física durante a previsão. A variabilidade da irradiância solar e das séries temporais relacionadas deve-se, principalmente, às nuvens e sistemas climáticos. Ignorar esses fatores na previsão de séries temporais, geralmente, resulta em previsões que parecem estar atrasadas (Yang, Kleissl, Gueymardc, Pedro, & Coimbra, 2018).

4.3 Método Regressão (*Regression Method*)

O método da Regressão é um processo estatístico e o trabalho de (Utpal Kumar Das, 2018) define Regressão como um método que é usado para estabelecer um relacionamento entre variáveis. Para o uso em sistema de previsão em sistemas fotovoltaicos, a potência prevista é considerada uma variável dependente e as variáveis meteorológicas são consideradas variáveis explicativas.

Com o método Regressão linear múltipla ou MLR (*multiple linear regression*) é possível inserir muitas entradas como velocidade do vento, temperatura ambiente, umidade relativa do ar, cobertura de nuvens, localização, tempo. Nesse método, a seleção de variáveis é fundamental para melhorar a previsibilidade e a interpretabilidade.

Uma aplicação particularmente promissora do MLR na previsão do recurso solar é previsão espaço-temporal que utiliza de dados de uma rede de monitoramento de tamanho apropriado. Como as nuvens em movimento são as principais fontes de variabilidade de irradiância, à medida que as nuvens se propagam pela rede de monitoramento, os dados coletados pelos sensores vizinhos podem ser usados como preditores para o local da previsão. No entanto, o número de preditores pode se tornar muito grande conforme o número de sensores na rede aumenta. Nessa situação, pode-se filtrar os preditores selecionando apenas as séries temporais defasadas coletadas pelos sensores em oposição a direção do vento.

Foi demonstrado que, ao fazer isso, os preditores de vento selecionados podem efetivamente ajudar a prever os eventos de rampa em locais a favor do vento e alcançar alta habilidade de previsão. Entretanto, os horizontes de previsão usando esses métodos são muitas vezes limitados pelo tamanho da rede de monitoramento. A correspondência entre a escala espacial da rede e o horizonte de previsão requer um estudo mais aprofundado.

Nos métodos estatísticos espaço-temporais, o valor da irradiância futura para uma determinada estação é prevista baseada no passado e na radiação solar atual no local determinado e nas estações vizinhas (Aloysius W. Aryaputera, 2015).

O método LASSO (*least absolute shrinkage and selection operator*), tem sido usado na previsão solar ao lado de outros métodos de seleção de variáveis. O LASSO aos poucos tem sido usado para identificar preditores mais apropriados para um dado período de tempo (Yang, Ye, Lim, & Dong, 2015).

Contudo, o rendimento do Lasso é limitado pela correlação espaço temporal observada. Com a baixa densidade de estações há uma baixa correlação entre as estações e assim, o rendimento do LASSO torna-se abaixo de um nível ótimo. A Eq. (2) apresenta o método LASSO, de acordo com (Tibshirani, 1996):

$$\hat{\beta} = \underset{\beta}{\operatorname{argmin}} \left\{ \sum_{i=1}^n (y_i - \alpha - \sum_{j=1}^p \beta_j x_{ij})^2 + \lambda \sum_{j=1}^p |\beta_j| \right\} \quad (2)$$

Onde: λ é o parâmetro de sintonização, t determina quantos coeficientes de $\hat{\beta}$ poderão ser zerados e refere-se ao número de preditores, y_i são as respostas, α é o intercepto, p é o número de preditores, β_j são os coeficientes de regressão, x_{ij} são as variáveis preditoras e n é o número de observações.

4.4 Método de Previsão numérica do tempo ou NWP (*Numerical weather prediction Method*)

O método NWP é um modelo utilizado para calcular diretamente os fluxos de irradiância em múltiplos níveis na atmosfera, considerando separadamente as partes de ondas curtas e ondas longas do espectro solar. Alguns NWP são famosos por serem *open-source*. É um modelo desenvolvido atualmente para o horizonte de previsão do dia seguinte, de acordo com (Perez et al., 2013); (Yang, Quan, Disfani, & Liu, 2017). De acordo com (Amanpreet Kaur, 2016) o modelo NWP gera bons resultados para previsão de curto prazo, geralmente, para horizontes maiores que 4 horas, sendo uma metodologia competitiva com as previsões baseadas em imagens de satélite para uma resolução temporal de 1 a 6h (Stefan Achleitner, 2014). A Eq. (3) apresenta a formulação do modelo NWP na sua forma simples, de acordo com (Cavalcanti).

$$\frac{\Delta A}{\Delta t} = F(A) \quad (3)$$

Onde: ΔA é a mudança na variável a ser prevista, Δt é o horizonte temporal e $F(A)$ representam os termos que podem causar mudanças no valor de A .




Figura 3: Evolução anual do método NWP entre 3 e 10 dias no Hemisfério Norte (HN) e no Hemisfério Sul (HS). (Bauer, Thorpe, & Brunet, 2015)

O modelo de Pesquisa climática e o modelo de previsão ou WRF (*Weather Research and Forecasting Model*) foi desenvolvido como uma cooperação entre vários pesquisadores de diversos institutos de pesquisas / universidades no mundo. Ele primeiro foi usado para numeração clássica de previsões climáticas, sendo, posteriormente, adaptado para aplicações de energia renovável. Recentemente, o WRF ganhou impulso para a previsão do dia seguinte da radiação solar. No Brasil, existem alguns grupos de pesquisa trabalhando no assunto, em diferentes metodologias. (Lima, Martins, & Pereira, 2014) utiliza o método WRF, junto com métodos estatísticos para realizar previsão do recurso solar.

A Fig 3 ilustra a evolução do método NWP com o passar dos anos a partir do uso do *Forecast skill* FS. Valores acima de 60% indicam previsões úteis, enquanto FS maiores que 80% representam um alto grau de precisão. A partir do ano de 1999 as informações de satélites foram incorporadas no método.

4.5 Método Aprendizado de máquina ou ML (*Machine Learning Method*)

O método de Aprendizado de máquina (ML) é uma das abordagens mais populares na previsão do recurso solar. É importante devido à sua capacidade de executar mapeamentos não lineares arbitrários.

Algoritmos ML baseiam-se no conceito de padrões de aprendizado e modelo dos dados, onde a aprendizagem implica classificação, regressão e previsão. Neste sentido, os algoritmos ML são adequados para a previsão da radiação solar. Aplicações de previsão do recurso solar consistem em criar modelos preditivos para valores pontuais ou intervalos de previsão baseados em conjunto de dados de dados históricos. O conjunto de dados, geralmente, contém o destino ou variável (irradiância ou potência fotovoltaica) e pode conter qualquer número de preditores, como previsões do NWP ou dados meteorológicos.

Os métodos ML são técnicas estatísticas capazes de identificar tendências e reduzir, substancialmente, o viés em relação ao conjunto de validação. A robustez dos modelos ML depende da diversidade do conjunto de dados, o método e a habilidade das variáveis para capturar o espaço de soluções necessárias para reproduzir as saídas, e muito importante, a figura de mérito usada para validar os resultados. Sobrepondo métodos ML com outros métodos quase sempre resulta em melhores previsões se um amplo conjunto de precisão de previsão métricas é utilizada.

Uma rede neural artificial ou ANN (*Artificial Neural Network*) é uma linha importante dentro do método ML e consiste em um processador paralelo maciço, composto de processamento simples (“neurônios”), que têm a capacidade de armazenar conhecimento (pesos sinápticos) e tornando-o disponível para uso posterior. Os principais benefícios das redes neurais podem ser ligados à sua capacidade de operar de forma não linear, o que os torna adequados para manipular fenômenos com modelos físicos complexos, que, na maioria dos casos, são difíceis ou impraticáveis para resolver através de funções lineares (Yang, Kleissl, Gueymard, Pedro, & Coimbra, 2018).

O método ML e as técnicas estatísticas de previsão da radiação solar são comumente usadas com uma resolução temporal de intra-hora e Previsão de curto prazo. (Pedro and Coimbra, 2012); (Yang, Quan, Disfani, & Liu, 2017). “No modelo MLP, a rede neural é construída com camadas de neurônios artificiais dispostas em sequência: uma camada de entrada, onde entram as informações; uma sequência de camadas ocultas, onde ocorrem uma série de processamentos capazes de abstrair em vários níveis as informações recebidas”. (Silva, 2019) A Eq. (4) define o modelo MLP para 2 camadas ocultas.

$$h(x|w, b) = \sigma(w^4 \sigma(w^3 \sigma(w^2 x + b^2) + b^3) + b^4) \quad (4)$$

Onde: σ é uma função de ativação vetorizada, w é o peso sináptico da conexão com o neurônio e sua saída e b o viés do neurônio.

4.6 Método por Imagens (*Image-based forecasting Method*)

As imagens retiradas do céu ou da Terra (extraterrestres) podem somar à habilidade de previsão do recurso solar, pois fornecem aviso antecipado de aproximação de nuvens em um tempo de espera de vários minutos a horas. Este tempo é muito superior ao tempo de um único radiômetro.

A variabilidade da radiação solar que chega ao solo é, principalmente, causada por movimento de nuvens. Para prever o recurso solar com precisão / exatidão, a informação de nuvens deve ser incorporada à formulação, direta ou indiretamente. Entretanto, devido à natureza estocástica das nuvens, é difícil de modelar totalmente sua geração, propagação e extinção usando abordagens físicas (Yang, Ye, Lim, & Dong, 2015).

“Normalmente são modelos com as seguintes etapas: aquisição das imagens no local em que se pretende prever a radiação solar incidente; análise das imagens de forma a identificar as nuvens e distinguir a sua opacidade; estimativa do vector de movimento das nuvens usando as imagens sucessivas; uso da localização das nuvens e vector de movimento das mesmas para a previsão a curto prazo de forma determinística ou estatística da cobertura das nuvens, radiação solar e produção fotovoltaica (S. Pelland, 2013) apud (Duarte, 2019).”

Ao usar dados de satélite, um dos desafios está no tempo e sincronização espacial entre a própria imagem do satélite e as medidas registradas e realizadas em solo por estações solarimétricas. Um outro problema é ignorar a natureza 3D das nuvens e a altura da mesma, aumentando o erro da previsão. Mas é possível fazer previsões de longo prazo. Para distâncias entre estações maiores que 30 km, avaliação de recursos solares com base em medições de satélites são preferíveis, de acordo com (Jose´ A. Ruiz-Arias, 2015).

Para previsões de intra-dia e para resoluções temporais abaixo de 4 h, a utilização de técnicas que utilizam satélite é indicada. (L. Nonnenmacher, 2014) apud (Amanpreet Kaur, 2016) .

Previsões que utilizam como entrada dados de satélites são, geralmente, executadas em uma resolução horária devido à resolução temporal das imagens de satélite (e.g., Voyant et al., 2014);

O método que usa fotos do céu, denominado de Imagem total do céu ou TSI (*Total Sky Imager*), feitas com uma *sky camera* possibilita um estudo mais profundo da dinâmica de nuvens e consegue bons resultados para tempos curtos. No inverno do hemisfério norte, com uma maior cobertura de nuvens, o método se mostra mais eficaz do que no verão, onde as previsões prevalecem devido ao céu quase limpo (Chu, Li, & Coimbra, 2016). Essa técnica utiliza de imagens de um sistema de rastreamento solar para realizar previsões de radiação solar. O método TSI é indicado por (Amanpreet Kaur, 2016) para se trabalhar com previsões intra-hora.

Um grande problema desse método é que a lente mais utilizada para essa medição, a “lente olho de peixe” (*fisheye lens*) distorce o movimento das nuvens em relação ao Sol, causando erros na previsão. Todavia, aumentando a resolução espacial e o detalhamento da geometria Sol-nuvens diminui esses erros.

No entanto, mesmo assim, questões de perspectiva contribuem para a maioria dos erros de previsão quando uma única câmera é usada e a natureza 3D das nuvens é negligenciada. Esse tipo de previsão requer múltiplas câmeras distribuídas para resolver a tridimensionalidade das nuvens.

Abordagens baseadas no uso de *Sky câmera* (e.g., Yang et al., 2014) rendem melhor em um horizonte de previsão acima de 15 min (Yang, Quan, Disfani, & Liu, 2017).

O *Sky scanner* é um instrumento amplamente utilizado como estudos das imagens do céu, mas apresenta um alto custo. Uma opção que tem crescido bastante é o uso de uma câmera simples com uma lente de olho de peixe para o mesmo fim. O trabalho de (Ignacio García1 & Ormazábal, 2019) faz uma comparação entre um *Sky scanner* e uma câmera com a lente olho de peixe e considera o uso da câmera promissor, pois a área da imagem próxima ao Sol é melhor definida e por ter a possibilidade de um controle melhor da quantidade de fotos por tempo.

A Fig 4 ilustra uma imagem bruta de um *sky imager* ou *Imagiador* juntamente com uma imagem já tratada do *Measurement and Instrumentation Data Center* (MIDC) na estação SRRL ASI-16 do NREL para o dia 26/09/2019 às 11:10h para o fuso do estado norte americano da Califórnia, nos Estados Unidos da América.




Figura 4: Exemplo de uma imagem bruta de um *Sky Imager* e outra já tratada. Fonte: (NREL, 2019)

5. CONCLUSÕES

Previsão da irradiância solar ou *forecast* é um gargalo que precisa ser solucionado para o crescimento das renováveis intermitentes no Brasil e no mundo. A previsão pode acontecer em diferentes intervalos de tempo, desde previsões de um minuto quanto um ano inteiro. Vários setores da indústria de energia necessitam dessas informações de previsão, então melhorar essa confiabilidade pode alavancar a utilização de fontes renováveis intermitentes.

O trabalho apontou três parâmetros importantíssimos para a escolha de um método de previsão, que são: Horizonte de previsão, Intervalo e Resolução espacial. Dessa forma, definidos esses parâmetros é o primeiro passo antes de escolher um método.

O presente trabalho organizou as diferentes linhas e métodos de previsão utilizados atualmente, são eles: Séries temporais (*Times Series*), Regressão (*Regression*), Previsão numérica do tempo ou NWP (*Numerical weather prediction*), Aprendizado de máquina (*Machine Learning*) e Previsão por base de imagem (*Image bases Forecasting*). Foi abordado também um outro que é normalmente utilizado como referência para avaliação de um novo método, que é o método Persistência (*Persistence*). Os métodos foram qualificados e caracterizados.

Há um trabalho de *forecasting* em curso e seus resultados serão apresentados em breve.

Agradecimentos

O presente trabalho foi realizado com o apoio financeiro da CAPES. Agradecemos o apoio da CEMIG, Pós-graduação em engenharia elétrica da UFMG – PPGE UFMG, CNPq – Brasil, FAPEMIG, PUC Minas, pró reitoria de pesquisa da PUC Minas e Curso de engenharia de energia da PUC Minas;

REFERÊNCIAS

Ahmad Syahiman Bin Mohd Shah, H. Y. (2015, april). High-Precision Forecasting Model of Solar Irradiance Based on Grid Point Value Data Analysis for an Efficient Photovoltaic System. *IEEE TRANSACTIONS ON SUSTAINABLE ENERGY*, 6.

- Aloysius W. Aryaputera, D. Y. (2015, december). Very short-term irradiance forecasting at unobserved locations using spatio-temporal kriging. *Solar Energy*, 122, pp. 1266-1278.
- Amanpreet Kaur, L. N. (2016). Benefits of solar forecasting for energy imbalance markets. *Renewable Energy*(86), 819 - 830.
- Bauer, P., Thorpe, A., & Brunet, G. (2015, September 3). The quiet revolution of numerical weather prediction. *Nature*, 47-55. Retrieved from <https://www.nature.com/articles/nature14956?proof=true>
- Bhola, P., & Bhardwaj, S. (2016). Solar Energy Estimation techniques: A review. *7th India International Conference on Power Electronics (IICPE)*.
- Brownson, J. (n.d.). *EME 810 - solar resource assessment and economics*. (PennState - Department of energy and mineral engineering) Retrieved 01 2019, 22, from <https://www.e-education.psu.edu/eme810/node/699>
- C. Renno, F. P. (2016, julho 11). ANN model for predicting the direct normal irradiance and the global radiation for a solar application to a residential building. *Journal of Cleaner Production*, pp. 1298 -1316.
- Canal Energia. (2019, agosto 7). Retrieved from <https://canalenergia.com.br/noticias/53107832/aplicacao-do-dessemm-vai-reduzir-geracao-fora-da-ordem-de-merito-diz-ons>
- Carlos F.M. Coimbra, J. K. (2013). Overview of Solar-Forecasting Methods and a Metric for Accuracy Evaluation. In *Solar Energy Forecasting and Resource Assessment* (pp. 172-192). Elsevier Inc.
- Cavalcanti, E. P. (n.d.). *NWP Equations (Adapted from UCAR/COMET Online Modules)*. UFCG - CTRN, Departamento de Ciências atmosféricas, Unidade acadêmica de ciências atmosféricas, Modelagem numérica da atmosfera, Campina Grande. Retrieved 02 12, 2020, from <http://www.dca.ufcg.edu.br/mna/Anexo-MNA-modulo01f.pdf>
- Chu, Y., Li, M., & Coimbra, C. F. (2016). Sun-tracking imaging system for intra-hour DNI Forecasts. *Renewable Energy*, pp. 792-799.
- Duarte, M. G. (2019). Previsão de produção de energia fotovoltaica a curto prazo recorrendo a imagens de céu integral. *Dissertação de Mestrado Integrado em Engenharia da Energia e do Ambiente. Universidade de Lisboa. Faculdade de ciências. DEPARTAMENTO DE ENGENHARIA GEOGRÁFICA, GEOFÍSICA E ENERGIA. Lisboa, Portugal.*
- EPE. (2016). *Energia Renovável: hidráulica, biomassa, eólica, solar, oceânica*. Rio de Janeiro.
- Eurostat Statistics Explained. (2019, 10 17). *Glossary*. Retrieved from https://ec.europa.eu/eurostat/statistics-explained/index.php/Glossary:Forecast_horizon
- Global CCS Institute. (2017, outubro 26). Retrieved from <https://hub.globalccsinstitute.com/publications/solar-intermittency-australias-clean-energy-challenge/61-potential-electricity-network-impacts>
- Gokhan Mert Yagli, D. Y. (2019, February). Reconciling solar forecasts: Sequential reconciliation. *Solar Energy*, 179, pp. 391-397.
- He Jiang, Y. D. (2017). A multi-stage intelligent approach based on an ensemble of two-way interaction model for forecasting the global horizontal radiation of India. *Energy Conversion and Management*(137), 142–154.
- Ignacio García1, M. d., & Ormazábal, M. (2019). Evaluation of Two Procedures for Selecting the CIE Standard Sky Type Using High Dynamic Range Images. *ISES Solar World Congress 2019*. Santiago.
- Inage, S.-i. (2017). Development of an advection model for solar forecasting based on ground data first report: Development and verification of a fundamental model. *Solar Energy*(153), 414–434.
- J. A. Ruiz-Arias, H. G. (2017, Oct 19). *How Solargis is improving accuracy of solar power forecasts*. Retrieved from Solar Gis: <https://solargis.com/blog/best-practices/improving-accuracy-of-solar-power-forecasts>
- Joao Gari da Silva Fonseca Jr., T. O. (2011, julho). Use of support vector regression and numerically predicted cloudiness to forecast power output of a photovoltaic power plant in kitakyushu japan. *Progress in Photovoltaics: Research and Applications*, pp. 874-882.
- Jose´ A. Ruiz-Arias, S. Q.-R. (2015). Optimal combination of gridded and ground-observed solar radiation data for regional solar resource assessment. *Solar Energy*(112), 411–424.
- Kaur, A., Nonnenmacher, L., Pedro, H. T., & Coimbra, C. F. (2016). Benefits of solar forecasting for energy imbalance markets. *Renewable energy*, pp. 819-830.
- L. Nonnenmacher, C. C. (2014). Streamline-based method for intra-day solar forecasting through remote sensing. *Solar Energy*, 108, pp. 447-459.
- Lemes, L. R. (2014). *Modelo de avaliação de risco para predição de preço de carne bovina utilizando inteligência computacional*. Universidade de São Paulo. Pirassununga: Faculdade de zootecnia e engenharia de alimentos. Retrieved 02 12, 2020, from <https://teses.usp.br/teses/disponiveis/74/74132/tde-28012015-141146/publico/DO2343880COR.pdf>
- Lima, F. J., Martins, F. R., & Pereira, E. B. (2014, Setembro 16-19). Forecast of short-term solar irradiation in Brasil using numerical models and statistical post-processing. *EuroSun*.
- Lima, S. D. (2014, julho 31). Previsão de Produção de Centrais Solares Fotovoltaicas. *Mestrado Integrado em Engenharia Eletrotécnica e de Computadores. U. Porto. FEUP. Faculdade de engenharia. Universidade do Porto. Porto.*
- M.Nobre, A., A.Severiano Jr., C., Karthik, S., Kubis, M., Zhao, L., R.Martins, F., . . . Reindl, T. (2016, August). PV power conversion and short-term forecasting in a tropical, densely-built environment in Singapore. *Renewable Energy*, 94, pp. 196-509.

- Maimouna Diagne, M. D. (2013). Review of solar irradiance forecasting methods and a proposition for small-scale insular grids. *Renewable and Sustainable Energy Reviews*(27), 65–76.
- Markvart, T., Fragaki, A., & Ross, J. (2006). PV system sizing using observed time series of solar radiation. *Solar Energy*, 80, 46–50.
- Marquez, R., & Coimbra, C. F. (2013). Proposed Metric for evolution of solar forecasting models. *Journal of solar energy engineering*.
- Meteogroup. (2019, 10 17). *theglobal weather authority*. Retrieved from <https://www.meteogroup.com/38-weather-forecasting-terms-you-need-know-glossary>
- Meteorology glossary. (2019, 10 11). Retrieved from American Meteorological Society: http://glossary.ametsoc.org/wiki/Persistence_forecast
- Nelson, C. R. (1973). *Applied Time Series Analysis*. San Francisco: Holden-Day.
- Neves, R. N. (2010, março). Desenvolvimento de Modelos de Previsão de Produção de Centrais Solares Fotovoltaicas. *Dissertação realizada no âmbito do Mestrado Integrado em Engenharia Electrotécnica e de Computadores Major Energia*. FEUP. Faculdade de Engenharia da Universidade de Porto. Porto.
- Nobre, A. M. (2015). *Short-term solar irradiance forecasting and photovoltaic systems performance in a tropical climate in Singapore*. Florianópolis: Programa de Pós-graduação em engenharia civil .
- NREL. (2019, 11 26). *Mesurement and Instrumentation Data Center - MIDC - SRRRL ASI-16 Sky Imager Gallery*. Retrieved from NREL: <https://midcdmz.nrel.gov/apps/imagergallery.pl?SRRLASI>
- Operador Nacional do Sistema Elétrico (ONS). (2017, outubro 26). Retrieved from ONS: <http://ons.org.br/pt/paginas/sobre-o-ons/atuacao>
- Paixão, J. L. (2019, fevereiro 22). Avaliação do impacto da microgeração fotovoltaica na rede de distribuição de energia elétrica. *Dissertação de mestrado*. Universidade Federal de Santa Maria. Centro de tecnologia. Programa de pós-graduação em engenharia elétrica. . Santa Maria, RS, Brasil.
- S. Pelland, J. R. (2013). Photovoltaic and Solar Forecasting: State of the Art. *Int. Energy Agency Photovolt. Power Syst. Program. Rep. IEA PVPS T14*, 1-40.
- Shaw, B. (2017, november 14). *Weather Forecasting: How Does It Work, and How Reliable Is It?* Retrieved from Precision Ag: <https://www.precisionag.com/digital-farming/data-management/weather-forecasting-how-does-it-work-and-how-reliable-is-it/>
- Silva, C. Q. (2019). *Redes neurais aplicadas no reconhecimento de símbolos matemáticos manuscritos online*. Trabalho de conclusão de curso , universidade de São Paulo, Instituto de matemática e estatística, São Paulo. Retrieved 02 12, 2020, from <https://www.ime.usp.br/~map/tcc/2019/CaiqueQuaresmaV2.pdf>
- Stefan Achleitner, A. K. (2014). SIPS: Solar Irradiance Prediction System. *IPSN-14 Proceedings of the 13th International Symposium on Information Processing in Sensor Networks*.
- Tibshirani, R. (1996). Regression Shrinkage and selection via the Lasso. *Journal of the Royal Statistical Society*, 58(1), pp. 267-288. Retrieved 01 16, 2020, from <http://statweb.stanford.edu/~tibs/lasso/lasso.pdf>
- Utpal Kumar Das, K. S. (2018). Forecasting of photovoltaic power generation and model optimization: A review. *Renewable and Sustainable Energy Reviews*, 81, pp. 912–928.
- Voyant, C., & Notton, G. (2018). Solar irradiation nowcasting by stochastic persistence: A new parsimonious, simple and efficient forecasting tool. *Renew. Sustain. Energy*, 92, 343-352.
- Yagli, G. M., Yang, D., & Srinivasan, D. (2019). Reconciling solar forecasts: Sequential reconciliation. *Solar Energy*, pp. 391–397.
- Yang, D. (2019). Making reference solar forecasts with climatology, persistence, and their optimal convex combination. *Solar Energy*, 193, pp. 981-985.
- Yang, D., Kleissl, J., Gueymard, C. A., Pedro, H. T., & Coimbra, C. F. (2018). History and trends in solar irradiance and PV power forecasting: A preliminary assessment and review using text mining. *Solar Energy*, 168, 60-101.
- Yang, D., Quan, H., Disfani, V. R., & Liu, L. (2017, April). Reconciling solar forecasts: Geographical hierarchy. *Solar Energy*, 146, pp. 276-286.
- Yang, D., Ye, Z., Lim, L. H., & Dong, Z. (2015). Very short term irradiance forecasting using the lasso. *Solar Energy*(114), 314–326.

STATE OF ART OF SOLAR IRRADIANCE FORECAST

Abstract. With the significant growth of renewable energy sources in Brazil and world, it is becoming eminent get a good forecasting accuracy of energy sources, mainly for solar and Eolic, that feature high flash. This advance would increase the use of renewable energies, allowed, for example, your inclusion on dispatch system by the electrical system operator. in an order by the electrical system operator. This work shows the factors, parameters and fundamental standards to definition one appropriate forecast method for a determinate set of criteria. From that point of view, that work was organized with a bibliographic review (state of art) with the main methods used to solar irradiation forecast and photovoltaics systems generation.

Key words: Solar irradiance forecast, Forecast methods, photovoltaic systems