

# ESTUDO DE REVISÃO SOBRE AS TÉCNICAS APLICADAS NA MODELAGEM DE SUJIDADES DEPOSITADAS SOBRE A SUPERFÍCIE DE MÓDULOS FOTOVOLTAICOS

**Leticia Recco Tramontin** – leticia.recco.tramontin@grad.ufsc.br

**Giuliano Arns Rampinelli** – giuliano.rampinelli@ufsc.br

Universidade Federal de Santa Catarina, Programa de Pós-Graduação em Energia e Sustentabilidade

**Resumo.** A deposição de sujeira na superfície de módulos fotovoltaicos é uma causa relevante para perdas na geração de energia, em Belo Horizonte/MG estima-se uma redução da ordem de 11% em seis meses de medição. Este artigo apresenta uma revisão dos modelos utilizados na literatura para estimar as perdas causadas pela sujeira depositada na superfície dos módulos. O protocolo de pesquisa definiu as palavras-chave para busca de artigos publicados a partir de 2011 em seis bases de dados, cujos resultados passaram por três fases de triagem: exclusão de artigos de título não pertinentes à pesquisa, exclusão de artigos de resumo não pertinentes à pesquisa, leitura integral dos artigos e seleção dos mais relevantes para a pesquisa. Os estudos selecionados foram agrupados de acordo com o tipo de modelo. Os modelos estatísticos utilizam regressão linear e métodos similares, são práticos e simples. Os modelos baseados em redes neurais podem retornar resultados muito precisos (acima de 90%), mas são complexos e precisam de muitos dados para treiná-los. Existem ainda modelos baseados em equações lineares, exponenciais, fator de desgaste, simulação numérica, ópticos e dependentes de proporção, que foram menos explorados pelos artigos encontrados. Em geral, os modelos utilizam dados empíricos para obtenção dos resultados, o que os restringe ao local pesquisado e impedem a sua generalização para outras regiões. As análises de sensibilidade apontam que as características físicas da sujeira (composição, tamanho e outras) podem ser mais relevantes do que os parâmetros ambientais, ao passo que dentre essas variáveis a precipitação e o vento são os parâmetros ambientais mais significativos. Isso evidencia o quão desafiador é desenvolver um modelo matemático que contemple todas as variáveis de impacto. Há uma grande variedade de estudos e abordagens, ao mesmo tempo que é compará-los sem uma metodologia padronizada para as análises.

**Palavras-chave:** Energia Solar, Módulo Fotovoltaico, Sujidade

## 1. INTRODUÇÃO

A sujidade pode ser o terceiro fator ambiental mais importante no impacto do valor da potência produzida por um sistema fotovoltaico, depois da irradiância e da temperatura (Hickel, 2017). A proporção de sujidade (SR) é a razão entre a potência do módulo sujo ( $P_{sujo}$ ) e a potência do módulo limpo ( $P_{limpo}$ ). O valor “1” representa o estado limpo do módulo fotovoltaico, quanto menor a proporção de sujidade, maiores são as perdas associadas ao sistema. Dependendo da forma como o experimento é conduzido, os dados do módulo limpo podem ser obtidos a partir de valores de referência determinados na condição de referência (25 °C e 1000 W/m<sup>2</sup>) e em seguida normalizados pela temperatura e irradiância conforme Eq. (1). Essa equação pode ser modificada para a razão entre a corrente de curto-circuito do módulo sujo normalizada e a corrente do módulo limpo em condições padrão de teste normalizada, de acordo com a Eq. (2) (Braga et al., 2020).

$$SR_{P_{m\acute{a}x}} = \frac{P_{M\acute{A}X_{sujo}}}{P_{M\acute{A}X_0} * \left(1 + \gamma * (T_{m_{sujo}} - T_0)\right) * \left(\frac{POA}{G_0}\right)} \quad (1)$$

$$SR_{I_{SC}} = \frac{I_{SC_{sujo}}}{I_{SC_0} * \left(1 + \alpha * (T_{m_{sujo}} - T_0)\right) * \left(\frac{POA}{G_0}\right)} \quad (2)$$

$I_{SC_{sujo}}$  e  $P_{M\acute{A}X_{sujo}}$  são a corrente de curto-circuito e potência no ponto de máxima potência medidas no módulo com deposição de sujidade, respectivamente.  $I_{SC_0}$  e  $P_{M\acute{A}X_0}$  são a corrente de curto-circuito e potência do módulo na condição de referência, enquanto  $\alpha$  e  $\gamma$  são os coeficientes de temperatura para corrente de curto-circuito e potência, respectivamente.  $T_{m_{sujo}}$  é a temperatura do módulo sujo,  $T_0$  e  $G_0$  são a temperatura e a irradiância solar na condição de referência. POA é a radiação solar incidente sobre o plano do módulo inclinado medido na célula de referência (Braga et al., 2020).

Em testes onde há dois módulos idênticos, em que um deles é limpo diariamente e o outro permanece sujo, a SR é a razão simples entre os dados de potência no ponto de máxima potência ou corrente de curto-circuito de cada módulo. Entretanto, a  $I_{SC}$  não é ideal para avaliar a proporção de sujidade quando a sujeira é não-uniforme, a  $P_{M\acute{A}X}$  é útil para avaliar sujidade em geral (Hickel, 2017).

No Brasil, a SR pode mudar de acordo com as regiões. Em Belo Horizonte (MG), Costa et al. (2018) mediu uma queda de 0,98 para 0,86 na proporção de sujidade durante o período seco. O valor 1 é restabelecido após precipitação de 20 mm. As perdas em seis meses podem chegar a 11% para a tecnologia de silício policristalino (p-Si) e 13% para a tecnologia de telureto de cádmio (CdTe), por conta da largura da banda *gap* das duas tecnologias (COSTA et al., 2018). A sujidade afeta mais os comprimentos de onda menores, conforme observado por Hickel (2017), em que as maiores perdas espectrais aconteceram para comprimentos de onda entre 350 nm e 650 nm.

Após um ano de operação de uma usina em Brotas de Macaúba (BA), Hickel (2017) mensurou perdas de 11,33% e 3,48% para módulo das tecnologias p-Si e CIGS (disseleneto de cobre, gálio e índio), sendo o máximo e o mínimo entre as tecnologias analisadas, respectivamente. Os módulos foram limpos e novas medições foram realizadas após mais um ano de operação, nas quais identificou-se perda mínima de 1,91% e máxima de 4,34%, referente às tecnologias de p-Si e silício amorfo (a-Si), respectivamente. Hickel (2017) dedica uma seção de seu trabalho para as análises de incerteza das medições. Em Buritis (RO), a granulometria da poeira varia até 125  $\mu\text{m}$  e as perdas em dois anos de operação atingiram 11,32% para a tecnologia p-Si, porém, as maiores perdas foram 16,69% e aconteceram para a tecnologia de a-Si sem moldura.

Em Belo Horizonte (MG), Braga et al. (2020) avalia a influência de variáveis meteorológicas sobre a proporção de sujidade. Identificou-se possíveis correlações entre a SR e a concentração de material particulado, assim como a extensão dos períodos secos, embora não haja correlação entre esses dois parâmetros, isto é, um período seco prolongado não implica em maior concentração de material particulado. A intensidade de ventos e a umidade relativa possuem baixa correlação com a proporção de sujidade, contudo, a precipitação tem relação evidente com a sua melhora. As perdas identificadas variam de 5% a 20%.

Lemos (2016) avalia o impacto do acúmulo de sujeira na geração de energia e caracteriza sua composição química, biológica e mineralógica em Belo Horizonte (MG). Identificou-se grande quantidade de matéria orgânica formando biofilme que não se desprende do módulo após precipitação, indicando dificuldade para a limpeza desse tipo de material. As perdas atingiram 11,7% para uma irradiância de 1000  $\text{W}/\text{m}^2$  e aumentou para 19,1% quando a irradiância diminuiu para 100  $\text{W}/\text{m}^2$ , ou seja, o efeito da sujidade é amplificado em condições de baixa irradiância.

Em laboratório, Lemos (2016) mediu o efeito da sujidade causada pelo talco (composto por magnésio e sílica) e pelo pó de carvão vegetal (composto por carbono) conforme a irradiância variava, ambos na concentração de 0,0076  $\text{cm}^3/\text{cm}^2$ . No primeiro caso, a perda foi de 17,9% para irradiância de 800  $\text{W}/\text{m}^2$  e aumentou para 47,7% para irradiância de 300  $\text{W}/\text{m}^2$ . No caso do carvão vegetal, a perda aumentou de 71,7% para 97,6% para irradiâncias de 800  $\text{W}/\text{m}^2$  e 300  $\text{W}/\text{m}^2$ , respectivamente. Esses resultados evidenciam o impacto da composição da sujeira, em especial a presença de carbono, para amplificação dos efeitos negativos da sujidade.

Um resultado concordante foi encontrado por Varga e Wiesner (2021) ao investigar as interações entre a superfície do módulo e sujeiras diversas: pólen de alfafa, pólen de gramínea, borossilicato, gesso, cinza, grafite, sílica e microesferas cerâmicas. Em distâncias curtas, a força de *Van der Waals* é predominante, porém, as forças capilares tendem a ser representativas de acordo com a umidade relativa e a hidrofobicidade. Notou-se também que o vento remove com eficácia partículas maiores que 50  $\mu\text{m}$ .

A força de adesão teórica (considerando apenas a força de *Van der Waals*) não reflete os resultados experimentais, a margem de erro pode chegar a 100% em algumas amostras, de forma que não representa tão bem o fenômeno e a estimativa é pouco confiável. As amostras baseadas em carbono apresentam maior força de adesão e são mais difíceis de prever (VARGA e WIESNER, 2021).

A finalidade desta revisão da literatura técnica e científica é identificar os modelos propostos para estimar o efeito da sujidade em usinas fotovoltaicas, com foco nos métodos empregados e na avaliação da influência de fatores que contribuem para o fenômeno.

## 2. METODOLOGIA

O presente estudo constitui uma revisão da literatura específica de caráter sistemático, com a finalidade de avaliar os modelos propostos para estimar o efeito da sujidade sobre os módulos fotovoltaicos. No protocolo de pesquisa definiu-se as seguintes palavras chave como critérios de inclusão: “soiling” (ou “sujidade”), “fotovoltaic” ou “solar energy” (“fotovoltaico” ou “energia solar”), “model” (ou “modelo”) e “review” (ou “revisão”). Além disso, os artigos devem tratar sobre as tecnologias de silício cristalino e/ou filmes finos e a data de publicação não deve ser anterior a 2011. A seleção dos artigos aconteceu nas bases de dados listadas na Tab. 1 de acordo com o fluxograma representado na Fig. 1.

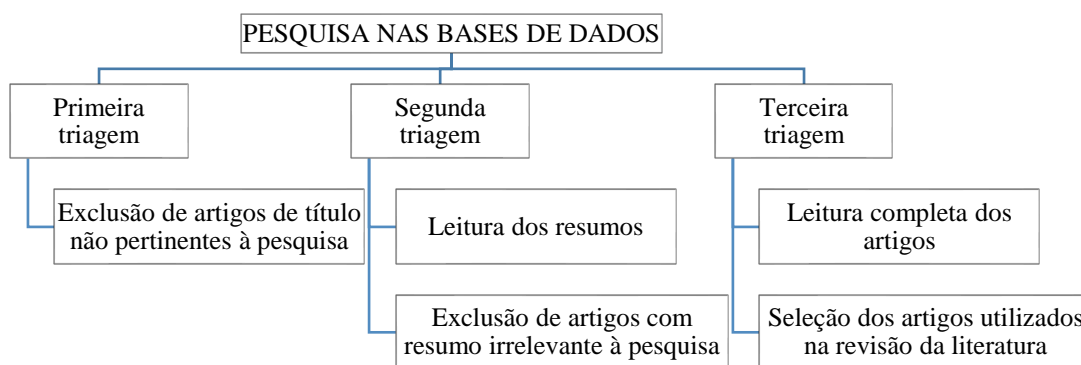


Figura 1 - Fluxograma do processo seletivo dos artigos.

A Tab. 1 apresenta o quantitativo de artigos científicos em cada etapa de triagem em cada base de dados. A pesquisa ocorreu entre os dias 13 e 30 de julho de 2021.

Tabela 1 – Bases de dados selecionadas e quantitativo de artigos selecionados em cada etapa da triagem.

BASE DE DADOS	RESULTADOS	TRIAGEM 1	TRIAGEM 2	TRIAGEM 3
IEEE	53	48	30	8
Science Direct	161	55	18	4
Scielo	0	0	0	0
CAPES	7	4	3	3
SCOPUS	117	58	32	11
CBENS	8	8	7	3
TOTAL	338	173	90	29

Dos 29 artigos selecionados para leitura integral do conteúdo, 27 (93%) foram publicados a partir de 2016, o que indica a atualidade e relevância do tema.

### 3. RESULTADOS

Os artigos foram divididos em grupos de acordo com o tipo de modelo, conforme a classificação sugerida por Younis e Alhorr (2021) em seu estudo de revisão sobre o tema: estatístico, redes neurais, exponencial, linear, fator de desgaste, simulações numéricas, ópticos e dependentes de proporção.

#### 3.1 Modelo estatístico

A Tab. 2 apresenta os artigos selecionados que elaboram modelos estatísticos, apresentando o método utilizado, o *software*, as variáveis de entrada e as perdas calculadas.

Javed et al. (2021) relaciona a densidade de poeira acumulada ( $\text{g}/\text{m}^2$ ) com perdas por sujidade e perda de transmitância a partir de dois modelos: o primeiro utiliza propriedades químico-físicas da sujeira e o segundo utiliza variáveis climáticas e a concentração de material particulado com diâmetro menor ou igual a  $10 \mu\text{m}$  (PM10). Ambos utilizam correlação linear e modelo de regressão linear múltipla. Os dados foram coletados no Catar, onde o cálcio foi o elemento mais abundante nas amostras de poeira (70%), seguido de silício (11%), ferro (5%), magnésio (4,8%), alumínio (4%) e outros componentes secundários (5,2%). O diâmetro das partículas varia majoritariamente entre  $17\text{--}23 \mu\text{m}$  e  $12\text{--}18 \mu\text{m}$ .

Javed et al. (2021) utiliza o termo “*dust potency*” (“potência de sujeira”, em tradução livre) para denominar a perda por sujidade a cada unidade de área por unidade de massa de poeira, medida em  $\text{m}^2/\text{g}$ . O primeiro modelo é uma equação linear cujo coeficiente angular é corrigido pela razão entre a potência de sujeira medida e a corrigida. A potência de sujeira é corrigida pela massa de material particulado de carbono orgânico (OC) e elementar (EC), o tamanho médio das partículas ( $\text{PS}_{\text{mean}}$ ) e conteúdo iônico (*Ions*). Essa razão tem valor médio de 0,98, mas varia entre 0,82 e 1,07. O modelo linear aumenta a correlação entre massa de poeira acumulada e perdas por sujidade de 0,78 para 0,94. Por outro lado, o modelo linear com variáveis ambientais (PM10, velocidade do vento e umidade relativa) apresentou  $R^2 = 0,57$ , mas a precipitação e a direção do vento não foram incluídas na equação. Observou-se também que o termo PM10 não é significativo para o resultado final (Javed et al., 2021).

Pavan, Mellit e Pieri (2011) determinaram as perdas causadas pela sujidade em duas usinas de 1 MWp na Itália através de um modelo de regressão polinomial genérico utilizando a temperatura do módulo e a irradiância. O  $R^2$  é superior a 99%. A usina localizada em solo arenoso teve ganho de geração de 6,9% após limpeza com água destilada sob

pressão e escovação, enquanto a usina localizada com solo compacto e vegetado teve ganho de 1,1% após limpeza com água pressurizada.

Souza (2020) desenvolveu uma plataforma eletrônica para coleta de dados ambientais, incluindo material particulado suspenso, e utilizou-os para avaliar o impacto dessas variáveis na produção fotovoltaica a partir de um estudo estatístico. Duas amostras de solo foram coletadas no entorno da usina, nas quais a composição predominante foi de  $Al_2O_3$ ,  $SiO_2$  e  $Fe_2O_3$ . O modelo de Coello e Boyle (2019) foi aplicado para estimar a deposição da massa sobre os módulos e os modelos logístico e de Gompertz foram comparados para estimativa de potência gerada pelo módulo (SOUZA, 2020). O modelo logístico é o que melhor explica os dados observados. O preditor estatístico de energia gerada apresentou um alto coeficiente de correlação (0,9778) e um erro quadrático médio muito pequeno (0,0067). A diferença entre o dado predito e o teórico é -1,4% a +0,7% durante o período dos experimentos. Observou-se uma relação entre períodos de chuva com a redução na concentração dos particulados atmosféricos.

Skomedal e Deceglie (2020) propuseram um algoritmo que decompõe iterativamente uma série temporal de índice de desempenho de um sistema, com sujidade não-linear ao longo do tempo. O algoritmo possui quatro etapas: detecção de eventos de limpeza; filtro de Kalman para estimativa de proporção de sujidade; estimar a incerteza com *bootstrapping*; e geração de dados sintéticos. O modelo estimou o índice de performance com  $R^2 = 0,71$  e a taxa de degradação foi determinada em -0,5%/ano. A proporção de sujidade, estimada pelo filtro de Kalman, é difícil de ser estimada em períodos com eventos de limpeza rápida e sucessiva, uma vez que o sinal de sujeira permanece menor que o ruído nesses períodos, levando a taxas de sujeira subestimadas. Esse é um problema geral para todos os modelos que tentam estimar as taxas de sujeira com base em uma taxa de performance diária.

Tabela 2 – Metodologia utilizada para desenvolvimento dos modelos estatísticos, com ênfase no *software*, variáveis de entrada e as perdas encontradas.

Artigo	País	Métodos	Software	Variáveis de entrada	Perdas
Javed et al. (2021)	Catar	Correlação linear, Modelo de Regressão Múltipla	-	PM10, irradiância, temperatura do módulo e do ambiente, velocidade do vento e direção, umidade relativa (UR)	7%-22%
Pavan, Mellit, De Pieri (2011)	Itália	Modelo de regressão polinomial ( <i>SANDIA array performance model</i> )	-	Corrente, tensão e temperatura do módulo, irradiância	6,9% (solo arenoso) e 1,1% (solo vegetado)
Souza (2020)	Brasil	Modelos Log-Logístico e Log-Gompertz	RStudio	Temperatura, velocidade do vento, tamanho das partículas e quantidade, inclinação dos módulos, distância do solo, viscosidade cinemática do ar e coeficiente de arrasto da superfície	-
Skomedal e Deceglie (2020)	EUA	<i>Bootstrap</i>	Pacote de análise PV para Python, RdTools	Índice de Performance (saída de energia medida do sistema dividida pela energia esperada)	Média: 2,2% [1,5%; 3,2%]. Diário: -0,1%/dia.
Micheli et al. (2021)	Espanha	Regressão por partes e algoritmos de detecção de ponto de mudança	Python, MATLAB	Taxa de sujidade diária e precipitação (medidas no local)	4%
Jamil et al. (2020)	Malásia	Regressão polinomial	Excel, IBM SPSS	Área, temperatura e fator de envelhecimento do módulo, horas de sol, irradiância, fator de <i>mismatch</i> , perdas nos cabos, eficiência do inversor, energia produzida	26,22% [4,86%, 58,67%]

Micheli et al. (2021) apresentam um modelo de regressão por partes com algoritmo de detecção de ponto de mudança para melhorar estimativa do perfil de sujidade de uma usina de 1 MW. Os perfis de sujeira medidos por nove estações de sujeira instaladas nos EUA foram usados. A sujidade é quantificada pela proporção de sujidade supondo uma taxa de acúmulo de sujidade constante na maioria das análises.

Micheli et al. (2021) consideraram o ponto de mudança contínua como um período prolongado de chuva seguido por um período de seca. Quatro abordagens diferentes foram aplicadas para detectá-los: segmentação (ou regressão por partes), algoritmo de tempo linear exato podado (PELT), algoritmo profeta *Facebook* (FBP - *facebook prophet algorithm*) e estimativa bayesiana de mudança abrupta, sazonalidade e tendência (BEAST). Dos métodos investigados, o método de segmentação e o FBP mostraram as maiores melhorias de modelagem para os locais considerados, sendo a segmentação o único método que não precisa de nenhum ajuste. A proporção média de sujidade não foi afetada significativamente por negligenciar os pontos de mudança, mas o algoritmo é útil para indicar as melhores datas para limpeza da usina. Visualmente, o dia de limpeza mais conveniente seria uma data do período de sujeira limitada, cerca de um mês anterior ao evento de vento carregado de areia, portanto o efeito dessa limpeza seria limitado ou nulo.

Jamil et al. (2020) apresentou um novo modelo de regressão para correlacionar o fator de redução de sujeira (*fdirt*) e a área do módulo fotovoltaico. Os dados foram coletados na Malásia, onde há clima tropical úmido, pouco investigado na literatura. Após 12 meses de medição, o *fdirt* calculado por regressão tem diferença média de 5%. As perdas variam de 4,46% a 58,67%, com média de 26,22%.

### 3.2 Redes neurais

A Tab. 3 apresenta os artigos que desenvolvem redes neurais, apresentando o método utilizado, o *software*, as variáveis de entrada e as perdas calculadas.

Tabela 3 – Metodologia utilizada para desenvolvimento das redes neurais, com ênfase no *software*, variáveis de entrada e as perdas encontradas.

Artigo	País	Método	Software	Variáveis	Perdas
Pavan et al. (2013)	Itália	Rede Neural Bayesiana (BNN)	MATLAB (Ver. 7.8, 2009)	Corrente das <i>strings</i> em paralelo, tensão do barramento CC, temperatura do módulo, irradiância	0,9% e 5,4%
Zhang et al. (2021)	China e Cingapura	SolarQRNN ( <i>quantile regression neural network</i> ), ImpactNet-8, ImageNet-99, Minimalistic + QRNN, ImpacNet + bootstrap, Minimalistic + bootstrap		Imagem de módulos fotovoltaicos	-
Pulipaka e Kumar (2016)	Índia	NNR (rede neural aleatória) com divisão de dados aleatórios, NNF (rede neural <i>fuzzy</i> ) com agrupamento de meios C difusos antes do treinamento, NNK (rede neural <i>k-means</i> ) com agrupamento de dados <i>k-means</i> e NNH (rede neural híbrida) com agrupamento de dados híbrido e técnicas de divisão	MATLAB	Propriedades de transmitância do solo, irradiância, ângulo de inclinação, corrente e tensão dos módulos	-
Pulipaka, Mani e Kumar (2016)	Índia	Redes neurais (algoritmo de Levenberg–Marquardt) e regressão linear	MATLAB, ANOVA	Corrente de curto-circuito, tensão de circuito aberto, irradiância, ângulo de inclinação	-
Laarabi et al. (2017, a)	Marrocos	Redes neurais (algoritmo de Levenberg–Marquardt, função de Tansig e Purline)	MATLAB, SAFE 1.1	Irradiância, velocidade do vento, direção do vento temperatura ambiente, umidade relativa e precipitação	[1.65%, 19.84%]
Laarabi et al. (2017, b)	Marrocos	Redes neurais (algoritmo de Levenberg–Marquardt, função de Tansig e Purline), algoritmo Garson (sensibilidade)		Irradiância, velocidade do vento, direção do vento, temperatura ambiente, umidade relativa e precipitação	[1.65%, 19.84%]
Chiteka, Arora e Sridhara (2020)	Zimbábue	Rede neural artificial (Algoritmo de treinamento de Levenberg–Marquardt) e regressão linear múltipla (Algoritmo de Boruta)	Python, MATLAB R2018a, Minitab 16 e ANOVA	Precipitação, temperatura máxima e mínima, umidade relativa, pressão superficial, faixa de temperatura, temperatura média, velocidade, direção, faixa de velocidade, velocidade máxima e mínima do vento, índice de clareza e PM10	-
Shapsough, Dhauadi e Zualkernan (2019)	Emirados Árabes Unidos	Regressão linear, regressão linear múltipla e rede neural simples de retropropagação	Biblioteca <i>neuralnet</i> em R	Irradiação, temperatura ambiente, corrente de curto-circuito, tensão de circuito aberto, ponto de potência máxima e registro de data/hora	-

Pavan et al. (2013) utiliza uma rede neural bayesiana (BNN) para calcular a potência produzida em condições de teste padrão (25 °C e 1000 W/m<sup>2</sup>) pelo sistema em estudo antes e depois da limpeza de seus módulos fotovoltaicos. Para a primeira planta, construída em local arenoso, as perdas foram de 5,4%, enquanto para a segunda planta, em terreno vegetado, foram de 0,9%. O R<sup>2</sup> foi superior a 0,989, apresentando um resultado levemente melhor que o modelo de regressão polinomial. As amostras foram coletadas a cada 15 minutos entre 21 de junho e 30 de agosto de 2010 e entre 02 de setembro e 24 de outubro de 2010.

Zhang et al. (2021) propõe um método de quantificação probabilística baseado em uma rede neural convolucional a partir de imagens capturadas por câmeras de vigilância para estimar a perda de potência do módulo fotovoltaico. Dentre os métodos estudados, o SolarQRNN tem o menor erro.

Pulipaka e Kumar (2016) fizeram um experimento de sujidade artificial com diferentes tipos de solo utilizando quatro algoritmos de redes neurais, que foram treinados com esses dados e aplicados para amostras desconhecidas. As amostras foram coletadas durante uma semana. A rede neural randômica (NNR) precisa de muito tempo (65 épocas) para atingir um desempenho eficiente e requer a maioria dos dados (75%) para treinamento. Cerca de 29% das amostras possuem erro desprezível e o modelo resulta em alta margem de erro (20-56%) para uma amostra de solo desconhecida. A rede neural *fuzzy* (NNF) apresenta melhoria em comparação com a NNR em termos de capacidade de previsão de dados de teste (45% das amostras com erro desprezível) e menos com épocas (10). No entanto, para uma amostra de solo desconhecida, este modelo superestima a produção de energia em todos os níveis de irradiância. A rede neural *k-means* (NNK) tem 39 épocas e cerca de 32% da precisão dos dados de teste, é melhor do que a NNR, mas não é tão eficiente quanto o NNF. No caso de amostra de solo desconhecida, a NNK superestima ou subestima a produção de energia em vários níveis de irradiância, tornando este modelo menos confiável. A rede neural híbrida (NNH) tem 15 épocas e 50% de precisão dos dados de teste e tem vantagem sobre os outros modelos no caso de previsão de potência do painel sujo. A margem de erro em qualquer nível de irradiância é sempre menor que 10% para o modelo NNH, tornando-o o melhor entre as redes neurais estudadas.

Pulipaka, Mani e Kumar (2016) utiliza uma rede neural bayesiana (BNN) para estimar a potência de saída do módulo fotovoltaico para diferentes composições granulométricas do solo acumulado em um módulo fotovoltaico. O modelo de regressão prevê a perda de potência em vários níveis de irradiância. A amostra 1 de solo tem a maior composição (83,8%) de tamanho de partícula de 150 µm, a amostra 2 tem composição igual de 150 µm (32%) e 75 µm (35%), as amostras 3 e 4 têm partículas de 300 µm em abundância (58% e 47%, respectivamente), enquanto a amostra 5 tem predominância de partículas de 150 µm (65,2%). A equação de regressão múltipla é independente das variáveis, demonstrando que o tamanho das partículas não influencia a potência de saída dos módulos. A equação de regressão falha em estimar a potência de saída de solos com composição granulométrica inferior a 75 µm e superior 150 µm, por isso, presume-se que a influência de partículas menores que 75 µm é predominante na saída de energia em níveis de irradiância mais baixos, enquanto é o tamanho de partícula superior a 150 µm que pode impactar a saída de energia em níveis mais altos níveis de irradiância. Os modelos baseados em regressão são úteis para determinar a relação entre as composições granulométricas, irradiância e potência, com R<sup>2</sup> = 97,85%, mas as redes neurais são eficientes na previsão de potência dada a composição granulométrica.

Laarabi et al. (2017, a) modela através de uma rede neural artificial (ANN) o efeito de sujeira em vidro solar fotovoltaico e faz uma análise de sensibilidade para determinar o efeito dos parâmetros de entrada na saída do modelo. O modelo representa satisfatoriamente o fenômeno real, o R<sup>2</sup> = 0,928. A análise de sensibilidade com índice PAWN indica que todos os parâmetros contribuem para o modelo, sendo os mais influentes a umidade relativa do ar (21,22%) seguida pela direção do vento (21,03%), velocidade do vento (17,78%), irradiância solar (17,33%), temperatura ambiente (16,89%) e precipitação (14,58%). As medições aconteceram entre 20 de abril e 31 de dezembro de 2016.

Laarabi et al. (2017, b) modelam o efeito de sujeira em vidro solar fotovoltaico e fazem análise de sensibilidade para determinar o efeito dos parâmetros de entrada na saída do modelo. Com base no Algoritmo de Garson, a análise de sensibilidade mostrou que os principais parâmetros meteorológicos são a precipitação (22,58%), a direção do vento (17,66%), irradiância (15,27%), velocidade do vento (14,84%), temperatura ambiente (15,47%) e umidade relativa (13,17%). As medições aconteceram entre 20 de abril e 31 de dezembro de 2016.

Chiteka, Arora e Sridhara (2020) comparam o resultado de uma ANN e de um modelo de regressão linear múltipla, além de apresentar uma análise de sensibilidade para 14 variáveis. Os dados médios diários foram coletados por um ano inteiro, de 01 de novembro de 2017 a 31 de outubro de 2018 em local com clima de savana tropical, onde os parâmetros mais relevantes são PM10, umidade relativa, velocidade do vento, precipitação e direção do vento, respectivamente. A precipitação não aparece como parâmetro relevante, já que ela é baixa. A rede neural apresentou R<sup>2</sup> = 0,9817, enquanto o modelo de regressão linear tem R<sup>2</sup> = 0,8092.

Shapsough, Dhaouadi e Zualkernan (2019) estimam a potência de saída de sistemas fotovoltaicos em condições de sujidade com uma rede neural simples de retropropagação e com regressão linear. Ambos os modelos foram treinados com dados coletados entre 1º de julho de 2018 e 16 de setembro de 2018. Usando a regressão linear, é possível prever a saída do painel limpo com um alto grau de precisão (R<sup>2</sup> = 0,981), porém, no caso do módulo sujo, o modelo linear perde precisão (R<sup>2</sup> = 0,883). A temperatura ambiente apresentou pouca relevância para os resultados da ANN, cujo menor R<sup>2</sup> foi 0,949 para o mês de setembro.

### 3.3 Simulação numérica

A Tab. 4 apresenta os artigos que utilizam simulações numéricas, apresentando o método utilizado, o *software* e as variáveis de entrada.

Chiteka, Arora e Sridhara (2021) implementaram um modelo numérico de dinâmica de fluidos computacional (CFD) para determinar a sujeira acumulada a partir da equação de *Navier-Stokes* com média de Reynolds (RANS). A margem de erro foi inferior a 4%.

Coello e Boyle (2019) elaboraram um algoritmo para prever perdas por sujeira em arranjos fotovoltaicos, no qual em cada iteração a massa total de particulados acumulada é usada para estimar a perda por sujeira. A validação foi feita em sete locais do Arizona e da Califórnia, nos EUA. A comparação entre a velocidade de deposição variável, a velocidade de deposição estática e a velocidade de sedimentação estática para os sete locais mostra que a velocidade de estabilização estática (*static settling velocity*) resultou nas saídas mais precisas. O modelo é dependente da frequência e intensidade da precipitação e do PM10.

Tabela 4 – Metodologia utilizada para desenvolvimento de simulações numéricas, com ênfase no *software* e nas variáveis de entrada.

Artigo	País	Método	Software	Variáveis
Chiteka, Arora e Sridhara (2021)	Zimbábue	CFD	ANSYS FLUENT v17.2	Densidade do fluido, variável de fluxo, termo da fonte, coeficiente de difusão efetivo, inclinação e azimute do módulo, velocidade do vento, irradiância, temperatura
Coello e Boyle (2019)	EUA	Múltiplas iterações/Modelo simples de velocidade de deposição estática		PM10, PM2.5, inclinação dos módulos, precipitação

### 3.4 Linear

Em geral, os modelos lineares são simples, práticos e razoavelmente precisos, mas não é possível generalizar para outras regiões geográficas pela dependência das características climáticas locais (YOUNIS e ALHARR, 2021). Esse tipo de modelo tem como premissa que a sujeira aumenta linearmente até que a precipitação seja suficiente ou até que os arranjos fotovoltaicos sejam limpos, o que não foi observado por Duarte et al. (2020).

Pelland et al. (2018) aplicaram o modelo de Boyle, que estima a média de sujeira a longo prazo a partir da concentração de material particulado em 20 locais no hemisfério norte, comparando os resultados com o modelo *GISS Model E2*. Os dados utilizados para alimentar os modelos foram obtidos a partir de satélites, especificamente a concentração de massa de superfície de poeira (DUSMASS) do conjunto de dados de reanálise MERRA-2 e a concentração de material particulado (PM10) previstos do Centro Europeu de Previsões de Tempo Médio do *Copernicus Atmosphere Monitoring Service* (ECMWF-CAMS).

Pelland et al. (2018) concluem que todos os modelos predizem corretamente maior nível de sujeira no Oriente Médio e parecem capturar grandes variações de sujeira em grandes áreas geográficas. A precisão é baixa quando a sujeira é da ordem de 5% e para variações em pequenas escalas espaciais, devido ao caráter local da sujeira. As resoluções espaciais dos modelos testados são de dezenas a centenas de quilômetros. Mesmo assim, os erros médios de polarização são de 1% ou menos, os desvios padrão dos erros variam de 2,3% a 5,4%. Entre os modelos individuais, o modelo ECMWF-CAMS de baixa resolução parece ter o melhor desempenho, tendo baixo viés (0,3%), menor desvio padrão (2,3%) e maior coeficiente de correlação (0,90).

### 3.5 Outros modelos

Younis e Alhorr (2021) discutem outros tipos de modelo em sua revisão, como o modelo exponencial, modelo de fator de desgaste, modelo óptico e modelo dependente de proporção.

Os modelos ópticos utilizam indicadores de degradação da performance a partir da mudança do ângulo de incidência de luz e das características espectrais. Esse modelo é apropriado para modelar a física da acumulação de poeira e a física óptica associada, porém, os resultados são totalmente dependentes das características locais (YOUNIS e ALHARR, 2021).

Os modelos dependentes de proporção relacionam um indicador, como o índice de limpeza, à razão entre um parâmetro de performance de duas células, uma suja e outra limpa. Esse tipo de modelo apresenta resultados diretos, são flexíveis e dependem da disponibilidade de dados no local (YOUNIS e ALHARR, 2021).

Os modelos exponenciais relacionam de forma simples as perdas causadas por sujeira com diferentes fatores de desempenho, mas os resultados podem ser pouco precisos e são muito dependentes de condições locais (YOUNIS e ALHARR, 2021).

Os modelos com fator de desgaste utilizam um fator de redução como indicador para as perdas de energia. Essa abordagem é relativamente simples, mas a robustez da previsão do modelo está sujeita ao método de análise matemática selecionado e os resultados são restritos à região de estudo (YOUNIS e ALHARR, 2021).

Yang, Ji e Guo (2018) apresentaram um método para o processamento de imagens preto e branco a fim de detectar a sujidade em módulos fotovoltaicos. O padrão preto e branco personalizado com vários níveis de carga de poeira é capturado por fotografia de luz visível obtidas de uma *Nikon D40* em várias velocidades do obturador, abertura e condições de foco. O método de análise de imagem extrai regiões em preto e branco da foto, com base no qual uma métrica chamada razão preto/branco (BWR) é calculada. Verificou-se que o foco é um fator importante de distorção do resultado, mas o problema pode ser resolvido usando um tamanho de *kernel* morfológico maior. A abertura afeta pouco o resultado, enquanto a exposição curta ressalta o preto da imagem e a exposição longa satura o sensor de brilho da câmera. Além disso, o pixel do arquivo *.jpeg* deve ser corrigido pelo fator gama para o arquivo *BEF* para obtenção do valor real de brilho.

Duarte et al. (2020) utilizam a Eq. (3) para determinar a sujidade com base na densidade gravimétrica ( $\text{g/m}^2$ ), em que a sujeira era coletada e pesada a cada 7 dias.

$$SR(\%) = 100\% - 34,37 \operatorname{erf}(0,17\omega^{0,8473}) \quad (3)$$

Os resultados obtidos com os dados empíricos são muito próximos dos dados estimados a partir de estações de monitoramento. Em 75 dias, as perdas chegaram a 14% em Belo Horizonte (MG) e o acúmulo de sujeira foi de  $2,5744 \text{ g/m}^2$ , o instrumento utilizado foi uma balança de precisão Shimadzu, modelo AUY220. A deposição não seguiu um padrão linear como proposto pelos modelos lineares.

Micheli, Deceglie e Muller (2019) desenvolveram um mapa de sujidade para os EUA a partir de dados de estações de sujidade coletados entre 2013 e 2016. Nesse estudo, diversos métodos de interpolação foram avaliados: Vizinheiro Mais Próximo (NN), Média Espacial (SA), Ponderação de Distância Inversa (ID), Ponderação da Distância Quadrada Inversa (ID2) e Estimativa de Distância Declusterizada (DDE). Apenas os dados coletados nas horas centrais do dia, com irradiância superior a  $500 \text{ W/m}^2$  e corrente até 80% do esperado foram considerados. Verificou-se que os estados que experimentam os mais longos períodos de seca são os mais afetados pelas perdas por sujidade, com os locais ao sul da Califórnia apresentando as perdas máximas. Os melhores resultados foram obtidos para locais dentro de 50 km dos locais investigados, o  $R^2$  aumenta de 42% para 63%. Existe correlação entre os dados interpolados e medidos, com  $R^2$  atingindo valores superiores a 70% para uma interpolação espacial de amostragem aleatória.

Cheema, Shaaban e Ismail (2021) propõem um novo modelo para geração de energia fotovoltaica a partir de modelagem estocástica, com o modelo de cadeia de *Markov*, que incorpora sazonalidades, inclusive da taxa de acúmulo de sujeira e da limpeza. Esse tipo de modelo pode ser usado para identificar o investimento ideal e estratégia de limpeza. A potência de saída estimada para o módulo condiz com os valores reais, no entanto, a média da poeira acumulada varia até 10% entre as estações do ano.

Deceglie, Micheli e Muller (2018) apresentam o método de taxa estocástica e recuperação (SRR) que detecta automaticamente os intervalos de sujeira em um conjunto de dados e gera estocasticamente uma amostra de perfis de sujeira possíveis com base nas características observadas de cada intervalo. O algoritmo é composto por quatro etapas: detectar automaticamente eventos de limpeza, dividindo o conjunto de dados em intervalos de sujeira; estimar a inclinação de cada intervalo e a magnitude da limpeza entre os intervalos; gerar estocasticamente perfis de sujeira para todo o conjunto de dados; e calcular sujidade para cada perfil gerado aleatoriamente, assim como a mediana e o intervalo de confiança. O método SRR leva em consideração diferentes taxas de sujeira que podem mudar com o tempo ou sazonalmente, ele também detecta eventos de limpeza com um limite determinado automaticamente com base no ruído no conjunto de dados.

Tabela 5 – Metodologia utilizada para desenvolvimento dos modelos estocásticos, com ênfase nas variáveis de entrada e as perdas encontradas.

Artigo	País	Método	Variáveis	Perdas
Cheema, Shaaban e Ismail (2021)	Diversos	Modelo de cadeia de Markov	Temperatura ambiente, irradiância, acúmulo e taxa de acúmulo de poeira, frequência de limpeza desejada	
Deceglie, Micheli e Muller (2018)	EUA	Método de taxa estocástica e recuperação (SRR)	Irradiação, corrente de curto-circuito	6,50%

#### 4. CONCLUSÃO

Este trabalho apresentou uma revisão da literatura técnica e científica, na qual a maioria dos estudos se basearam em dados experimentais para derivar seus modelos, o que contribui para verificar sua validade, mas os resultados são restritos ao local e não podem ser generalizados. Esse tipo de restrição é recorrente entre os modelos apresentados.

Em relação aos parâmetros de entrada, observou-se que as características físicas da poeira podem descrever melhor a proporção de sujidade do que parâmetros ambientais, no entanto, dentre as características ambientais, a precipitação e o vento são mais representativos. Os modelos divergem em relação ao tamanho de partícula predominante para o efeito da sujidade, podendo ser desprezível em alguns casos.



A coleta de dados pode acontecer localmente ou a partir de dados de satélite, como concentração de material particulado e precipitação, em locais onde esse tipo de coleta não é possível.

Vargas e Wiesner (2021) investigaram a força de adesão das partículas sobre a superfície do módulo fotovoltaico, de modo que as partículas baseadas em carbono (como pólen) são mais aderentes. Esse resultado é sustentado por Lemos (2016), que identificou a presença de biofilme sobre os módulos em seu estudo. Contudo, no geral os resultados de Vargas e Wiesner (2021) foram pouco satisfatórios por conta da alta margem de erro entre os valores teóricos e os valores experimentais.

Dentre os modelos analisados, verificou-se que na maior parte dos casos as redes neurais têm bom desempenho, mas precisam de muitos dados de entrada e são específicos para um local. Os modelos de regressão linear e similares explicam fenômenos localmente e são mais simples para implementação.

A utilização de imagens para detecção de sujidade pode simplificar a estimativa de sujidade em sistemas existentes, mas a técnica ainda precisa ser desenvolvida e validada.

Verificou-se a viabilidade de elaborar um mapa de sujidade para grandes áreas através da interpolação de dados de estações respeitando-se um raio de 50 km. Isso também é possível a partir de dados de satélite combinados com um modelo linear ou similar.

De forma geral, os resultados apontam a ausência de estudos sobre sujidade em regiões de clima tropical úmido. Os dados de Hickel (2017) coletados em Buritis/RO e de Jamil et al. (2020) sugerem que as perdas podem superar 10%, mas seria importante acompanhar esse parâmetro no decorrer do tempo, o que não foi possível no caso de Hickel (2017), embora o estudo tenha apontado que as tecnologias que utilizam menores comprimentos de onda (ex: TeCd) são mais afetadas pela sujidade e que as perdas por sujidade são amplificadas quando há baixa irradiância.

Os estudos apresentados são heterogêneos entre si, o que é natural devido à complexidade do fenômeno analisado e permite o desenvolvimento de abordagens diversas, mas dificulta a comparação entre elas e a criação de uma metodologia padronizada para as análises.

### **Agradecimentos**

Agradecimento à Universidade Federal de Santa Catarina pelo apoio no desenvolvimento da pesquisa. Agradecimento ao orientador Giuliano Rampinelli Arns pela disponibilidade e dedicação em transmitir os conhecimentos.

### **REFERÊNCIAS**

- Braga, D. S., Costa, S. C. S., Diniz, A. S. A. C., Camatta, V., Kazmerski, L. L., 2020. Estudo da Relação Entre Parâmetros Ambientais e Taxa de Sujidade em Módulos Fotovoltaicos, VIII CBENS – VIII Congresso Brasileiro de Energia Solar, Fortaleza.
- Cheema, A., Shaaban, M. F., Ismail, M. H., 2021. A Novel Stochastic Dynamic Modeling For Photovoltaic Systems Considering Dust And Cleaning, Applied Energy, vol. 300.
- Chiteka, K., Arora, R., Sridhara, S. N., 2020, A Method To Predict Solar Photovoltaic Soiling Using Artificial Neural Networks And Multiple Linear Regression Models, Energy Systems, vol. 11, pp. 981-1002.
- Chiteka, K., Arora, R., Sridhara, S. N., Enweremadu, C. C., 2021, Influence Of Irradiance Incidence Angle And Installation Configuration On The Deposition Of Dust And Dust-Shading Of A Photovoltaic Array. Energy Systems, vol. 216.
- Coello, M., Boyle, L., 2019, Simple Model For Predicting Time Series Soiling Of Photovoltaic Panels. IEEE Journal Of Photovoltaics, vol. 9, n. 5, pp. 1382-1387.
- Costa, S. C. S., Diniz, A. S. A. C., Santana, V. A. C., Muller, M., Micheli, L. Kazmerski, L. L., 2018. Avaliação da Sujidade em Módulos Fotovoltaicos em Minas Gerais, Brasil, VII CBENS - VII Congresso Brasileiro de Energia Solar, Gramado.
- Deceglie, M. G., Micheli, L., Muller, M., 2018, Quantifying Soiling Loss Directly From PV Yield, IEEE Journal Of Photovoltaics, vol. 8, n. 2, pp. 547-551.
- Duarte, T. P., Costa, S. C. S., Diniz, A. S. A. C., Kazmerski, L. L., 2020, Estimativa da Taxa de Sujidade em Módulos Fotovoltaicos Utilizando Dados de Densidade Gravimétrica, VIII CBENS – VIII Congresso Brasileiro de Energia Solar, Fortaleza.
- Hickel, B. M., 2017, O Impacto no Desempenho de Sistemas Fotovoltaicos Causado Pelo Acúmulo de Sujeira Sobre os Módulos FV – Metodologia e Avaliação Através de Curvas IxV em Campo, Dissertação, PPGEC, UFSC, Florianópolis.
- Ilse, K. K., Figgis, B. W., Naumann, V., Hagendorf, C., Bagdahn, J., 2018, Fundamentals Of Soiling Processes On Photovoltaic Modules, Renewable and Sustainable Energy Reviews, vol. 98, pp. 239-254.
- Jamil, W. J., Rahman, H. A., Shaari, S., Desa, M. K. M., 2020, Modeling Of Soiling Derating Factor In Determining Photovoltaic Outputs, IEEE Journal Of Photovoltaics, vol. 10, n. 5, pp. 1417-1423.
- Javed, W., Guo, B., Figgis, B., Aissa, B., 2021, Dust Potency In The Context Of Solar Photovoltaic (Pv) Soiling Loss, Solar Energy, vol. 2020, pp. 1040-1052.
- Laarabi, B., Tzuc, O. M., Dahlioui, D., Bassam, A., Flota-Bañuelos, M., Barhdadi, A., 2017, a, Artificial Neural Network Modeling And Sensitivity Analysis For Soiling Effects On Photovoltaic Panels In Morocco, Superlattices and Microstructures, pp. 1-12.

- Laarabi, B., Tzuc, O. M., Dahlioui, D., Bassam, A., Flota-Bañuelos, M., Daoudi, F., Safsafi, F., Barhdadi, A., 2017, b, New Correlation Of Pv Modules Soiling And Outdoor Conditions Using Artificial Neural Networks, 5th IRSEC - 5th International Renewable and Sustainable Energy Conference.
- Lemos, L. O., 2016, Estudo Do Efeito Do Acúmulo De Sujidade Na Eficiência De Módulos Fotovoltaicos, Dissertação, Programa de Pós-Graduação em Engenharia de Materiais, CEFET/MG, Belo Horizonte.
- Micheli, L., Deceglie, M. G., Muller, M., 2019, Mapping Photovoltaic Soiling Using Spatial Interpolation Techniques, IEEE Journal Of Photovoltaics, vol. 9, n. 1, pp. 272-277.
- Micheli, L., Theristis, M., Livera, A., Stein, J. S., Georghiou, G. E., Muller, M., Almonacid, F., Fernández, E. F., 2021, Improved PV Soiling Extraction Through The Detection Of Cleanings And Change Points. IEEE Journal Of Photovoltaics, vol. 11, n. 2, pp. 519-526.
- Pavan, A. M., Mellit, A. Pieri, D. D., 2011. The Effect Of Soiling On Energy Production For Large-Scale Photovoltaic Plants, Solar Energy, vol. 85, pp. 1128-1136.
- Pavan, A. M., Mellit, A. Pieri, D. D., Kalogirou, S. A., 2013, A Comparison Between BNN And Regression Polynomial Methods For The Evaluation Of The Effect Of Soiling In Large Scale Photovoltaic Plants, Applied Energy, vol. 108, pp. 392-401.
- Pelland, S., Pawar, P., Veeramani, A., Gustafson, W., Leahy, L., Etringer, A., 2018, Testing Global Models Of Photovoltaic Soiling Ratios Against Field Test Data Worldwide, 7th WCPEC - IEEE 7th World Conference on Photovoltaic Energy Conversion, pp. 3442-3446.
- Pulipaka, S., Mani, F., Kumar, R., 2016, Modeling Of Soiled PV Module With Neural Networks And Regression Using Particle Size Composition, Solar Energy, vol. 123, pp. 116-126.
- Pulipaka, S., Kumar, R., 2016, Power Prediction Of Soiled PV Module With Neural Networks Using Hybrid Data Clustering And Division Techniques, Solar Energy, vol. 133, pp. 485-500.
- Shapsough, S., Dhauadi, R., Zualkernan, I., 2019, Using Linear Regression And Back Propagation Neural Networks To Predict Performance Of Soiled PV Modules, Procedia Computer Science, vol. 155, pp. 463-470.
- Skomedal, A., Deceglie, M. G., 2020, Combined Estimation Of Degradation And Soiling Losses In Photovoltaic Systems, IEEE Journal Of Photovoltaics, vol. 10, n. 6, pp. 1788-1796.
- Souza, G. G., 2020, Infraestrutura Computacional Para Detecção e Análise de Particulados em Plantas Solares Fotovoltaicas, Dissertação, Mestrado Acadêmico em Ciência da Computação, UFMS, Campo Grande.
- Varga, H. F., Wiesner, M. R., 2021, Effect Of Dust Composition On The Reversibility Of Photovoltaic Panel Soiling, Environ. Sci. Technol, vol. 55, pp. 1984-1991.
- Yang, M., Ji, J., Guo, B., 2020, An Image-Based Method For Soiling Quantification, ICIoT - IEEE International Conference on Informatics, IoT, and Enabling Technologies, pp. 89-94.
- Younis, A., Alhorr, Y., 2021, Modeling Of Dust Soiling Effects On Solar Photovoltaic Performance: A Review, Solar Energy, vol. 2020, pp. 1074-1088.
- Zhang, W., Liu, S., Gandhi, O., Rodríguez-Gallegos, C. D., Quan, H., Srinivasan, D., 2021, Deep-Learning-Based Probabilistic Estimation Of Solar Pv Soiling Loss, IEEE Transactions On Sustainable Energy, vol. 12, n. 4, pp. 2346-2444.

## REVIEW STUDY ON THE TECHNIQUES APPLIED IN THE MODELING OF SOILING ON PHOTOVOLTAIC MODULES

**Abstract.** *Soiling on photovoltaic modules is a relevant cause for losses in energy generation, in Belo Horizonte/MG it is estimated a reduction of around 11% in six months of measurement. This article presents a review of the models used in the literature to estimate the losses caused by dirt deposited on the surface of the modules. The research protocol defined the keywords to search for articles published from 2011 onwards in six databases, whose results went through three stages of selection: exclusion of articles with titles not relevant to the research, exclusion of abstract articles not relevant to the research, full reading of the articles and selection of the most relevant to the research. The studies developed were grouped according to the type of model. Statistical models use linear regression and similar methods, are practical and simple. Models based on neural networks can return very accurate results (above 90%), but they are complex and need a lot of data to train them. There are also models based on linear, exponential, derating factor, numerical simulation, optical and ratio-dependent equations, which were less explored by the articles. In general, the models use empirical data to obtain the results, which restricts them to the researched location and prevents their generalization to other regions. Sensitivity analyses indicate that physical characteristics of the dirt (composition, size and others) might be more relevant than the environmental parameters, while among these variables precipitation and wind are the most significant parameters. This shows how challenging it is to develop a mathematical model that includes all impact variables. There is a wide variety of studies and approaches, while comparing them without a standardized methodology for the analyses.*

**Key words:** *Solar Energy, Photovoltaic Module, Soiling.*