

INSTITUTO FEDERAL DE SANTA CATARINA

LEONARDO LUDVIG SILVA

**Análise de degradação de módulos fotovoltaicos
utilizando combinação de técnicas de
Inteligência Artificial**

São José - SC

março/2025

ANÁLISE DE DEGRADAÇÃO DE MÓDULOS FOTOVOLTAICOS UTILIZANDO COMBINAÇÃO DE TÉCNICAS DE INTELIGÊNCIA ARTIFICIAL

Projeto de Trabalho de conclusão de curso
apresentado à Coordenadoria do Curso de
Engenharia de Telecomunicações do campus
São José do Instituto Federal de Santa Cata-
rina

Orientador: Prof. Ramon Mayor Martins,
Dr.

São José - SC

março/2025

Leonardo Ludvig Silva

**ANÁLISE DE DEGRADAÇÃO DE MÓDULOS FOTOVOLTAICOS
UTILIZANDO COMBINAÇÃO DE TÉCNICAS DE INTELIGÊNCIA
ARTIFICIAL**

Projeto de Trabalho de conclusão de curso apresentado à Coordenadoria do Curso de Engenharia de Telecomunicações do campus São José do Instituto Federal de Santa Catarina

São José, 12 de março de 2026.

Prof. Ramon Mayor Martins, Dr.
Instituto Federal de Santa Catarina

Professor Diego da Silva de Medeiros, Dr.
Instituto Federal de Santa Catarina

Professora Evanaska Maria Barbosa Nogueira, Dra.
Instituto Federal de Santa Catarina

*A nossa maior glória não reside no fato de nunca cairmos, mas sim em levantarmo-nos
sempre depois de cada queda.*

Oliver Goldsmith

RESUMO

O trabalho investiga a degradação de módulos fotovoltaicos por meio de técnicas de Inteligência Artificial, com foco na classificação do estado de funcionamento em diferentes níveis de desempenho.

A partir de parâmetros técnicos de módulos comerciais, foi construída uma base de dados sintética que contempla variáveis como irradiância, temperatura do módulo, tensão de circuito aberto, corrente de curto-circuito e eficiência ajustada, representando cenários de bom funcionamento, mau funcionamento e não funcionamento. Foram avaliados quatro algoritmos supervisionados baseados em árvores de decisão, Random Forest, XGBoost, LightGBM e CatBoost, em uma tarefa de classificação multiclasse.

Os resultados mostraram acurácia, precisão e F1-Score superiores a 0,997 para todos os modelos, com destaque para o LightGBM, que apresentou os melhores indicadores médios. A abordagem proposta demonstra potencial para automatizar o diagnóstico de módulos fotovoltaicos, permitindo identificar precocemente degradações e contribuir para a otimização da eficiência de sistemas de geração de energia solar.

Palavras-chave: Energia Solar. Degradação. Módulo fotovoltaico. Inteligência Artificial.

ABSTRACT

This work investigates the degradation of photovoltaic modules using Artificial Intelligence techniques, focusing on classifying the operating state into different performance levels.

A synthetic dataset was built from technical parameters of commercial modules, including variables such as irradiance, module temperature, open-circuit voltage, short-circuit current and adjusted efficiency, representing scenarios of good operation, poor operation and non-operation. Four supervised tree-based algorithms, Random Forest, XGBoost, LightGBM and CatBoost, were evaluated in a multiclass classification task.

The results showed accuracy, precision and F1-Score above 0.997 for all models, with LightGBM achieving the best average metrics. The proposed approach shows potential to automate the diagnosis of photovoltaic modules, enabling early detection of degradation and contributing to the optimization of the efficiency of solar energy generation systems.

Keywords: Solar energy. Degradation. Photovoltaic Module. Artificial Intelligence.

LISTA DE ILUSTRAÇÕES

Figura 1 – Células Mono e Policristalinas	14
Figura 2 – Efeito voltaico	15
Figura 3 – Equipamento de análise PV-Check	16
Figura 4 – Comparação das métricas de acurácia, precisão e F1-Score entre os modelos avaliados	26
Figura 5 – Comparação completa do desempenho dos modelos	26
Figura 6 – Matrizes de confusão dos modelos Random Forest, XGBoost, LightGBM e CatBoost	27

LISTA DE TABELAS

Tabela 1 – Parâmetros coletados	23
Tabela 2 – Distribuição das classes na base de dados	25
Tabela 3 – Desempenho individual dos modelos avaliados	25

LISTA DE ABREVIATURAS E SIGLAS

IA Inteligência Artificial.

M-Si Silício Monocristalino.

P-Si Silício Policristalino.

Si Silício.

STC *Standard Test Conditions*.

SUMÁRIO

1	INTRODUÇÃO	10
1.1	Objetivo geral	11
1.2	Objetivos específicos	11
1.3	Justificativa	12
2	FUNDAMENTAÇÃO TEÓRICA	13
2.1	Energia solar	13
2.2	Módulos fotovoltaicos	13
2.3	Célula fotovoltaica	14
2.4	PV-Check	15
2.5	Modelos de Machine Learning Utilizados	16
2.5.1	Random Forest	16
2.5.2	XGBoost	17
2.5.3	LightGBM	17
2.5.4	CatBoost	18
3	METODOLOGIA	19
3.1	Estudo sobre módulos fotovoltaicos e IAs	19
3.2	Tipo e abordagem da pesquisa	19
3.3	Coleta e Geração de Dados	19
3.3.1	Geração da base de dados sintética	20
3.3.2	Preparação dos dados	20
3.4	Comparação entre os Dados e Ensaios Laboratoriais	21
3.5	Cálculo da Eficiência Real	21
3.6	Ferramentas e Tecnologias	21
3.6.1	Modelagem e algoritmos utilizados	21
3.6.2	Avaliação e comparação dos modelos	22
4	PROPOSTA	23
4.1	Coleta e Processamento de Dados	23
4.2	Implementação da Inteligência Artificial	23
4.2.1	Classificação do Desempenho dos Módulos Fotovoltaicos	23
4.2.2	Comparação e Avaliação dos Modelos	24
5	RESULTADOS E DISCUSSÃO	25
5.1	Parâmetros e Caracterização da Base de Dados	25

5.2	Resultados	25
5.3	Discussão	26
6	CONCLUSÕES	29
	REFERÊNCIAS	30
	ANEXOS	32
	ANEXO A – DATASHEET EMSZ 380M DG	33
	ANEXO B – DATASHEET EMSZ 430M HC	38
	ANEXO C – DATASHEET EMSB 455 HC	43
	ANEXO D – DATASHEET EMSB 535M HC	48
	ANEXO E – DATASHEET EMSH 550 HC	53
	ANEXO F – DATASHEET EMSC 555 HC	59

1 INTRODUÇÃO

A energia elétrica gerada por meio de usinas fotovoltaicas, também conhecida como energia solar, representa uma alternativa de geração limpa que tem se consolidado no setor energético. De acordo com a Associação Brasileira de Energia Solar Fotovoltaica ([ABSOLAR, 2024](#)), em 2023, a fonte solar representou 36 GW de geração de energia, cerca de 16% da matriz elétrica do país. Em 2024, a energia solar respondeu por mais da metade da expansão da matriz elétrica brasileira ([Portal Solar, 2024](#)). O aumento da popularidade dessa tecnologia é impulsionado pela queda nos custos de produção, tornando-a acessível a diferentes segmentos socioeconômicos. Atualmente, essa fonte é empregada tanto em pequenos sistemas residenciais para consumo próprio quanto em grandes usinas destinadas à comercialização no mercado livre de energia ([ABSOLAR, 2024](#)). Embora apresentem diferenças significativas na infraestrutura, como a potência dos inversores, capacidade dos dispositivos de proteção e a dimensão dos condutores, ambos os modelos de geração dependem dos módulos fotovoltaicos, componentes fundamentais na conversão da luz solar em energia elétrica.

Com o desenvolvimento tecnológico, surgiram duas principais variantes de células fotovoltaicas feitas de Silício (Si): as policristalinas (P-Si) e as monocristalinas (M-Si). As células policristalinas são produzidas com silício de diferentes graus de pureza, resultando em formações cristalinas irregulares, o que implica menor eficiência e maior sensibilidade a variações de temperatura. Em contrapartida, as células monocristalinas são fabricadas com silício de alta pureza, apresentando uma estrutura mais uniforme e maior eficiência energética. Entretanto, essa última tecnologia possui custo mais elevado ([CARVALHO; MESQUITA; ROCIO, 2014](#)).

O funcionamento dos módulos fotovoltaicos baseia-se na excitação de suas células de silício pela radiação solar. O silício, sendo um semicondutor, é combinado com elementos como boro e fósforo para criar camadas com polaridades opostas – positiva e negativa. Quando os fótons da luz solar atingem essas camadas, provocam o deslocamento de elétrons, gerando uma corrente elétrica contínua entre as camadas. Esse processo se mantém constante, com os fótons preenchendo as lacunas deixadas pelos elétrons, permitindo a geração ininterrupta de energia ([CARVALHO; MESQUITA; ROCIO, 2014](#)).

Em termos de desempenho, os fabricantes projetam que, após 25 anos de operação, os módulos fotovoltaicos manterão cerca de 80% de sua capacidade nominal ([SOLAR, 2025b](#)). No entanto, verificou-se que sistemas instalados há aproximadamente cinco anos já apresentam uma degradação superior à prevista ([JORDAN; KURTZ, 2013](#)). A alta temperatura de operação é uma das principais causas dessa queda de desempenho, impac-

tando especialmente os módulos policristalinos, cuja estrutura menos uniforme os torna mais vulneráveis ao superaquecimento (HUDIŞTEANU et al., 2024). Embora outros fatores, como erros de instalação e dimensionamento inadequado, possam contribuir para a degradação dos módulos, este trabalho se concentrará primariamente nos efeitos das condições climáticas.

Estudos recentes mostram que, mesmo em condições consideradas adequadas, alguns módulos já apresentam sinais visíveis de degradação, como manchas cinzentas nas células, causadas pela infiltração de umidade sob exposição à radiação ultravioleta (??). Além disso, algumas degradações não perceptíveis a olho nu são causadas por altas temperaturas e exposição prolongada ao clima. Essas falhas são mais comuns nos módulos policristalinos, que podem ter sua eficiência reduzida para 70% da capacidade nominal em apenas cinco anos, um resultado 10% abaixo da projeção de 80% estipulada para 25 anos (JORDAN; KURTZ, 2013). Dessa forma, dada a complexidade e o custo elevado das análises de desempenho desses sistemas, o presente estudo propõe o desenvolvimento de modelos de uma *Inteligência Artificial (IA)* para identificar se os módulos estão operando abaixo da eficiência esperada. A *IA* será alimentada com dados obtidos em laboratório, em condições ideais de fabricação, e comparará esses resultados com o desempenho real dos módulos em campo. Serão consideradas variáveis como tensão e corrente máxima de operação, irradiação solar, temperatura ambiente e a curva característica I-V do módulo. Com essa solução, pretende-se fornecer uma ferramenta eficiente para o monitoramento em tempo real dos sistemas fotovoltaicos, assegurando que eles mantenham a performance prometida e funcionem dentro dos parâmetros previstos.

1.1 Objetivo geral

Como objetivo geral, procura-se desenvolver um modelo de *IA* para avaliar o desempenho de módulos fotovoltaicos e identificar se estão operando abaixo da eficiência esperada, considerando as condições climáticas e comparando dados de laboratório, de modo a identificar um modelo de machine learning eficiente e confiável para a análise dos parâmetros dos módulos fotovoltaicos e a verificação de seu desempenho atual.

1.2 Objetivos específicos

- Coletar dados de desempenho de módulos fotovoltaicos em condições de laboratório, incluindo tensão, corrente, irradiação solar e temperatura ambiente;
- Coletar dados de desempenho de módulos fotovoltaicos em campo, sob diferentes condições climáticas;

- Desenvolver um modelo de IA capaz de analisar os dados coletados em laboratório e em campo;
- Avaliar a influência da temperatura, umidade entre outros fatores do ambiente no desempenho dos módulos fotovoltaicos.
- Identificar os módulos fotovoltaicos que apresentam desempenho abaixo do esperado e as possíveis causas, considerando as condições climáticas.

1.3 Justificativa

No cenário atual da energia solar, observa-se uma crescente migração para os módulos monocristalinos, embora ainda não haja certeza absoluta sobre sua superioridade em relação aos policristalinos. Este estudo visa identificar padrões de degradação em módulos fotovoltaicos, avaliar o desempenho e ser capaz de discernir qual dos dois tipos de módulos apresenta maior durabilidade e mantém a eficiência esperada ao longo do tempo.

Para possibilitar a detecção de padrões de degradação, e viabilizar a análise e comparação do desempenho desses módulos, o estudo propõe o desenvolvimento de modelos de IA. Atualmente, mesmo com equipamentos de medição como o PV-Check, a verificação e comparação dos dados com os ensaios de laboratório são realizadas manualmente, demandando tempo e esforço consideráveis.

As *Inteligência Artificiais (IAs)* a serem desenvolvidas neste trabalho auxiliarão na automatização da análise das degradações que possam causar anomalias e permitirão, posteriormente, uma avaliação mais rápida e eficiente dos módulos fotovoltaicos.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Energia solar

A energia solar é uma fonte de energia renovável e limpa que utiliza a luz do sol para gerar eletricidade. Um sistema de geração de energia solar, também conhecido como sistema fotovoltaico, é composto por dois elementos principais, os módulos fotovoltaicos e o inversor (PINHO; GALDINO, 2014). Estes sistemas fotovoltaicos podem ser classificados em dois tipos principais, os conectados à rede elétrica (*on-grid*), que permitem o consumo da energia solar e da rede, e os isolados (*off-grid*), ideais para locais remotos, onde a energia é armazenada em baterias (SOLAR, 2025b). Além dos painéis e do inversor, um sistema fotovoltaico pode incluir outros componentes, como controladores de carga, baterias, estruturas de fixação e fiação. Porém, o que há em comum entre estes tipos de sistemas são os módulos fotovoltaicos, sendo considerados a parte vital de toda a operação.

2.2 Módulos fotovoltaicos

Os módulos fotovoltaicos, foco deste estudo, são fabricados de diversas formas, porém a tecnologia dominante no mercado atual são as células de Silício cristalino. Esses módulos possuem cerca de 20% de eficiência e garantia de manter até 90% da capacidade em 10 anos de uso e até 80% da capacidade nominal em 25 anos (NASCIMENTO; RÜTHER, 2014).

A potência nominal de um módulo geralmente corresponde à sua capacidade máxima de geração de energia em condições laboratoriais padronizadas, conhecidas como *Standard Test Conditions* (STC) (PINHO; GALDINO, 2014). Essas condições, porém, não refletem os cenários reais de aplicação. Por esse motivo, ao analisar a eficiência de um módulo, não basta verificar apenas a potência atual gerada, mas sim calcular a fração da irradiação solar que está sendo efetivamente convertida em energia elétrica, levando em consideração fatores ambientais como temperatura de operação, irradiação e angulação.

Esse cálculo é realizado a partir da relação entre a potência de entrada e a potência de saída do módulo fotovoltaico, expressa pelas equações (SIKIRU et al., 2022):

$$\eta = \frac{P_{\text{out}}}{P_{\text{in}}} \times 100 \quad (2.1)$$

$$P_{\text{in}} = G \times A \quad (2.2)$$

Onde:

- η representa a eficiência do módulo (%);
- P_{out} é a potência de saída do módulo (W);
- P_{in} é a potência de entrada (W), o produto obtido da irradiação solar incidente (G , em W/m^2) e da área do módulo (A , em m^2).


2.3 Célula fotovoltaica

A célula fotovoltaica é a unidade básica de um módulo fotovoltaico e é responsável por converter a luz solar em eletricidade. Quando os fótons (partículas de luz solar) colidem com os átomos do material do painel solar, provocando assim o deslocamento dos elétrons, esse fluxo de elétrons gera uma corrente elétrica contínua. Esse fenômeno tem o nome de “efeito fotovoltaico” (Portal Solar, 2025). Existem dois tipos principais de células fotovoltaicas, classificadas de acordo com o processo de fabricação do silício (BuHLER; SANTOS; GABE, 2018):

Silício Monocristalino (M-Si): As células monocristalinas são fabricadas a partir de um único cristal de silício de alta pureza. Esse processo resulta em células com estrutura uniforme e maior eficiência energética, porém, seus custos de produção são mais elevados.

Silício Policristalino (P-Si): As células policristalinas são fabricadas a partir de vários cristais de silício de diferentes graus de pureza. Esse processo resulta em células com estrutura menos uniforme e menor eficiência energética em comparação com as monocristalinas, porém com custo de produção mais baixo.

Figura 1 – Células Mono e Policristalinas

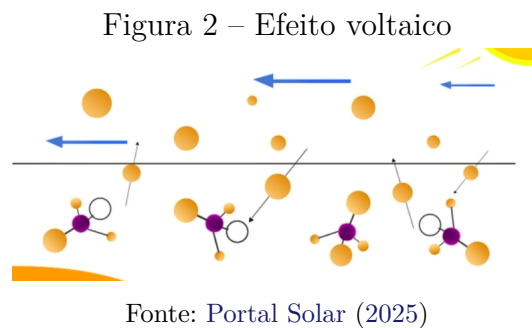


Fonte: Solar (2025a)

Para que ocorra o efeito fotovoltaico, é necessário haver uma diferença de potencial nas células, ou seja, elas devem conter uma carga negativa e uma carga positiva. No

silício, isso é obtido ao combiná-lo com boro, um elemento que possui menos elétrons que o silício. Essa combinação faz com que o silício fique com falta de elétrons, gerando uma carga positiva. Já para criar uma carga negativa, o silício é combinado com fósforo, um elemento que possui mais elétrons que ele. Essa combinação faz com que o silício fique com excesso de elétrons, criando uma carga negativa (UFC, 2025).

As células fotovoltaicas são construídas sobrepondo camadas de silício carregado positivamente e silício carregado negativamente. A junção desses dois tipos de silício forma uma barreira de potencial, uma região onde os elétrons não podem fluir livremente. Quando a luz solar incide sobre a célula, os fótons fornecem energia suficiente para que os elétrons "saltem" essa barreira de potencial (PINHO; GALDINO, 2014).



2.4 PV-Check

Para realizar a medição dos dados dos módulos e coletar os parâmetros de desempenho, como a curva característica I-V, será utilizado o equipamento PV-Check Figura 3. Essa ferramenta é específica para uso em módulos fotovoltaicos e é conectada diretamente ao módulo. Utilizando um sensor auxiliar de angulação e outro sensor de irradiação, o PV-Check realiza um ensaio de desempenho do módulo, fornecendo dados precisos sobre sua eficiência e saúde (AMPERI, 2025).

Os parâmetros medidos e coletados pelo PV-Check são:

- Potência máxima de operação P_{max}
- Tensão de circuito aberto V_{oc}
- Tensão de máxima potencia V_{mpp}
- Corrente de curto-circuito I_{sc}
- Corrente de máxima potencia I_{mpp}
- Irradiação incidente na superfície do módulo

Figura 3 – Equipamento de análise PV-Check



(a) Medição dos módulos usando PV-Check



(b) PV-Check

- Temperatura de operação do módulo
- Fator de Preenchimento FF
- Coeficiente de temperatura de tensão α
- Coeficiente de temperatura de corrente β

2.5 Modelos de Machine Learning Utilizados

Os modelos de aprendizado de máquina baseados em árvores têm sido amplamente empregados em tarefas de classificação e regressão devido à sua robustez, capacidade de lidar com relações não lineares e facilidade de interpretação. Neste estudo, quatro técnicas da literatura serão utilizadas para analisar o desempenho dos módulos fotovoltaicos: Random Forest, XGBoost, LightGBM e CatBoost. Todas elas pertencem à família dos modelos supervisionados e se destacam pela eficiência na análise de dados tabulares, sendo adequadas para o tipo de informação gerada na avaliação de módulos em condições reais ou simuladas.

2.5.1 Random Forest

O Random Forest é um método de ensemble amplamente utilizado por combinar diversas árvores de decisão independentes em um único modelo preditivo (BREIMAN, 2001). Cada árvore é treinada a partir de subconjuntos aleatórios dos dados e de atributos selecionados de forma aleatória a cada divisão, o que reduz a correlação entre as árvores individuais. Esse processo resulta em um classificador mais estável, pois os er-

ros cometidos por árvores isoladas tendem a ser compensados pela votação coletiva do conjunto, melhorando a capacidade de generalização do modelo.

Essa técnica possui duas propriedades que explicam seu bom desempenho: a força individual das árvores (capacidade preditiva de cada uma) e a baixa correlação entre elas. Quanto maior a diversidade entre as árvores e maior sua capacidade de aprendizado, melhor o desempenho geral do modelo. Além disso, o Random Forest apresenta resistência ao overfitting e lida bem com dados de alta dimensionalidade, sendo uma escolha adequada para a análise dos parâmetros elétricos dos módulos fotovoltaicos.

2.5.2 XGBoost

O XGBoost (eXtreme Gradient Boosting) é uma implementação otimizada do algoritmo Gradient Boosting, sendo amplamente reconhecido por sua eficiência e desempenho superior em tarefas de classificação e regressão (FRIEDMAN, 2001). Diferentemente do Random Forest, em que as árvores são treinadas de forma independente, o XGBoost constrói suas árvores de maneira sequencial. Cada nova árvore é ajustada para corrigir os erros cometidos pelas árvores anteriores, aproximando o gradiente negativo da função de perda.

O XGBoost incorpora técnicas importantes de regularização (L1 e L2), que reduzem a complexidade das árvores e evitam o sobreajuste, além de mecanismos internos de paralelização, manejo eficiente de valores ausentes e estratégias otimizadas de busca por divisões. Essas características tornam o algoritmo altamente escalável e adequado para aplicações que exigem grande volume de dados ou processamento intensivo.

2.5.3 LightGBM

O LightGBM é um algoritmo baseado em Gradient Boosting projetado para oferecer maior velocidade de treinamento e menor consumo de memória em comparação com outras implementações tradicionais, como o próprio XGBoost (KE et al., 2017). Para isso, utiliza três técnicas principais: divisão baseada em histogramas, Gradient-based One-Side Sampling (GOSS) e Exclusive Feature Bundling (EFB).

Na divisão baseada em histogramas, os valores contínuos são agrupados em intervalos (bins), reduzindo o número de comparações necessárias para encontrar os melhores pontos de divisão. O LightGBM também constrói as árvores no modo leaf-wise, selecionando sempre a folha que proporciona maior redução de perda, o que geralmente resulta em modelos mais precisos. Entretanto, essa abordagem exige controle de profundidade para evitar sobreajuste.

O algoritmo ainda acelera o treinamento por meio do GOSS, que seleciona todas as instâncias com grandes gradientes (mais influentes no cálculo da perda) e amostra uma

fração das instâncias com gradientes pequenos. Já o EFB reduz a dimensionalidade combinando atributos mutuamente exclusivos em um único recurso, sem perda de informação relevante. Essas técnicas tornam o LightGBM particularmente eficiente e adequado a cenários com conjuntos extensos de dados.

2.5.4 CatBoost

O CatBoost é uma implementação de Gradient Boosting desenvolvida especificamente para lidar com variáveis categóricas e reduzir problemas de overfitting decorrentes de codificações inadequadas (DOROGUSH et al., 2017). Diferentemente de outras abordagens, o CatBoost utiliza duas técnicas centrais: Ordered Target Statistics e Ordered Boosting.

Nas Ordered Target Statistics, os valores categóricos são convertidos em estatísticas calculadas somente a partir de exemplos anteriores em uma permutação aleatória dos dados. Essa abordagem evita o vazamento de informação durante o treinamento, um problema comum em técnicas tradicionais de target encoding. Já o Ordered Boosting garante que as previsões utilizadas na construção dos resíduos não incorporem informações do próprio exemplo, produzindo um treinamento mais robusto e imparcial.

Com essas estratégias, o CatBoost apresenta excelente desempenho em bases que misturam atributos numéricos e categóricos, além de exigir menor pré-processamento dos dados. Isso o torna um modelo adequado para aplicações diversas.

3 METODOLOGIA

Neste capítulo, é apresentada a metodologia a ser utilizada no desenvolvimento do trabalho, descrevendo as etapas do processo e as ferramentas que serão empregadas na pesquisa.

3.1 Estudo sobre módulos fotovoltaicos e IAs

A etapa inicial da metodologia consiste em uma revisão bibliográfica abrangente sobre módulos fotovoltaicos, explorando os diferentes tipos de células, seus princípios de funcionamento, características de desempenho, fatores de degradação e vida útil. Além disso, serão abordadas as fundamentações de [Inteligência Artificial](#), investigando os conceitos básicos, os tipos de técnicas de aprendizado de máquina, as estratégias de treinamento e validação, as métricas de avaliação e as aplicações de IA em sistemas fotovoltaicos. Por fim, será estudada a curva característica I-V, incluindo seus fundamentos, importância, parâmetros extraíveis e os efeitos de diferentes condições sobre seu comportamento.

3.2 Tipo e abordagem da pesquisa

Este estudo caracteriza-se como uma pesquisa aplicada, com abordagem quantitativa, uma vez que busca desenvolver e avaliar modelos computacionais capazes de classificar o estado de funcionamento de módulos fotovoltaicos a partir de variáveis numéricas simuladas. O delineamento adotado é experimental/computacional, pois os dados são gerados artificialmente sob condições controladas e utilizados para comparar o desempenho de diferentes técnicas de aprendizado de máquina.

3.3 Coleta e Geração de Dados

A coleta de dados será realizada utilizando uma base de dados sintética a partir dos datasheets de painéis solares reais que podem ser mensurados via equipamento PV-Check, que permite obter as seguintes variáveis:

- Tensão e corrente de operação
- Azimute e elevação do módulo
- Irradiação solar incidente
- Temperatura de operação do módulo

- Curva característica I-V de cada módulo

A base de dados sintética, simula módulos em bom funcionamento, em mau funcionamento e nenhum funcionamento. Essa base de dados sintética é criada utilizando modelos matemáticos e/ou simulações computacionais que representem o comportamento de módulos fotovoltaicos em diferentes condições de operação e com diferentes níveis de degradação.

3.3.1 Geração da base de dados sintética

A base de dados utilizada na análise será construída de forma sintética a partir de parâmetros técnicos presentes nos *datasheets* de módulos fotovoltaicos da Intelbras, incluindo eficiência em STC, valores de V_{oc} , I_{sc} e coeficientes de temperatura. Esses dados serão organizados para representar diferentes modelos comerciais.

Para cada módulo, serão geradas combinações de irradiância (400, 600, 800 e 1000 W/m²) e temperatura do módulo (valores próximos a 25°C, ampliados para refletir condições reais de operação). A partir desses parâmetros, serão calculados a eficiência, a tensão e a corrente ajustadas por meio de funções que aplicam os coeficientes de temperatura e um fator proporcional à irradiância.

Com base na eficiência ajustada, os dados serão rotulados em três categorias:

- **Bom Funcionamento** (degradação $\leq 10\%$);
- **Mau Funcionamento** (10% – 30%);
- **Não Funcionando** ($> 30\%$).

Dessa forma, o problema será tratado como uma tarefa de classificação multiclasse. Ao final, todos os registros serão armazenados em arquivo CSV contendo as variáveis de entrada (modelo, irradiância, temperatura, eficiência ajustada, V_{oc} ajustado e I_{sc} ajustado) e o respectivo rótulo de desempenho.

3.3.2 Preparação dos dados

O arquivo da base sintética será carregado em Python e convertido para um *DataFrame*. As variáveis preditoras utilizadas no treinamento dos modelos serão: irradiância, temperatura do módulo, eficiência ajustada, V_{oc} ajustado e I_{sc} ajustado. O rótulo de desempenho será definido como variável alvo. O atributo “Modelo” será removido da matriz de entrada por não contribuir diretamente para a classificação.

Os rótulos (*Bom Funcionamento*, *Mau Funcionamento* e *Não Funcionando*) serão convertidos para valores numéricos utilizando o *LabelEncoder*. Em seguida, o conjunto de

dados será dividido em treino (70%) e teste (30%), aplicando estratificação para manter a proporção entre classes.

As variáveis numéricas serão padronizadas utilizando o *StandardScaler*, garantindo média zero e desvio padrão unitário, a fim de melhorar a estabilidade numérica e o desempenho dos modelos de aprendizagem de máquina.

3.4 Comparação entre os Dados e Ensaios Laboratoriais

Os valores obtidos em campo serão comparados com parâmetros de pleno funcionamento fornecidos pelos fabricantes nos respectivos *datasheets* e resultados de ensaios laboratoriais realizados em condições ideais, caso estejam disponíveis.

Essa comparação permitirá identificar possíveis desvios no desempenho dos módulos em relação aos valores esperados.

3.5 Cálculo da Eficiência Real

A eficiência real de cada módulo será calculada pela relação entre a potência de saída (obtida a partir da curva I-V) e a potência incidente (calculada com base na irradiação solar). Esse cálculo permitirá determinar a porcentagem da energia solar que é efetivamente convertida em eletricidade pelo módulo.

3.6 Ferramentas e Tecnologias

Serão utilizadas as seguintes ferramentas e tecnologias:

- Equipamento PV-Check para coleta de dados em campo.
- Ferramentas de análise de dados (e.g., Python com bibliotecas como Pandas e NumPy).
- Bibliotecas de aprendizado de máquina (e.g., Scikit-learn, TensorFlow ou PyTorch).
- Ambiente de desenvolvimento para a IA (e.g., Google Colab ou Jupyter Notebook).

3.6.1 Modelagem e algoritmos utilizados

Para a etapa de modelagem, serão avaliados quatro algoritmos supervisionados amplamente utilizados para dados tabulares: **Random Forest**, **XGBoost**, **LightGBM** e

CatBoost. A implementação será realizada em Python, utilizando as bibliotecas: Scikit-learn (RandomForestClassifier), XGBoost (XGBClassifier), LightGBM (LGBMClassifier) e CatBoost (CatBoostClassifier).

Os modelos serão configurados com hiperparâmetros de complexidade intermediária:

- **Random Forest:** 200 árvores, profundidade máxima 20;
- **XGBoost e LightGBM:** 200 estimadores, profundidade máxima 10, taxa de aprendizado 0,1 e *subsampling* de 0,8;
- **CatBoost:** 200 iterações, profundidade 10, taxa de aprendizado 0,1.

Todos os modelos serão treinados com os dados padronizados do conjunto de treino e, posteriormente, utilizados para prever o conjunto de teste.

3.6.2 Avaliação e comparação dos modelos

A avaliação dos modelos será realizada utilizando acurácia, precisão ponderada e F1-Score ponderado, métricas adequadas para tarefas de classificação multiclasse. Serão gerados relatórios de classificação contendo precisão, *recall* e F1 individual por classe, além de matrizes de confusão que permitirão visualizar os acertos e erros de cada algoritmo.

Também serão construídos gráficos comparativos das métricas para facilitar a análise global do desempenho dos modelos. Ao final, os resultados consolidados serão organizados em tabela e exportados para arquivo CSV, garantindo reprodutibilidade e transparência da análise desenvolvida.

4 PROPOSTA

Neste capítulo é descrita a proposta do projeto a ser desenvolvido, bem como suas principais etapas e funcionamento, além do cronograma planejado para o desenvolvimento do trabalho.

4.1 Coleta e Processamento de Dados

Inicialmente, os módulos fotovoltaicos serão avaliados utilizando o equipamento PV-Check, que permitirá a obtenção de dados essenciais para a análise de desempenho. Os parâmetros coletados incluirão tensão, corrente, irradiação solar, temperatura de operação, curva característica I-V e coeficientes de temperatura [Tabela 1](#).

Os módulos testados serão de diferentes tecnologias, como silício [Silício Monocristalino \(M-Si\)](#) e [Silício Policristalino \(P-Si\)](#), possibilitando a comparação de seu desempenho em diferentes condições ambientais. Os dados serão coletados em campo e super amostrados utilizando uma base sintética, simulando diferentes condições de ambiente, e comparados com valores de referência obtidos em ensaios laboratoriais.

Tabela 1 – Parâmetros coletados

Módulo	Pmax[W]	Voc[V]	Vmpp[V]	Impp[A]	Isc[A]	Irrad.[W/m ²]	Temp.[°C]	FF[%]	α [%/°C]	β [%/°C]
340W										
Medição	223,90	40,01	32,10	6,98	7,56	939	47,3	74	0,05	-0,37
STC	261,85	43,48	35,66	7,34	7,92	1000	25,0	76	0,05	-0,37
Nominal	340,00	45,78	37,37	9,10	9,47	1000	25,0	78	0,05	-0,37

Fonte: Elaborada pelo autor.

4.2 Implementação da Inteligência Artificial

Para a análise do desempenho dos módulos fotovoltaicos, serão empregadas quatro abordagens de [Inteligência Artificial \(IA\)](#) baseadas em algoritmos de aprendizado de máquina supervisionado, todas fundamentadas em modelos de ensemble baseados em árvores de decisão: Random Forest, XGBoost, LightGBM e CatBoost. Esses modelos foram selecionados devido ao bom desempenho reportado na literatura para problemas de classificação envolvendo dados tabulares e variáveis numéricas contínuas.

4.2.1 Classificação do Desempenho dos Módulos Fotovoltaicos

Os modelos de [IA](#) serão treinados com uma base de dados composta por informações provenientes de ensaios laboratoriais sob condições ideais [STC](#), medições realizadas

em campo e dados gerados sinteticamente. As variáveis de entrada incluem parâmetros elétricos e ambientais, tais como irradiância solar, temperatura de operação do módulo, eficiência ajustada, tensão de circuito aberto (V_{oc}) e corrente de curto-circuito (I_{sc}).

A partir dessas informações, os algoritmos serão responsáveis por classificar o estado de funcionamento dos módulos fotovoltaicos em três classes distintas: bom funcionamento, mau funcionamento e não funcionando. Essa classificação permitirá identificar módulos que estejam operando abaixo da eficiência esperada, considerando as condições climáticas e comparando os dados medidos com valores de referência obtidos em laboratório ou especificados pelos fabricantes.

4.2.2 Comparação e Avaliação dos Modelos

Os quatro modelos, Random Forest, XGBoost, LightGBM e CatBoost, serão avaliados de forma comparativa quanto ao seu desempenho na tarefa de classificação, utilizando métricas como acurácia, precisão e F1-Score. Essa análise permitirá identificar o modelo mais eficiente e confiável para a aplicação proposta, considerando não apenas a qualidade das predições, mas também aspectos como estabilidade e potencial de generalização.

5 RESULTADOS E DISCUSSÃO

5.1 Parâmetros e Caracterização da Base de Dados

Após a realização das simulações utilizando quatro modelos de IA, foi obtida uma base de dados sintética contendo 6000 amostras e 7 variáveis, incluindo atributos de entrada e o rótulo de desempenho do módulo fotovoltaico.

A Tabela 2 apresenta a distribuição das classes da base de dados, evidenciando um maior número de amostras classificadas como *Não Funcionando*, seguido por *Mau Funcionamento* e *Bom Funcionamento*. Essa distribuição reflete diferentes níveis de degradação simulados nos módulos fotovoltaicos.

Tabela 2 – Distribuição das classes na base de dados

Classe	Quantidade de amostras
Bom Funcionamento	852
Mau Funcionamento	1600
Não Funcionando	3548

5.2 Resultados

Os resultados obtidos foram:

Tabela 3 – Desempenho individual dos modelos avaliados

Modelo	Acurácia	Precisão	F1-Score
Random Forest	0.9983	0.9983	0.9983
XGBoost	0.9978	0.9978	0.9978
LightGBM	0.9989	0.9989	0.9989
CatBoost	0.9983	0.9983	0.9983

Observa-se que todos os modelos avaliados apresentaram desempenho elevado, com valores de acurácia superiores a 99%, evidenciando alta capacidade de classificação do estado de funcionamento dos módulos fotovoltaicos. A Figura 5 apresenta a comparação gráfica dos modelos em termos de acurácia, precisão e F1-Score, permitindo uma análise conjunta do desempenho obtido por cada algoritmo.

Complementarmente, a Figura 6 ilustra as matrizes de confusão correspondentes, nas quais é possível verificar a correta identificação das classes Bom Funcionamento, Mau Funcionamento e Não Funcionando. Os resultados indicam baixa ocorrência de erros de




Figura 4 – Comparação das métricas de acurácia, precisão e F1-Score entre os modelos avaliados

classificação, reforçando a robustez dos modelos propostos e a consistência da metodologia adotada para a avaliação do desempenho dos módulos fotovoltaicos.



Figura 5 – Comparação completa do desempenho dos modelos

5.3 Discussão

A análise comparativa evidenciou que todos os modelos de ensemble baseados em árvores (Random Forest, XGBoost, LightGBM e CatBoost) alcançaram desempenho extremamente elevado na classificação das três classes de funcionamento, com acurácia, precisão e F1-Score superiores a 0,997 no conjunto de teste. Esse resultado indica forte separabilidade entre as classes a partir das variáveis disponíveis e confirma a adequação de métodos baseados em florestas e boosting de árvores para problemas tabulares de natureza industrial.

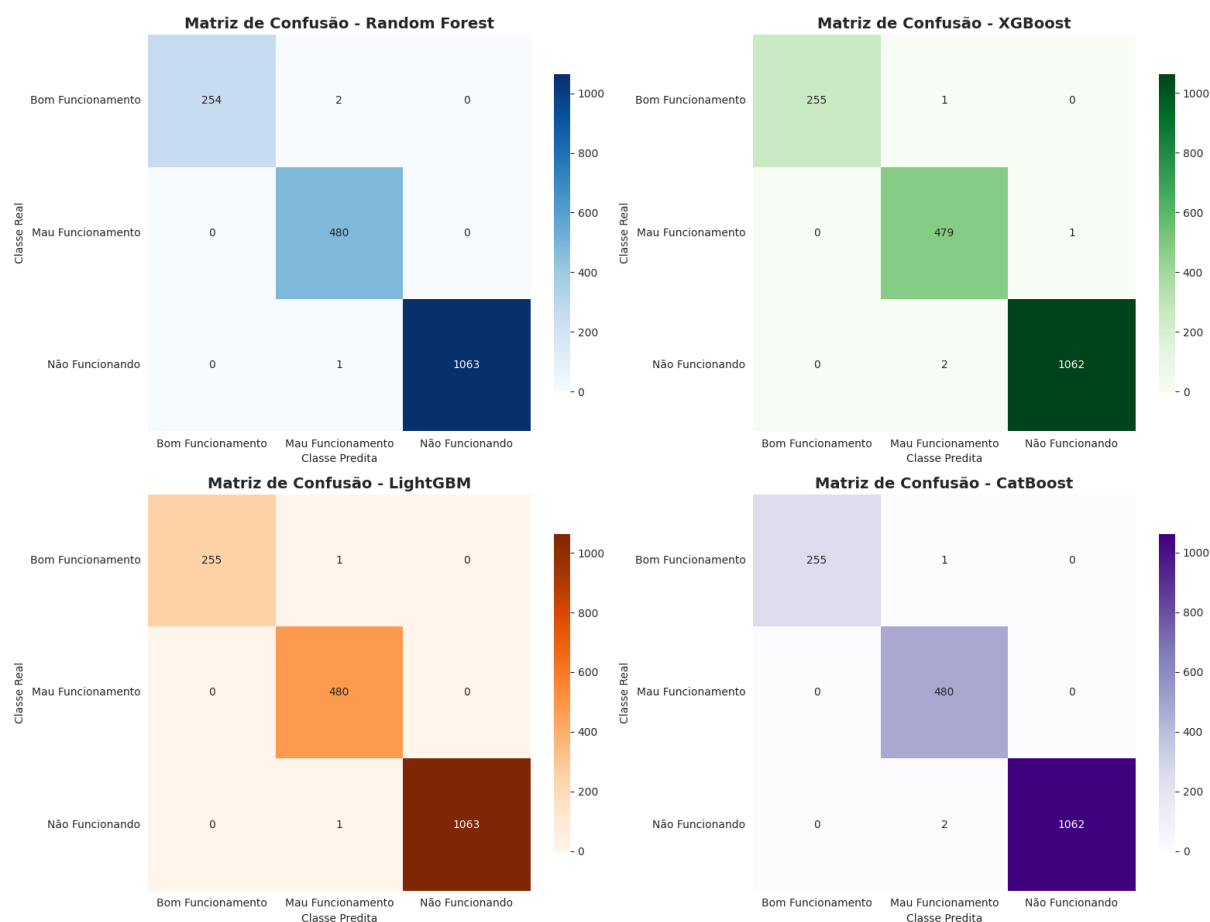


Figura 6 – Matrizes de confusão dos modelos Random Forest, XGBoost, LightGBM e CatBoost

Entre os quatro algoritmos avaliados, o LightGBM apresentou os melhores valores médios de acurácia, precisão e F1-Score, ainda que com vantagem numérica reduzida em relação aos demais. Essa superioridade é coerente com características do LightGBM, como o crescimento leaf-wise das árvores e o uso de divisão baseada em histogramas, que possibilitam explorar de forma mais eficiente interações não lineares, mantendo elevada eficiência computacional. Dessa forma, a escolha do LightGBM como modelo final justifica-se tanto pelos resultados métricos quanto pela sua escalabilidade em cenários com maior volume de dados.

Os modelos Random Forest e CatBoost apresentaram desempenhos praticamente equivalentes, sugerindo que, neste conjunto de dados específico, tanto o bagging de árvores profundas (Random Forest) quanto o boosting com tratamento mais elaborado de variáveis categóricas (CatBoost) atingem um patamar muito próximo do limite observado. O XGBoost, embora amplamente reconhecido pelo elevado desempenho em dados tabulares, apresentou resultados ligeiramente inferiores aos do LightGBM, o que pode estar associado a uma maior sensibilidade do algoritmo ao ajuste de hiperparâmetros em bases de dados de tamanho moderado.

Do ponto de vista prático, os resultados indicam que modelos baseados em árvores de decisão são altamente promissores para apoiar o diagnóstico automático do estado de funcionamento de equipamentos, contribuindo para a redução de erros de classificação tanto em condições normais quanto em situações de falha. No entanto, a proximidade das métricas em relação a 100% sugere a necessidade de cuidados adicionais, como a validação em dados provenientes de períodos distintos ou de diferentes equipamentos, a fim de assegurar que o desempenho observado reflita uma capacidade real de generalização e não possíveis vieses de amostragem ou fuga de informação durante o processo de preparação dos dados.

6 CONCLUSÕES

Esta pesquisa desenvolveu e avaliou modelos de Inteligência Artificial para classificar o estado de funcionamento de módulos fotovoltaicos, considerando variáveis elétricas e ambientais obtidas a partir de uma base sintética construída com parâmetros de módulos comerciais. Foram aplicados quatro algoritmos supervisionados baseados em árvores, a saber: Random Forest, XGBoost, LightGBM e CatBoost, à tarefa de classificação multi-classe em três categorias: bom funcionamento, mau funcionamento e não funcionando.

Os resultados evidenciaram desempenhos muito elevados para todos os modelos, com acurácia, precisão e F1-Score superiores a 0,997, demonstrando alta capacidade de distinção entre os diferentes níveis de degradação simulados. Dentre os algoritmos avaliados, o LightGBM apresentou os melhores indicadores médios, justificando sua escolha como o modelo mais adequado para aplicações práticas de monitoramento do desempenho de módulos fotovoltaicos.

Do ponto de vista prático, a abordagem proposta contribui para automatizar o diagnóstico de módulos, reduzindo a dependência de análises manuais demoradas e possibilitando a identificação precoce de falhas, o que favorece ações de manutenção e a otimização da eficiência global dos sistemas de geração fotovoltaica. Como limitações, ressalta-se o uso predominante de dados sintéticos e a necessidade de validação adicional com medições de campo em diferentes contextos e tecnologias. Como trabalhos futuros, recomenda-se ampliar a base com dados reais, incluir novas variáveis relacionadas ao histórico de operação e investigar a integração dos modelos em plataformas de monitoramento em tempo real, de modo a consolidar soluções inteligentes para o acompanhamento contínuo de sistemas fotovoltaicos.

REFERÊNCIAS

ABSOLAR. *2024: O ano da energia solar no Brasil*. 2024. Acesso em: 12 fev. 2025. Disponível em: <<https://www.absolar.org.br/noticia/https-www-modaisemfoco-com-br-noticias-2024-o-ano-da-energia-solar-no-brasil/>>. 10

AMPERI. *HT PVChecks: Ideal para fazer os testes de comissionamento de usinas fotovoltaicas*. 2025. Acesso em: 12 fev. 2025. Disponível em: <<https://amperi.com.br/canais/energia-solar/ht-pvchecks-ideal-para-fazer-os-testes-de-comissionamento-de-usinas-fotovoltaicas/>>. 15

BREIMAN, L. Random forests. *Machine Learning*, v. 45, n. 1, p. 5–32, 2001. Disponível em: <<https://www.stat.berkeley.edu/~breiman/randomforest2001.pdf>>. 16

BuHLEER, A. J.; SANTOS, F. H. dos; GABE, I. J. Uma revisão sobre as tecnologias fotovoltaicas atuais. *VII Congresso Brasileiro de Energia Solar*, 2018. Gramado, 17 a 20 de abril de 2018. 14

CARVALHO, P. S. L. d.; MESQUITA, P. P. D.; ROCIO, M. A. R. A rota metalúrgica de produção de silício grau solar: uma oportunidade para a indústria brasileira? *Metalurgia*, v. 40, p. 205–234, 2014. 10

DOROGUSH, A. V. et al. Fighting biases with dynamic boosting. *CoRR*, abs/1706.09516, 2017. Disponível em: <<http://arxiv.org/abs/1706.09516>>. 18

FRIEDMAN, J. H. Greedy function approximation: A gradient boosting machine. *The Annals of Statistics*, Institute of Mathematical Statistics, v. 29, n. 5, p. 1189 – 1232, 2001. Disponível em: <<https://doi.org/10.1214/aos/1013203451>>. 17

HUDIȘTEANU, V.-S. et al. Impact of temperature on the efficiency of monocrystalline and polycrystalline photovoltaic panels: A comprehensive experimental analysis for sustainable energy solutions. *Sustainability*, v. 16, n. 23, 2024. ISSN 2071-1050. Disponível em: <<https://www.mdpi.com/2071-1050/16/23/10566>>. 11

JORDAN, D. C.; KURTZ, S. R. Photovoltaic degradation rates—an analytical review. *Progress in Photovoltaics: Research and Applications*, v. 21, n. 1, p. 12–29, 2013. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.1002/pip.1182>>. 10, 11

KE, G. et al. Lightgbm: A highly efficient gradient boosting decision tree. In: GUYON, I. et al. (Ed.). *Advances in Neural Information Processing Systems*. Curran Associates, Inc., 2017. v. 30. Disponível em: <https://proceedings.neurips.cc/paper_files/paper/2017/file/6449f44a102fde848669bdd9eb6b76fa-Paper.pdf>. 17

NASCIMENTO, L. R. do; RÜTHER, R. A avaliação de longo prazo de um sistema fotovoltaico integrado à edificação urbana e conectado à rede elétrica pública. *Revista Brasileira de Energia Solar*, Associação Brasileira de Energia Solar (ABENS), V, n. 1, p. 73–81, 2014. 13

PINHO, J. T.; GALDINO, M. A. *Manual de Engenharia para Sistemas Fotovoltaicos*. Revisada e atualizada. Rio de Janeiro, Brasil: CEPEL – CRESESB, 2014. 13, 15

Portal Solar. *Energia solar foi a fonte que mais cresceu no Brasil em 2024*. 2024. Disponível em: <<https://www.portalsolar.com.br/noticias/operacao-e-expansao/oem/energia-solar-foi-a-fonte-que-mais-cresceu-no-brasil-em-2024>>. Acesso em: 12 fev. 2025. 10

Portal Solar. *Como funciona placa solar?* 2025. Disponível em: <<https://www.portalsolar.com.br/como-funciona-placa-solar>>. Acesso em: 12 fev. 2025. 14, 15

SIKIRU, T. D. S. et al. Recent advances and impact of phase change materials on solar energy: A comprehensive review. *The Journal of Energy Storage*, v. 53, p. 105200, 09 2022. 13

SOLAR, C. *Silício mono ou policristalino: quem vence o duelo?* 2025. Acesso em: 12 fev. 2025. Disponível em: <<https://canalsolar.com.br/silicio-mono-ou-policristalino-quem-vence-o-duelo/>>. 14

SOLAR, W. *Saiba o que é eficiência de painéis solares e veja como calculá-la*. 2025. Disponível em: <<https://www.weg.net/solar/blog/saiba-o-que-e-eficiencia-de-paineis-solares-e-veja-como-calcula-la/>>. Acesso em: 12 fev. 2025. 10, 13


UFC, P. Q. *A química por trás dos painéis solares e o funcionamento de um sistema fotovoltaico*. 2025. Acesso em: 12 fev. 2025. Disponível em: <<http://www.petquimica.ufc.br/a-quimica-por-tras-dos-paineis-solares-e-o-funcionamento-de-um-sistema-fotovoltaico/>>. 15

Anexos

ANEXO A – DATASHEET EMSZ 380M
DG

EMSZ 380M DG

Módulo Fotovoltaico Monocristalino Double Glass 72 células 380 W



Com certificação INMETRO Intelbras, o módulo fotovoltaico monocristalino *double glass* e com revestimento em grafeno oferece excelente custo-benefício na geração de energia solar, em projetos de todos os tamanhos. Mantendo o rigoroso padrão Intelbras de qualidade, todos os módulos são testados individualmente. Segurança e qualidade aliadas a 30 anos de garantia de desempenho (no mínimo 80% de seu desempenho nominal).

- » Fácil instalação
- » Excelente eficiência do módulo de até 19,37%
- » Tecnologia *double glass*
- » Revestimento em grafeno
- » Grau de proteção: IP68
- » 5BB
- » Alta eficiência e durabilidade
- » Certificação INMETRO Intelbras

Especificações técnicas

Modelo	EMSZ 380M DG
Registro INMETRO	Registro 009462/2019 (Portaria nº004/2011)
PERFORMANCE EM STC*	
Potência máxima	380 W (+3%)
Tensão máxima de operação	39,8 Vcc
Corrente máxima de operação	9,55 A
Tensão de circuito aberto	48,5 Vcc
Corrente de curto circuito	10,04 A
Eficiência do módulo	19,37%

* Sob Condições Padrão de Teste (STC): irradiância de 1000 W/m², AM de 1,5 e temperatura do módulo de 25°C.

PERFORMANCE EM NOCT*

Potência máxima	281,1 W
Tensão máxima de operação	36,8 Vcc
Corrente máxima de operação	7,63 A
Tensão de circuito aberto	44,8 Vcc
Corrente de curto circuito	8,11 A

*Sob Condições de Temperatura Nominal de Operação Da Célula (NOCT): irradiância de 800 W/m², AM de 1,5, temperatura ambiente de 20°C, vento de 1 m/s.

ESPECIFICAÇÕES MECÂNICAS

Tipo de célula	Monocristalino
Dimensões das células	156,75 * 156,75 mm
Dimensões do módulo (L x A x P)	992 x 1978 x 30 mm
Número de células	72 (6 x 12)
Peso	25,5 kg
Comprimento do cabo	900 mm
Diodos Bypass	3
Seção transversal do cabo	4 mm ²
Conector	Compatível com MC4
Grau de proteção (módulo / caixa de junção)	IP68


CONDIÇÕES DE OPERAÇÃO

Temperatura de operação	-40°C - +85°C
Carga de neve	Até 5400 Pa
Carga de vento	Até 2400 Pa
Tensão máxima do Sistema	1500 Vcc
Corrente máxima do fusível	15 A


CARACTERÍSTICAS DE TEMPERATURA

Coefficiente de temperatura máxima (Pmax)	-0,39%/K
Coefficiente de temperatura (Voc)	-0,29%/K
Coefficiente de temperatura (Isc)	+0,05%/K
Temperatura nominal da célula (NOCT)	45±2°C


CURVAS I x V




30 anos de garantia de desempenho linear



Dimensões do módulo (mm)




Fotos do produto



ANEXO B – DATASHEET EMSZ 430M
HC

EMSZ-430M HC

Módulo Fotovoltaico Monocristalino Half Cell 156 células 430 W



O módulo fotovoltaico monocristalino *half cell* e com revestimento em grafeno oferece excelente custo-benefício na geração de energia solar, em projetos de todos os tamanhos. Mantendo o rigoroso padrão Intelbras de qualidade, todos os módulos são testados individualmente. Segurança e qualidade aliadas a 25 anos de garantia de desempenho (no mínimo 84% de seu desempenho nominal).

- » Fácil instalação
- » Excelente eficiência do módulo de até 19,67%
- » PERC
- » Tecnologia half cell
- » Revestimento em grafeno
- » Grau de proteção: IP68
- » 9BB
- » Alta eficiência e durabilidade

Especificações técnicas

Modelo	EMSZ-430M HC
Registro INMETRO	005857/2020 (Portaria nº004/2011)
PERFORMANCE EM STC*	
Potência máxima	430 W (+3%)
Tensão máxima de operação	44,8 Vcc
Corrente máxima de operação	9,60 A
Tensão de circuito aberto	53,6 Vcc
Corrente de curto circuito	10,14 A
Eficiência do módulo	19,67%

* Sob Condições Padrão de Teste (STC): irradiância de 1000 W/m², AM de 1,5 e temperatura do módulo de 25°C.

PERFORMANCE EM NOCT*

Potência máxima	319,6 W
Tensão máxima de operação	41,5 Vcc
Corrente máxima de operação	7,70 A
Tensão de circuito aberto	49,9 Vcc
Corrente de curto circuito	8,19 A

* Sob Condições de Temperatura Nominal de Operação Da Célula (NOCT): irradiância de 800 W/m², AM de 1,5, temperatura ambiente de 20°C, vento de 1 m/s.

ESPECIFICAÇÕES MECÂNICAS

Tipo de célula	Monocristalino
Dimensões das células	158,75 * 79,375 mm
Dimensões do módulo (L x A x P)	1002 x 2182 x 35 mm
Número de células	156 (6 x 26)
Peso	24 kg
Comprimento do cabo	1200 mm
Diodos Bypass	3
Seção transversal do cabo	4 mm ²
Conector	Compatível com MC4
Grau de proteção (módulo / caixa de junção)	IP68

CONDIÇÕES DE OPERAÇÃO

Temperatura de operação	-40°C - +85°C
Carga de neve	Até 5400 Pa
Carga de vento	Até 2400 Pa
Tensão máxima do Sistema	1500 Vcc
Corrente máxima do fusível	20 A


CARACTERÍSTICAS DE TEMPERATURA

Coefficiente de temperatura máxima (Pmax)	-0,36 %/°C
Coefficiente de temperatura (Voc)	-0,29 %/°C
Coefficiente de temperatura (Isc)	+0,05 %/°C
Temperatura nominal da célula (NOCT)	44±2°C


EMBALAGEM

Peças por caixa	30
Peças por Container de 20' HQ	325 peças
Peças por Container de 40' HQ	700 peças


CURVAS I x V





25 anos de garantia de desempenho linear



Dimensões do módulo (mm)



Fotos do produto



ANEXO C – DATASHEET EMSB 455 HC

EMSB-455 HC

Módulo Fotovoltaico Monocristalino Monofacial Half Cell 120 células 455 W



O módulo fotovoltaico monocristalino, monofacial e *half cell* oferece excelente custo-benefício na geração de energia solar, em projetos de todos os tamanhos. Mantendo o rigoroso padrão Intelbras de qualidade, todos os módulos são testados individualmente. Segurança e qualidade aliadas a 25 anos de garantia de desempenho (no mínimo 84,8% de seu desempenho nominal).

- » Fácil instalação
- » Excelente eficiência do módulo de até 21,08%
- » Tecnologia PERC
- » Tecnologia *half cell*
- » Grau de proteção (caixa de junção): IP68
- » Alta eficiência e durabilidade

Especificações técnicas

Modelo

EMSB-455 HC

PERFORMANCE EM STC¹

Potência máxima	455 W
Tensão máxima de operação	34,82 V
Corrente máxima de operação	13,07 A
Tensão de circuito aberto	41,24 V
Corrente de curto circuito	13,95 A
Eficiência do módulo	21,08 % ²

¹ Sob Condições Padrão de Teste (STC): irradiância de 1000 W/m², AM de 1,5 e temperatura do módulo de 25°C.

² Equivalente à 210,84 Wp/m².

PERFORMANCE EM NMOT³

Potência máxima	342,0 W
Tensão máxima de operação	32,45 V
Corrente máxima de operação	10,54 A
Tensão de circuito aberto	39,20 V
Corrente de curto circuito	11,25 A

³ Sob Condições de Temperatura Nominal de Operação Do Módulo (NMOT): irradiância de 800 W/m², AM de 1,5, temperatura ambiente de 20°C, vento de 1 m/s.

ESPECIFICAÇÕES MECÂNICAS

Tipo de célula	Silício Monocristalino
Dimensões das células	182 x 91 mm
Dimensões do módulo (L x A x P)	1134 x 1903 x 30mm
Número de células	120 (2 x (6 x 10))
Peso	23,4 kg
Comprimento do cabo	1200mm
Diodos Bypass	3
Seção transversal do cabo	4 mm ²
Conector	Compatível com MC4
Grau de proteção (caixa de junção)	IP68

CONDIÇÕES DE OPERAÇÃO

Temperatura de operação	-40°C - +85°C
Carga de neve	Até 5400 Pa
Carga de vento	Até 2400 Pa
Tensão máxima do Sistema	1500 Vcc
Corrente máxima do fusível	25 A


CARACTERÍSTICAS DE TEMPERATURA

Coefficiente de temperatura máxima (Pmax)	-0,36 %/°C
Coefficiente de temperatura (Voc)	-0,29 %/°C
Coefficiente de temperatura (Isc)	+0,048 %/°C
Temperatura nominal do módulo (NMOT)	42±3°C


EMBALAGEM

Módulos por pallet	36
Módulos por Container de 40'	864 peças


Garantia de Desempenho Linear



Curvas I x V



Dimensões do Módulo (mm)



ANEXO D – DATASHEET EMSB 535M
HC

EMSB-535M HC

Módulo Fotovoltaico Monocristalino Monofacial Half Cell 144 células 535 W



O módulo fotovoltaico monocristalino, monofacial, 10BB, PERC e *half cell* oferece excelente custo-benefício na geração de energia solar, em projetos de todos os tamanhos. Mantendo o rigoroso padrão Intelbras de qualidade, todos os módulos são testados individualmente. Segurança e qualidade aliadas a 25 anos de garantia de desempenho (no mínimo 84,8% de seu desempenho nominal).

- » Fácil instalação
- » Excelente eficiência do módulo de até 20,7%
- » Tecnologia PERC e *half cell*
- » Grau de proteção (caixa de junção): IP68
- » Alta eficiência e durabilidade
- » Garantia de 12 anos de produto

Especificações técnicas

Modelo	EMSB-535M HC
Registro INMETRO	Registro 006029/2021 (Portaria n° 004/2011)

PERFORMANCE EM STC¹

Potência máxima	535 W
Tensão máxima de operação	41,45 V
Corrente máxima de operação	12,91 A
Tensão de circuito aberto	49,31 V
Corrente de curto circuito	13,79 A
Eficiência do módulo	20,7 % ²

¹ Sob Condições Padrão de Teste (STC): irradiância de 1000 W/m², AM de 1,5 e temperatura do módulo de 25°C.

² Equivalente à 207,36 Wp/m².

PERFORMANCE EM NOCT³

Potência máxima	402 W
Tensão máxima de operação	38,59 V
Corrente máxima de operação	10,41 A
Tensão de circuito aberto	46,41 V
Corrente de curto circuito	11,12 A

³ Sob Condições de Temperatura Nominal de Operação Do Módulo (NMOT): Irradiância de 800 W/m², AM de 1,5, temperatura ambiente de 20°C, vento de 1 m/s.

ESPECIFICAÇÕES MECÂNICAS

Tipo de célula	Monocristalino
Dimensões das células	182 * 91 mm
Dimensões do módulo (L x A x P)	1134 x 2279 x 35 mm
Número de células	144 (2 x (6 x 12))
Peso	28,6 kg
Comprimento do cabo	1165 mm
Diodos Bypass	3
Seção transversal do cabo	4 mm ²
Conector	Compatível com MC4
Grau de proteção (caixa de junção)	IP68

CONDIÇÕES DE OPERAÇÃO

Temperatura de operação	-40°C - +85°C
Carga de neve	Até 5400 Pa
Carga de vento	Até 2400 Pa
Tensão máxima do Sistema	1500 Vcc
Corrente máxima do fusível	25 A



CARACTERÍSTICAS DE TEMPERATURA

Coeficiente de temperatura máxima (Pmax)	-0,36 %/°C
Coeficiente de temperatura (Voc)	-0,29 %/°C
Coeficiente de temperatura (Isc)	+0,048 %/°C
Temperatura nominal do módulo (NMOT)	41±3°C


EMBALAGEM

Módulos por pallet	31
Módulos por Container de 40'	620 peças


CURVAS I x V




Dimensões do módulo (mm)



Fotos do produto



ANEXO E – DATASHEET EMSH 550 HC



EMSH-550 HC

Módulo Fotovoltaico Monocristalino Monofacial Half Cell 144 células 550 W

O módulo fotovoltaico monocristalino, monofacial e *half cell* oferece excelente custo-benefício na geração de energia solar, em projetos de todos os tamanhos. Mantendo o rigoroso padrão Intelbras de qualidade, todos os módulos são testados individualmente. Segurança e qualidade aliadas a 25 anos de garantia de desempenho (no mínimo 83,1% de seu desempenho nominal).

- » Fácil instalação
- » Excelente eficiência do módulo de até 21,30%
- » Tecnologia *half cell*
- » Grau de proteção (caixa de junção): IP68
- » Alta eficiência e durabilidade
- » Certificação INMETRO Intelbras

Especificações técnicas

Modelo EMSH-550 HC

Código para venda 4842828

Certificado INMETRO 011720/2022

PERFORMANCE EM STC¹

Potência máxima 550 W

Tensão máxima de operação 41,95 V

Corrente máxima de operação 13,12 A

Tensão de circuito aberto 49,80 V

Corrente de curto circuito 14,00 A

Eficiência do módulo 21,30 %²

¹ Sob Condições Padrão de Teste (STC): irradiância de 1000 W/m², AM de 1,5 e temperatura do módulo de 25°C.

² Equivalente à 212,9Wp/m².

PERFORMANCE EM NMOT³

Potência máxima 409 W

Tensão máxima de operação 39,76 V

Corrente máxima de operação 10,29 A

Tensão de circuito aberto 47,20 V

Corrente de curto circuito 11,30 A

³ Sob Condições de Temperatura Nominal de Operação Do Módulo (NMOT): irradiância de 800 W/m², AM de 1,5, temperatura ambiente de 20°C, vento de 1 m/s.

ESPECIFICAÇÕES MECÂNICAS

Tipo de célula	Silício Monocristalino
Dimensões das células	182 * 91 mm
Dimensões do módulo (L x A x P)	1134 x 2278 x 30mm
Número de células	144 (6 x 24)
Peso	27,0 kg
Comprimento do cabo	1200mm
Diodos Bypass	3
Seção transversal do cabo	4 mm ²
Conector	Compatível com MC4
Grau de proteção (caixa de junção)	IP68

CONDIÇÕES DE OPERAÇÃO

Temperatura de operação	-40°C - +85°C
Carga de neve	Até 5400 Pa
Carga de vento	Até 2400 Pa
Tensão máxima do Sistema	1500 Vcc
Corrente máxima do fusível	25 A

CARACTERÍSTICAS DE TEMPERATURA

Coefficiente de temperatura máxima (Pmax)	-0,33 %/°C
Coefficiente de temperatura (Voc)	-0,26 %/°C
Coefficiente de temperatura (Isc)	+0,042 %/°C
Temperatura nominal do módulo (NMOT)	41±3°C


EMBALAGEM

Módulos por pallet	36
Módulos por Container de 40' HQ	720 peças


GARANTIA

Garantia de produto	12 anos
Garantia de desempenho (mínimo de 83,1% de seu desempenho nominal)	25 anos


CURVAS I x V




Desempenho linear



Dimensões do módulo (mm)



Fotos do produto



ANEXO F – DATASHEET EMSC 555 HC



EMSC 555 HC

Módulo Fotovoltaico Monocristalino Monofacial Half Cell 144 células 555 W

O módulo fotovoltaico monocristalino, monofacial e *half cell* oferece excelente custo-benefício na geração de energia solar, em projetos de todos os tamanhos. Mantendo o rigoroso padrão Intelbras de qualidade, todos os módulos são testados individualmente. Segurança e qualidade aliadas a 25 anos de garantia de desempenho (no mínimo 84,8% de seu desempenho nominal).

- » Excelente eficiência do módulo de até 21,48%
- » Tecnologia PERC+
- » Tecnologia *half cell*
- » Grau de proteção (caixa de junção): IP68
- » Alta eficiência e durabilidade
- » Garantia de 12 anos de produto

Especificações técnicas

Modelo	EMSC 555 HC
Código para venda avulsa	4842841
Certificado INMETRO	000370/2023

PERFORMANCE EM STC¹

Potência máxima	555 W
Tensão máxima de operação	42,27 V
Corrente máxima de operação	13,13 A
Tensão de circuito aberto	50,30 V
Corrente de curto circuito	13,98 A
Eficiência do módulo	21,48 % ²

¹ Sob Condições Padrão de Teste (STC): irradiância de 1000 W/m², AM de 1,5 e temperatura do módulo de 25°C.

² Equivalente à 214,8 Wp/m².

PERFORMANCE EM NMOT³

Potência máxima	414.8 W
Tensão máxima de operação	39,39 V
Corrente máxima de operação	10,53 A

Tensão de circuito aberto	47,53 V
---------------------------	---------

Corrente de curto circuito	11,35 A
----------------------------	---------

³ Sob Condições de Temperatura Nominal de Operação Do Módulo (NMOT): irradiância de 800 W/m², AM de 1,5, temperatura ambiente de 20°C, vento de 1 m/s.

ESPECIFICAÇÕES MECÂNICAS

Tipo de célula	Silício Monocristalino
----------------	------------------------

Dimensões das células	182*91 mm
-----------------------	-----------

Dimensões do modulo (L x A x P)	2278 x 1134 x 30mm
---------------------------------	--------------------

Número de células	144 (6*24)
-------------------	------------

Peso	26,6 kg
------	---------

Comprimento do cabo	1400mm
---------------------	--------

Diodos Bypass	3
---------------	---

Seção transversal do cabo	4 mm ²
---------------------------	-------------------

Conector	Compatível com MC4
----------	--------------------

Grau de proteção (caixa de junção)	IP68
------------------------------------	------

CONDIÇÕES DE OPERAÇÃO

Temperatura de operação	-40°C - +85°C
-------------------------	---------------

Carga de neve	Até 5400 Pa
---------------	-------------

Carga de vento	Até 2400 Pa
----------------	-------------

Tensão máxima do Sistema	1500 Vcc
--------------------------	----------

Corrente máxima do fusível	25 A
----------------------------	------

CARACTERÍSTICAS DE TEMPERATURA

Coefficiente de temperatura máxima (Pmax)	-0,35 %/°C
---	------------

Coefficiente de temperatura (Voc)	-0,27 %/°C
-----------------------------------	------------

Coefficiente de temperatura (Isc)	+0,045 %/°C
-----------------------------------	-------------

Temperatura nominal do módulo (NMOT)	41±2°C
--------------------------------------	--------

EMBALAGEM

Módulos por pallet	36
--------------------	----

Módulos por Container de 40'HQ	720 peças
--------------------------------	-----------

GARANTIA

Garantia de produto	12 anos
---------------------	---------

Garantia de desempenho (mínimo de 84,8 % de seu desempenho nominal)	25 anos
---	---------